UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

JOÃO PAULO ABDALA BOHACZK

RECONHECIMENTO ÓPTICO DE CARACTERES PARA LEITURA DE DOCUMENTOS EM FORMATO PDF

GUARAPUAVA

2025

JOÃO PAULO ABDALA BOHACZK

RECONHECIMENTO ÓPTICO DE CARACTERES PARA LEITURA DE DOCUMENTOS EM FORMATO PDF

Optical Character Recognition for Reading PDF Documents

Trabalho de Conclusão de Curso de Graduação apresentado como requisito para obtenção do título de Tecnólogo em Tecnologia em Sistemas para Internet do Curso Superior de Tecnologia em Sistemas para Internet da Universidade Tecnológica Federal do Paraná.

Orientadora:Profª. Drª. Kelly Lais Wiggers

GUARAPUAVA

2025

RESUMO

Diante da inacessibilidade de determinados livros e outros textos publicados antes da era digital, bem como do tratamento secundário da comunidade de OCR para com o tratamento dos documentos analisados em texto digital próprio para a leitura casual, determina-se a necessidade de uma ferramenta que, trabalhando com OCR, dedique-se na extração de textos de imagens ou arquivos PDF, visando facilitar a leitura e disseminação desses textos. Para atingir esse objetivo será realizada uma pesquisa comparativa entre ferramentas OCR. Será construída uma API em Python para realizar o trabalho de processamento do OCR e a formatação do texto. Isso será integrado por uma interface web desenvolvida com o framework PHP Laravel, com o objetivo de disponibilizar o projeto para a maior quantidade de pessoas possível. O presente trabalho possui tanto uma via científica e experimental como prática, buscando comparar as ferramentas OCR e solucionar algo que, por muitas vezes, ignorado pelas ferramentas, a devida formatação do texto para leitura, também tendo como objetivo disponibilizar os resultados dessa pesquisa como uma ferramenta de fácil uso e acesso para a comunidade.

Palavras-chave: optical caractere recognition; detecção de textos; aprendizado de máquina.

ABSTRACT

Given the inaccessibility of certain books and other texts published before the digital era, as well as the secondary treatment by the OCR community toward the processing of analyzed documents into digital text suitable for casual reading, there is a need for a tool that, working with OCR, focuses on extracting text from images or PDF files, aiming to facilitate the reading and dissemination of these texts. To achieve this objective, comparative research between OCR tools will be conducted. A Python API will be built to perform the OCR processing work and text formatting. This will be integrated through a web interface developed with the PHP Laravel framework, with the goal of making the project available to as many people as possible. The present work has both a scientific and experimental aspect as well as a practical one, seeking to compare OCR tools and solve something that has been ignored by this tools until now: the proper formatting of text for reading, also aiming to make the results of this research available as an easy-to-use and accessible tool for the community.

Keywords: optical caracter recognition; text detection; machine learning.

LISTA DE FIGURAS

SUMÁRIO

1 INTRODUÇÃO

A escrita é uma grande invenção da humanidade, sendo ela primariamente a representação dos fonemas sonoros, isto é, representação da fala através de símbolos (SCHMANDT-BESSERAT; ERARD, 2009, p. 7). É o salto tecnológico que permitiu que a humanidade se desenvolvesse intelectualmente através do compartilhamento de informações. Durante longo tempo a escrita foi empregada em diferentes materiais e superfícies com o objetivo de transmitir informações, passando por pedras e papiros até finalmente chegar ao papel que é conhecido atualmente. (GABRIAL, 2009)

Grande parte dos escritos da humanidade estão presos em mídia física, como livros e revistas, o que dificulta a sua transmissão por meios digitais. Uma das formas de compartilhamento mais eficientes é através de fotografias que podem ser juntadas em, por exemplo, um arquivo PDF. Isso preserva a sua estrutura original, mas impede a análise de dados, pesquisa e capacidade de compartilhamento que poderia ser obtida se o texto fosse devidamente convertido em formato digital. Neste contexto, um texto digital é aquele que pode ser lido, selecionado e manipulado por um computador — ou seja, convertido em caracteres reais, e não apenas visualmente representado como seria o caso de uma imagem digitalizada que contenha texto.

A humanidade conta com séculos de história escrita inacessíveis, ou com acesso dificultado e inapropriado, para o formato digital. É de grande interesse obter esses textos digitalizados propriamente para o seu compartilhamento, de forma que se preserve ao máximo a sua estrutura original, facilitando a sua leitura e disseminação nos meios digitais.

Algumas tecnologias atuais se destacam na extração de textos em imagens para o formato digital, como por exemplo, Optical Character Recognition (OCR), que é muito popular nos dias de hoje, estando presente na maioria dos smartphones na função da câmera ou na galeria de fotos, fazendo com que seja fácil extrair textos de fotos. Pesquisas recentes têm utilizado OCR para análise de documentos históricos (BOENIG *et al.*, 2019), análise de jornais antigos (DROBAC, 2019) e extração de texto de fotografias de forma geral (LI *et al.*, 2022, p. 9).

Uma das dificuldades encontradas na extração de texto via ferramentas de OCR é a falta de formatação dos textos extraídos. O objetivo do OCR é a extração do texto puro para processamento computacional, contudo, a sua reconstrução para a leitura humana é algo secundário e que muitas vezes deixa a desejar. Outro problema é que essas ferramentas tem de ser treinadas usando Ground Truth (GT) para se tornarem mais eficientes – uma técnica de treinamento em que se mantêm um arquivo, que corresponde ao resultado final da análise de OCR, como espécie de prova real do resultado final (BOENIG *et al.*, 2019).

Visto que o acesso a essas ferramentas e sua otimização exige um olhar especializado e dedicado, o presente projeto busca solucionar esse problema, focando na extração e compartilhamento de textos. Além disso, visa obter uma solução genérica o suficiente para ser usada em diferentes situações.

1.1 Objetivos

1.1.1 Objetivo geral

O objetivo deste trabalho é extrair e transcrever textos completos provenientes de arquivos, os quais podem ser imagens ou arquivos em formato PDF, mediante técnicas de processamento de imagens e OCR.

1.1.2 Objetivos específicos

- Definir a base de dados para realização dos experimentos;
- Efetuar pré-processamento na base de dados, como realce, redimensionamento, recortes, dentre outros;
- Implementar experimentos comparativos com as tecnologias de OCR disponíveis;
- Construir uma API para permitir a inserção e formatação de arquivos;
- Criar um protocolo experimental robusto para validação dos resultados.

1.2 Justificativa

Boenig *et al.* (2019), distinguem a digitalização de imagens do processamento das mesmas por OCR. Os avanços na tecnologia de OCR permitiram que a maioria desses textos fossem processados, resultando em *dirty full text*, um texto sujo, com erros e sem formatação, que tem validade de processamento para alguns casos científicos, mas que pecam em sua precisão e falta de estrutura.

Isso faz com que a conversão de uma página de, por exemplo, uma revista ou um livro, seja uma fotografia ou um arquivo PDF composto por essas fotografias, seja frustrante, caso o objetivo seja a leitura por humanos, devido as imprecisões no resultado final. Por vezes o texto digitalizado final acaba sendo ilegível.

Portanto, avalia-se que a tecnologia de OCR está mais direcionada para a análise de dados do que necessariamente para o consumo humano desses dados. Assim, o desenvolvimento de tecnologias que auxiliem na leitura e transcrição do conteúdo para versões em formato digital pode ser visto como um complemento e optimização da tecnologia.

Como contribuição, tem-se o desenvolvimento de uma ferramenta que visa facilitar a formatação de textos digitalizados com OCR, preservando sua estrutura original, o que torna sua leitura mais agradável e aumenta seu potencial de difusão por meios digitais, como redes sociais e sites dedicados a disseminação cultural.

A principal motivação para o desenvolvimento deste projeto é a dificuldade que se encontra no compartilhamento, anotação e localização de textos que tiveram seu principal período de publicação anterior à popularização da internet. E, consequentemente, esses textos podem não ter sua republicação disponível em formato digital.

Isso é um caso comum em, por exemplo: cursos de faculdades da área de humanas, em que há um desinteresse por parte das editoras na republicação de determinados livros que ainda são muito lidos internamente na academia, fazendo com que um dos parcos meios de acesso desse material seja por escaneamento (VARELLA; FERREIRA, 2012).

O processamento desses textos é custoso e tecnicamente desafiador, mas os avanços recentes de reconhecimento textual utilizando redes neurais oferece maior precisão e eficácia para a área. Isso possibilita visualizar o avanço do uso de redes neurais na tecnologia de OCR, bem como suas possíveis limitações e avaliar sua eficiência. Existem várias ferramentas de OCR disponíveis no mercado que vão desde o nível industrial (PaddleOCR) até o nível acadêmico (OCR-D), o que faz disso um bom momento para testes e comparações entre elas.

Como resultado do projeto desenvolvido será possível disponibilizar uma ferramenta que digitalize texto a partir de imagens ou arquivos PDF facilmente, bem como contribuir para uma pesquisa comparativa de ferramentas OCR disponíveis no mercado.

2 FUNDAMENTAÇÃO TEÓRICA

Nessa seção serão apresentadas as principais definições das técnicas que envolvem visão computacional aplicada na detecção e reconhecimento de textos.

2.1 Visão computacional

A visão computacional é um ramo da inteligência artificial que permite aos computadores interpretar e compreender informações visuais de imagens e vídeos. Muitas vezes, supera-se a percepção visual humana devido o uso de algoritmos especializados (KRISHNA, 2017).

Uma aplicação fundamental de visão computacional é a detecção de texto em imagens, nos quais os sistemas podem identificar e extrair automaticamente o conteúdo textual incorporado em fotos, documentos digitalizados ou *frames* de vídeos. Esse processo, frequentemente chamado de OCR (Optical Character Recognition), envolve a detecção de regiões que contém texto e o reconhecimento dos caracteres e palavras para convertê-los em formatos legíveis por máquinas.

O *pipeline*[1], etapas de processamento, típico de uma aplicação OCR se divide em pré-processamento, processamento e pós-processamento. Alguns modelos OCR possuem processos de pré e pós-processamento integrados. No pré-processamento, geralmente se tem a optimização da imagem para facilitar a detecção da região do texto e a própria detecção de caracteres, em seguida é realizada detecção de texto, classificando as regiões de interesse em que o a detecção de caracteres será realizada (SUBRAMANI *et al.*, 2020).

Para resolver problemas de visão computacional, é considerado o formato de reconstrução da visão humana. Um computador não tem toda a contextualização que um ser humano possui para, por exemplo, distinguir os planos de uma imagem, localizando seu centro e seu fundo. Portanto, uma parte do estudo da área consiste em um esforço por conseguir contextualizar as imagens por meio de algum algoritmo para que operações sejam possíveis (SZELISKI, 2010).

A partir dessas questões, tecnologias como Cadeias de *Markov* e Aprendizado de Máquina surgem de forma associada ao ramo da visão computacional. Essa evolução em torno da contextualização são os primeiros passos para a formulação de IA's (SZELISKI, 2010). Nesse contexto, verifica-se o avanço da literatura com relação às técnicas de transcrição utilizando mLLMs (*Multimodal Large Language Models*), baseadas em aprendizado profundo, pois os modelos multimodais possuem capacidade contextual maior. Além disso, são capazes de ler imagens que possuem agravantes que podem ser ignorados por humanos, mas que representam dificuldades para uma aplicação OCR típica, necessitando de correções.

[1] *pipeline* é uma sequência automatizada de processamento

2.1.1 Processamento de imagens

Segundo Gonzalez e Woods (2017), uma imagem pode ser definida como uma função bidimensional, representada por *f(x,y)*, onde *x* e *y* são coordenadas espaciais, respectivamente horizontal e vertical, e o valor da função *f* indica a intensidade ou nível de cinza da imagem, que pode variar de 0 a 255. Quando os valores dessa função são finitos e discretos, resultam em uma imagem digital. Os autores elencam as principais etapas para processamento de imagens digitais como sendo: aquisição de imagem, filtragem, aprimoramento, processamento de cores, wavelets*, compressão, manipulação morfológica, segmentação, extração de características e classificação de padrões.

Considerando estas etapas de processamento levantadas, o foco do presente trabalho reside em pré-processamento, morfologia, segmentação e extração de características das imagens. Essas etapas serão detalhadas na sequência.

2.1.2 Pré-processamento

Bieniecki, Grabowski e Rozenberg (2007), chamam a atenção para o pré-processamento de imagens que foram adquiridas por aparelhos celulares (em contraposição a documentos escaneados), as deformações correspondentes a esse tipo de captura, os seus efeitos no processamento de OCR e como amenizá-los. Os principais pontos levantados são a distorção geométrica, perca de foco e iluminação não uniforme. Para amenizar isso são aplicadas técnicas de rotação de imagem, correção de perspectiva e transformação de imagem não linear. Um dado interessante ressaltado das tabelas que o trabalho produziu é que imagens com 600dpi (*dots per inch*) resultam em menor acurácia do que imagens com 300dpi.

Os métodos de correção usados na experimentação proposta por Bieniecki, Grabowski e Rozenberg (2007) são de rotação, correção de perspectiva e transformação não linear. Para o experimento, foi utilizada uma imagem de uma página com rotação em 90°. Os resultados foram uma imagem sem área de texto detectável para a imagem original e para a correção de rotação, para 2,72% de erros com a correção de perspectiva e 0,96% de erros com a transformação não linear.

Um dado valioso extraído do artigo anteriormente analisado, é a perspectiva histórica de ferramentas OCR serem optimizadas para a leitura de documentos escaneados, fazendo com que eles tenham iluminação uniforme, sem distorção espacial. Contudo, pode ser viável aumentar a eficiência de documentos adquiridos através de fotografias, sendo necessário realizar o pré-processamento aplicado por Bieniecki, Grabowski e Rozenberg (2007).

2.1.3 Morfologia Matemática

É um processo que pode ser utilizado em imagens binarizadas para aprimorar o reconhecimento de caracteres. Ela se concentra na análise da forma, geometria e estrutura dos objetos presentes em imagens, utilizando operadores não lineares e elementos estruturantes para transformar e extrair informações relevantes (GIROD, 2018).

A morfologia pode ser aplicada tanto no sentido de, por exemplo, expandir as sessões em preto (as linhas de uma letra), para torná-las mais legíveis, ou diminuir as mesmas linhas, com o mesmo objetivo, a depender da mancha da fonte. Em termos gerais é um processo que modifica a forma da imagem (SZELISKI, 2010). Duas operações comuns de morfologia matemática são:

- Abertura: suaviza contornos, elimina pequenos objetos e ruídos, sendo composta por erosão seguida de dilatação;
- Fechamento: preenche pequenas lacunas e conecta regiões próximas, sendo composta por dilatação seguida de erosão.

2.1.4 Segmentação de imagens

A segmentação de imagens é o processo de dividir uma imagem em suas partes constituintes ou objetos, de modo que cada parte seja mais simples e mais significativa para análise. A segmentação visa identificar regiões homogêneas com base em propriedades como intensidade, cor, textura ou forma, facilitando a extração de informações relevantes para tarefas posteriores, como reconhecimento ou análise de cena (GONZALEZ; WOODS, 2017).

O processo de binarização da imagem, também conhecido como *thresholding*, é um tipo de segmentação que tem por objetivo destacar áreas de interesse das imagens. É uma técnica simples que separa objetos do fundo com base em um ou mais valores de intensidade.

Técnicas de segmentação de imagem podem estar aliadas com a detecção de textos. Ou seja, a detecção das regiões de interesse que contém textos, as quais podem ser imagens fotografadas por celulares, pode resultar em resíduos de outras páginas em suas bordas. E, então, é necessária uma segmentação da área de interesse principal. Essa segmentação pode ser obtida por algoritmos de análise de *layout* de documentos ou através de *bounding boxes*, que contornam as principais áreas de interesse da imagem, podendo ser feita a eliminação das outras áreas que não a principal (SZELISKI, 2010).

2.1.5 Extração de características

As técnicas de visão computacional podem permitir o reconhecimento de uma gama de características, que vão de objetos, faces, textos, logos, pontos de referência etc. (KRISHNA,

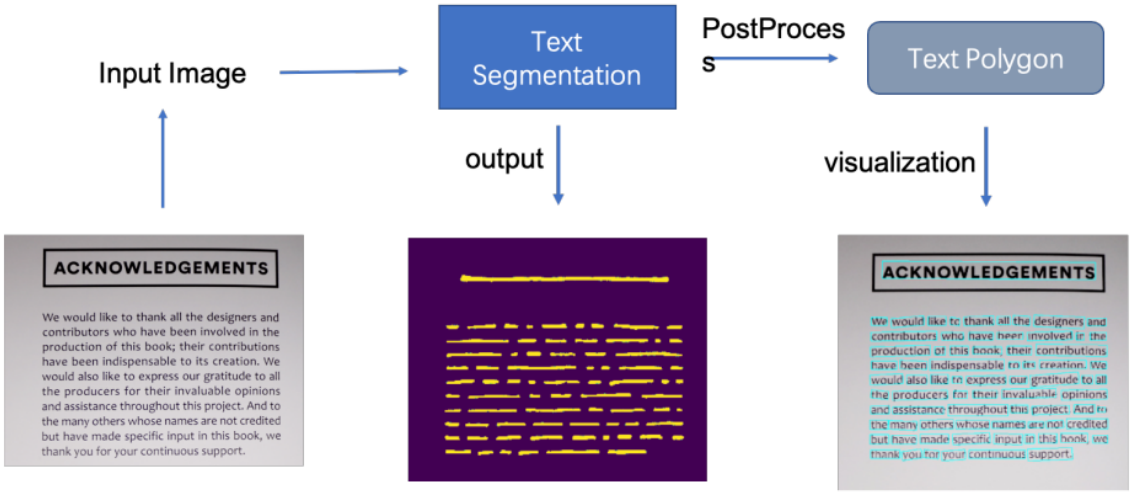

Figura 1 – Demonstração de região de interesse processada pelo paddleOCR, retirado de Li *et al.* (2022)

2017). Desta forma, a extração de características é a etapa na qual se obtêm informações quantitativas relevantes a partir das regiões ou objetos segmentados na imagem.

Uma técnica de destaque para essa etapa é a extração de *layouts* e de diagramação das páginas. Isso permite detectar títulos e subtítulos, bem como classificar regiões que possam representar a contagem de páginas ou o cabeçalho corrente. Alguns OCRs como o paddleOCR (PaddlePaddle Community, 2020) possuem ferramentas nativas para extração de *layouts*.

2.2 Detecção e reconhecimento de textos

A detecção de textos é uma técnica de visão computacional que identifica e localiza regiões que contêm texto em imagens ou documentos digitalizados, permitindo a extração desse texto para posterior processamento, pesquisa ou análise. A detecção de texto normalmente é a primeira etapa nos fluxos de trabalho de OCR. Assim que as regiões de texto são detectadas, os algoritmos de OCR reconhecem e convertem os caracteres visuais em texto legível por máquina, permitindo edição, pesquisa e extração de dados.

Nesse sentido, o objetivo da fase de detecção de textos é encontrar a posição do texto dentro de uma imagem. A área detectada como área de texto pode ser tanto uma linha de texto como somente uma letra ou palavra, como pode ser visto na Figura 1.

Uma abordagem interessante foi apresentada por Li *et al.* (2022), os quais dividiram os métodos de detecção de texto em duas categorias, baseadas em regressão e baseadas em segmentação. Sendo:

- No método regressivo a imagem tem duas propriedades, o texto detectado e o restante é tido como *background*. A imagem é segmentada por uma rede neural, depois é feito um calculo de probabilidade daquele segmento conter um texto.

- O método de segmentação se baseia em uma análise pixel-a-pixel da imagem, também por uma rede neural, para então determinar se esses pixels formam um bloco textual. Devido a esse método se torna mais eficiente na detecção de textos curvados e tem mais precisão dessa segmentação.

Por sua vez, o reconhecimento de texto é uma subárea do OCR, que se realiza após a detecção do texto. Tem como objetivo converter a imagem segmentada em texto. De forma tradicional o reconhecimento de texto se divide em três etapas: 1) pré-processamento de imagem, 2) segmentação de caracteres e 3) reconhecimento de caracteres.

No trabalho de Li *et al.* (2022), os autores dividiram o reconhecimento de texto em duas categorias: reconhecimento de texto regular e reconhecimento de texto irregular. Mais especificamente:

- O método regular é utilizado em imagens mais horizontais, como imagens documentos escaneados;
- O método irregular é usado para cenários naturais, em que o texto não está horizontalmente posicionado na imagem, também podendo estar distorcida, borrada ou com algum outro tipo de irregularidade.

Avanços recentes combinam OCR com *Large Language Models* (LLM) para detectar textos, criando sistemas híbridos para detectar textos e também compreender o contexto e estrutura. Uma LMM é um modelo de linguagem capaz de interpretar e gerar linguagem humana, tendo capacidade de aprendizado a partir de uma entrada, assim como é capaz de resolver tarefas, interpreta e organiza informações. LLMs são treinadas a partir de uma grande quantidade de dados, e conseguem construir texto de forma probabilística, determinando as palavras seguintes a partir dos dados com que foi treinada (MINAEE *et al.*, 2024).

Greif, Griesshaber e Greif (2025) fazem uma comparação entre transcrições feitas com OCR e *Multimodal Large Language Models* (mLLM). Enquanto as tecnologias OCR exigem um *pipeline* complexo e de treinamento em suas múltiplas etapas, sendo elas, de forma geral, pré-processamento, processamento e pós-processamento, as mLLMs propõem uma solução de um passo a partir do *prompt* implementado. Segundo os autores o processamento por mLLMs é mais eficiente do que o estado de arte atual das tecnologias OCR para textos impressos no alfabeto latino, chegando a ser comparado a precisão de uma transcrição manual, mas possuem desempenho inferior para textos históricos escritos.

As mLLMs são mais eficientes do que soluções OCR e não precisam de qualquer pré-processamento de imagem. Contudo, seu custo de processamento é mais elevado em comparação com o OCR. Outro fator a se levar em consideração é o *black box* típico de uma LLM, ou seja, temos entradas e saídas dessa LLM, mas o modo como o processamento da entrada resulta em determinada saída pode ser difícil de precisar, podendo ocorrer resultados imprevistos.

2.3 Pós-processamento

Nguyen *et al.* (2021) classificam o trabalho de pós-processamento em duas etapas: detecção de erros e correção de erros. Para a correção de erros de forma automática o artigo explora as seguintes abordagens:

- **Misturar múltiplos *outputs*:** Consiste em várias leituras OCR do mesmo *input*, podendo ser feitas várias condições diferentes, até mesmo com múltiplas ferramentas, fazendo a junção dessas leituras a partir de algum critério;
- **Abordagem lexical:** A correção é realizada a partir de um dicionário verificando o nível de assertividade das palavras. Esse dicionário pode ser customizado a depender da área de especificidade do texto, algumas abordagens criativas para realizar a correção são exemplificadas, como realizar uma pesquisa no Google com as palavras erradas para que o motor de busca sugira a correção;
- **Modelos de erros:** Baseiam-se no número de mudanças de caracteres por palavra para realizar correções de forma descontextualizada, podendo ajustar palavras que possuem caracteres a mais ou a menos.

Greif, Griesshaber e Greif (2025) chama a atenção para o uso de mLLMs no pós-processamento dos resultados de OCR como meio de correção de erros, mas destaca sua maior eficiência para um processo *end-to-end* em si.

Como o esperado de um artigo que é focado em um *output* para processamento de dados, a formatação do texto não é considerada. Para isso é possível trabalhar a partir dos metadados que a ferramenta de OCR fornece, como ocorre, por exemplo, com o PaddleOCR (PaddlePaddle Community, 2020) e o Tesseract (TEAM, 2024). O Tesseract, por exemplo, pode extrair dados de linha de texto, bloco de texto posição do conteúdo e grau de confiança da transcrição, entre outros (TEAM, 2024).

Esse tipo de dado será importante em uma etapa de reconstrução do texto, mantendo a sua formatação original. Também é importante para sinalizar o grau de confiança da transcrição. Com a devida separação do que pode ser parágrafo, título, imagem e outros componentes do texto é possível construir *outputs* de forma adaptada para diversos formatos. No caso do uso de uma mLLM para a extração do texto Greif, Griesshaber e Greif (2025) utiliza do próprio *input* no *prompt* para enviar instruções da formatação esperada no retorno seu retorno.

3 TRABALHOS RELACIONADOS

A Tabela 1 apresenta os trabalhos relacionados encontrados na literatura que são similares ao presente projeto. Verifica-se que os autores utilizam o OCR integrado com outras técnicas, tais como LLM e Deep Neural Network (DNN) para treinamento das bases de dados. Contudo, considerando que é necessário o treinamento, muitos documentos em diferentes idiomas foram requisitados para a realização dos experimentos.

Tabela 1 – Trabalhos relacionados

Artigo	**Técnica**	**Vantagens**	**Limitações**
Greif, Griesshaber e Greif (2025)	Comparação entre mLLM e OCR.	Não precisa de treinamento, consegue por vezes ser mais eficiente que abordagens OCR tradicionais.	Custo computacional elevado. Tem de lidar com *black boxes*.
Drobac (2019)	OCR com multiplas linguagens e análise de layout.	Desenvolvimento de um modelo OCR capaz de processar mais de uma língua, extração da formatação de jornais em múltiplas colunas.	Precisa de dados em várias línguas para ser treinado.
Kumar, Tanwar e Tiwari (2025)	Comparativo entre técnicas OCR e usando DNN.	Solução end-to-end, não é necessário saber exatamente o que acontece na execução dos testes, sendo fácil e rapidamente aplicável. É mais malevável do que uma aplicação OCR típica.	Precisa de um corpus maior para treinamento.
Traub, Ossenbruggen e Hardman (2015)	Pesquisa sobre o uso de OCR para pesquisas de documentos históricos.	Util para uma análise superficial nos termos de busca.	Insuficiente e não confiável devido ao baixo nível de confiabilidade das transcrições.
Nguyen *et al.* (2021)	Panorama sobre técnicas de pós-correção.	O artigo apresenta técnicas manuais e semiautomáticas, baseadas tanto em correção por palavra-a-palavra como por contexto.	Não se aplica
Liu *et al.* (2024)	Comparativo entre LLMs no uso de OCR.	Debate o por que de LLMs terem capacidade para OCR, faz comparativo de performance com OCR tradicional e aponta para uma perspectiva futura no uso de LLMs em conjunto com tecnologias OCR.	Não se aplica

4 MATERIAIS E MÉTODOS

Para o desenvolvimento deste projeto, foram realizadas as etapas apresentadas na Figura 2. Primeiramente, se selecionou a base de dados. Após isso, um aprimoramento com técnicas de processamento de imagens foi executado. Na sequência, foram realizados experimentos comparativos das tecnologias OCR disponíveis, bem como com a mLLMs Gemini. Após, os resultados foram comparados no processo de digitalização da base de dados escolhida.

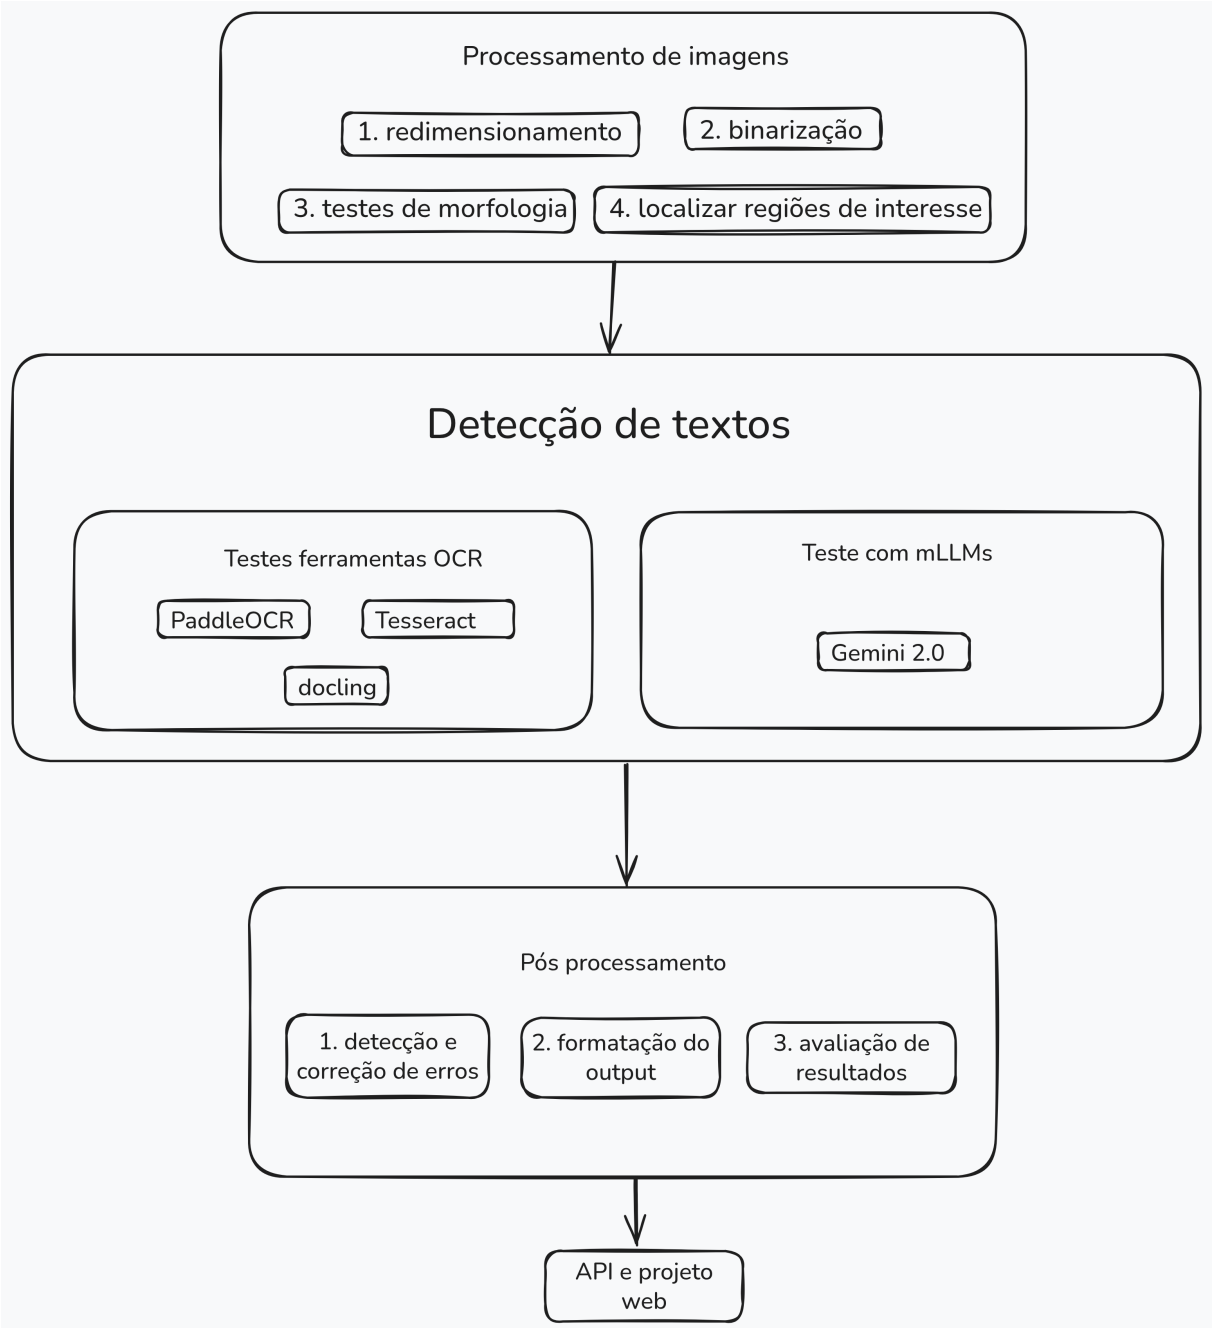

Figura 2 – Diagramas de Etapas do desenvolvimento do Sistema

4.1 Materiais

4.1.1 Base de dados

A base de dados escolhida para os experimentos é a primeira edição da revista italiana de cinema, *Cinema & Film*, que teve suas atividades entre 1967-1970. Essa revista foi escolhida por ser um material de difícil acesso, disponível somente em bibliotecas especializadas de cinematecas, fazendo com que a maior parte do público atual da revista tenha acesso somente através de fotografias que foram transformadas em arquivos PDF. A formatação da revista em texto digital visa tanto facilitar a leitura da revista como a maior autonomia do usuário para ferramentas de tradução. Exemplos das imagens digitalizadas da base de dados são apresentados na Figura 3.

O arquivo da base consiste em um PDF composto por imagens da revista que foram fotografadas. O PDF contêm 162 páginas e ocupa espaço de 771MB. Portanto, a base de dados é composta de imagens de alta resolução, cada página ocupando em torno de 4,8MB. A capa da revista está colorida, mas o restante passou por um processo de *grayscaling*.

Essa base foi organizada em dois conjuntos, um de treinamento e outro de testes para permitir a avaliação das ferramentas.

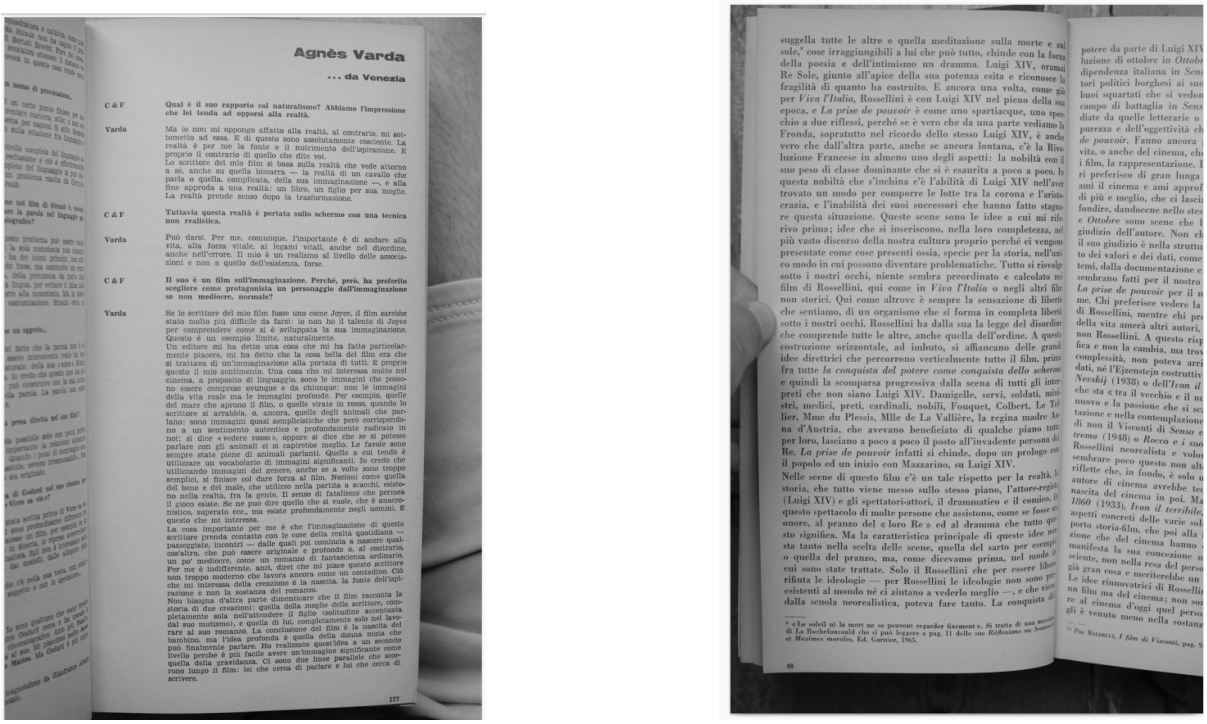

(a) **(b)**

Figura 3 – Exemplos de páginas do livro Cinema & Film

4.1.2 Ferramentas

Foram selecionadas três ferramentas de OCR para testes. PaddleOCR (PaddlePaddle Community, 2020) é uma ferramenta chinesa que tem foco em nível industrial de escalonamento; Docling (Docling Team, 2024) tem como foco a comunidade de IA, especializando-se em extrair texto em arquivos *json* e *markdown*; Tesseract (TEAM, 2024) é a ferramenta mais tradicional da comunidade, contando com boa documentação e vastos exemplos de implementação devido a sua popularidade.

- OpenCV para processamento de imagens;
- Ferramentas OCR: PaddleOCR, Tesseract e Docling;
- Gemini 2.0 para realizar teste com mLLMs;
- Python para criar uma API usando as ferramentas OCR;
- Laravel para fazer uma aplicação web intuitiva e de fácil acesso para a ferramenta;

4.2 Métodos

Considerando as etapas de processamento levantadas na fundamentação teórica, o foco do presente trabalho reside em pré-processamento, morfologia, segmentação e extração de características das imagens.

4.2.1 Processamento de imagens

Na fase de pré-processamento, quando o arquivo de entrada é um PDF, ele foi primeiramente convertido em imagens de alta resolução, garantindo a preservação dos detalhes visuais essenciais para a detecção de texto.

Em seguida, cada imagem gerada passa por uma série de etapas fundamentais de processamento, sendo elas:

- Aplicar o redimensionamento para padronizar as dimensões das imagens, otimizando o desempenho e a precisão dos algoritmos subsequentes.
- Realizar a binarização para converter a imagem em um formato de alto contraste, facilitando a separação do texto do fundo.
- Testar processos de morfologia matemática, como abertura e fechamento, para verificar se há melhora da qualidade dos caracteres.

- Realizar a localização das regiões de interesse (ROIs), onde o texto está presente, utilizando técnicas de seleção manual ou então baseadas em análise de contornos, detecção de bordas ou modelos de aprendizado profundo, conforme descrito em (LI *et al.*, 2022). Essas etapas combinadas aumentam significativamente a eficiência e a acurácia da ferramenta OCR durante o reconhecimento textual.

No caso do presente trabalho, o interesse na segmentação de imagem está aliado com a detecção de textos. Ao mesmo tempo que a imagem deve ser segmentada na área de texto detectada, como o objeto de interesse são imagens fotografadas por celulares, as imagens podem conter resíduos de outras páginas em suas bordas, sendo necessária uma segmentação da área de interesse principal. Essa segmentação pode ser obtida por algoritmos de análise de *layout* de documentos ou através de *bounding boxes*, que contornam as principais áreas de interesse da imagem, podendo ser feita a eliminação das outras áreas que não a principal (SZELISKI, 2010).

Nesse sentido, um dos interesses deste trabalho está na extração de *layout* e de diagramação das páginas, podendo detectar títulos e subtítulos, bem como classificar regiões que possam representar a contagem de páginas ou o cabeçalho corrente. Alguns OCRs como o paddleOCR (PaddlePaddle Community, 2020) possuem ferramentas nativas para extração de *layout*.

O Tesseract, por exemplo, pode extrair dados de linha de texto, bloco de texto posição do conteúdo e grau de confiança da transcrição, entre outros (TEAM, 2024). Esse tipo de dado é importante em uma etapa de reconstrução do texto, como é o maior objetivo deste trabalho, mantendo a sua formatação original. Também é importante para sinalizar o grau de confiança da transcrição. Com a devida separação do que pode ser parágrafo, título, imagem e outros componentes do texto é possível construir *outputs* de forma adaptada para diversos formatos. No caso do uso de uma mLLM para a extração do texto, Greif, Griesshaber e Greif (2025) utiliza do próprio *input* no *prompt* para enviar instruções da formatação esperada no seu retorno.

Portanto, para a detecção de *layout* foi selecionado o paddleOCR, que possui uma opção de *layout detection* que pode ser utilizada de forma autônoma, sendo possível de integrar com as outras ferramentas. Isso é feito de forma que a ferramenta detecta e categoriza partes da imagem. Essas partes, quando de interesse, são enviadas para a ferramenta OCR. O resultado é salvo em um arquivo formato *json* com a *label* e o texto editável. Os *labels* que representam algo como imagens são ignorados nesse processo, pois o interesse está em organizar os títulos, parágrafos, descrições etc. Além disso, foi verificado que o recorte de algumas imagens, devido a angulação da foto, removem as regiões superiores e inferiores do texto, como pode ser visto na Figura 4 . Portanto, foi optado por adicionar um *offset* de cinco pixels em cada *bounding box*.

Como resultado da aplicação da detecção de layout, é possível remover partes que não condizem com a página central, pois elas são classificadas como *image*. Por outro lado, algumas regiões que eram capturadas anteriormente pelo processo padrão do OCR, como o

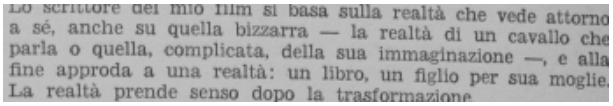

Figura 4 – Exemplo de recorte sem offset

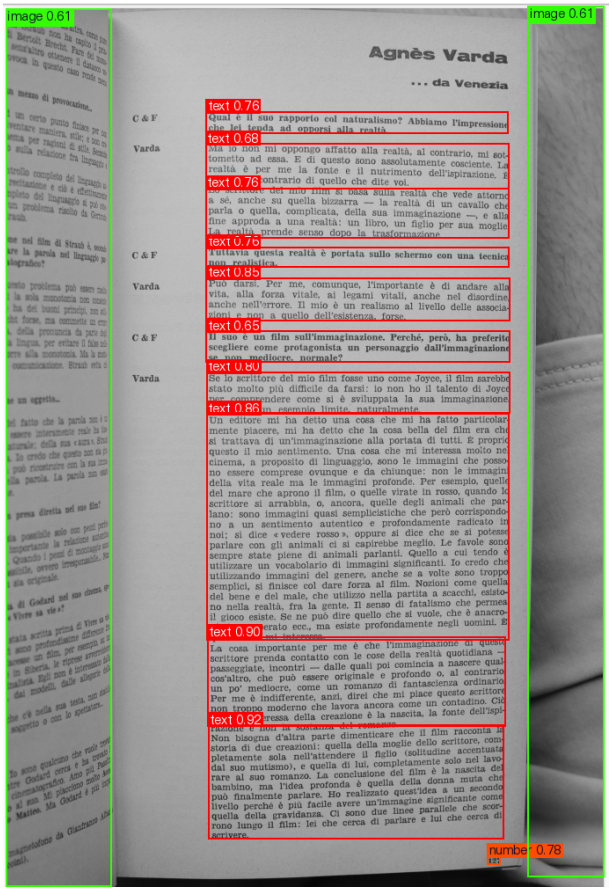

Figura 5 – Exemplo de página com layout detection do Paddle

título do texto e as colunas com o nome do entrevistador e entrevistado (C & F, Varda), no exemplo dado na Figura 5, não foram incluídas para reconhecimento.

4.2.2 Detecção de textos

Nessa etapa foram comparadas algumas ferramentas de OCR disponíveis na literatura, tais como: PaddleOCR (PaddlePaddle Community, 2020), Docling (Docling Team, 2024) e Tesseract (TEAM, 2024).

Os experimentos utilizando mLLM, foram baseados no artigo de Greif, Griesshaber e Greif (2025). No presente projeto, é utilizado o Gemini em diversas versões gratuitas.

É importante destacar que cada ferramenta possui tratamentos específicos. Uma ferramenta pode conseguir extrair a formatação da página e categorizá-la, enquanto outra pode não ter essa função. Portanto, o desenvolvimento das capacidades de pré e pós processamento serão determinadas, em partes, pela ferramenta selecionada.

4.2.3 Pós-processamento

Formatação de output

Devido a natureza singular de cada OCR o processo de formatação de *output* será importante para se obter um retorno consistente na API, independentemente do modelo utilizado.

Avaliação dos resultados

A avaliação das ferramentas teve como critério a maior quantidade de acertos de palavras em conjunto com a facilidade que consegue-se extrair a formatação da página original, isto é, a detecção de linhas, parágrafos e imagens do texto original e a maleabilidade do *output* gerado por elas.

Foi seguido o mesmo método de avaliação disponibilizado em Greif, Griesshaber e Greif (2025), em que é feito um cálculo de distância de Levenshtein e a partir disso é verificada a quantidade de erros por caractere e por palavra, conforme a Equação 1:

$$\frac{\text{Insertions} + \text{Deletions} + \text{Substitutions}}{N} \tag{1}$$

O cálculo de Levenshtein consiste em uma contagem de inserções, deleções e substituições de letras, para o caso de *Word Error Rating* (WER), ou palavras, para o caso de *Character Error Rating* (CER) do resultado final da ferramenta OCR em comparação com um arquivo *Ground Truth*. Essa contagem de Levenshtein é então dividida pelo total de caracteres ou palavras do arquivo *Ground Truth*, representado na equação por *N*, para se obter a porcentagem de cada CER e WER (GREIF; GRIESSHABER; GREIF, 2025).

4.2.4 Desenvolvimento do Sistema Web

Foi construída uma aplicação em Python que realiza a digitalização e formatação do texto extraído de imagens e arquivos PDF, visando melhorar os erros cometidos na fase de digitalização, bem como no pós-processamento de texto encontrados no processamento de ferramentas de OCR.

Como resultado, criou-se uma ferramenta que digitaliza e formata o texto digitalizado, baseado em sua formatação original. A ferramenta possibilita a inserção de um documento, seja em PDF ou imagem, e traz como resultado o texto digitalizado.

Foi construído uma aplicação web, utilizando do framework Laravel, para realizar o processamento dos documentos e imagens, e remontá-los em um PDF. Ao longo da pesquisa, experimentos com a mLLM Gemini a revelou como uma ferramenta de extrema eficiencia para

o processo de OCR. Portanto, ela foi selecionada para ser integrada ao sistema web, deixando a ideia de construir uma API baseada em uma ferramenta OCR em Python de lado.

5 RESULTADOS

5.1 Desenvolvimento Web

Foi desenvolvido uma aplicação web funcional para o projeto, focando em deixar o ambiente já configurado para a fase de testes com as ferramentas OCR. Para desenvolver a implementação foi feito o uso do Gemini 2.0-flash por ser a ferramenta de mais fácil acesso e que exige menos configurações, não sendo necessário treinamentos para conseguir um resultado satisfatório, como notado por Greif, Griesshaber e Greif (2025) .

Para a fase de desenvolvimento focou-se nos elementos principais do projeto como maneira de deixar clara as intenções do trabalho. A tela principal, que pode ser vista na Figura 6, possui um *input* que recebe tanto imagens como arquivos PDF.

Para realizar o Upload foi Utilizada a biblioteca javascript *filepond*, que realiza o upload em chuncks para o servidor, facilitando o envio de arquivos grandes. Os arquivos PDF são convertidos em JPG antes de serem enviados ao Gemini, isso é feito usando a extensão nativa do PHP, o Imagick.

O processamento das páginas e a transcrição do Gemini é executada por filas, usando *jobs*. Para que haja o carregamento progressivo das transcrições para o usuário é feito o disparo de eventos dentro da fila para o *frontend*, utilizando-se de um sistema de *websockets* da biblioteca do próprio Laravel, o Reverb.

O processo de conversão de PDF para imagens, quando feito com arquivos grandes, como é o caso da base de dados (que tem por volta de 5MB por página), trás problemas de performance, cada página leva por volta de um minuto para ser processada, o que estoura o limite padrão de *timeout* dos *workes* das filas do laravel, que é de um minuto, sendo necessária a sua redefinição.

O *prompt* instrui o Gemini a extrair os principais dados da página, como título, subtítulo, parágrafos e número da página em um formato *json*, que é então processado para a visualização do usuário. Foi construída uma versão inicial do *prompt*, que pode ser vista no Apêndice A, e que posteriormente foi aprimorada utilizando da ajuda do próprio Gemini, como instruído por Greif, Griesshaber e Greif (2025) e que também pode ser visto no Apêndice A. O texto então pode ser baixado em formato PDF e cada página tem a opção de ser copiada para a área de transferência, como pode ser visto na Figura 7.

Caso o usuário não esteja logado as transcrições serão apagadas de tempo em tempo por um *job*, que realiza o processamento em *background*, em uma *schedule*, que realiza a operação uma vez por dia. Já os usuários logados tem a possibilidade de observar suas transcrições em um *dashboard*.

Como o trabalho foca no teste de várias ferramentas OCR e mLLMs foi adotado um padrão de *Factories* com *Adapters*, para que na mudança do *provider* OCR não sejam ne-

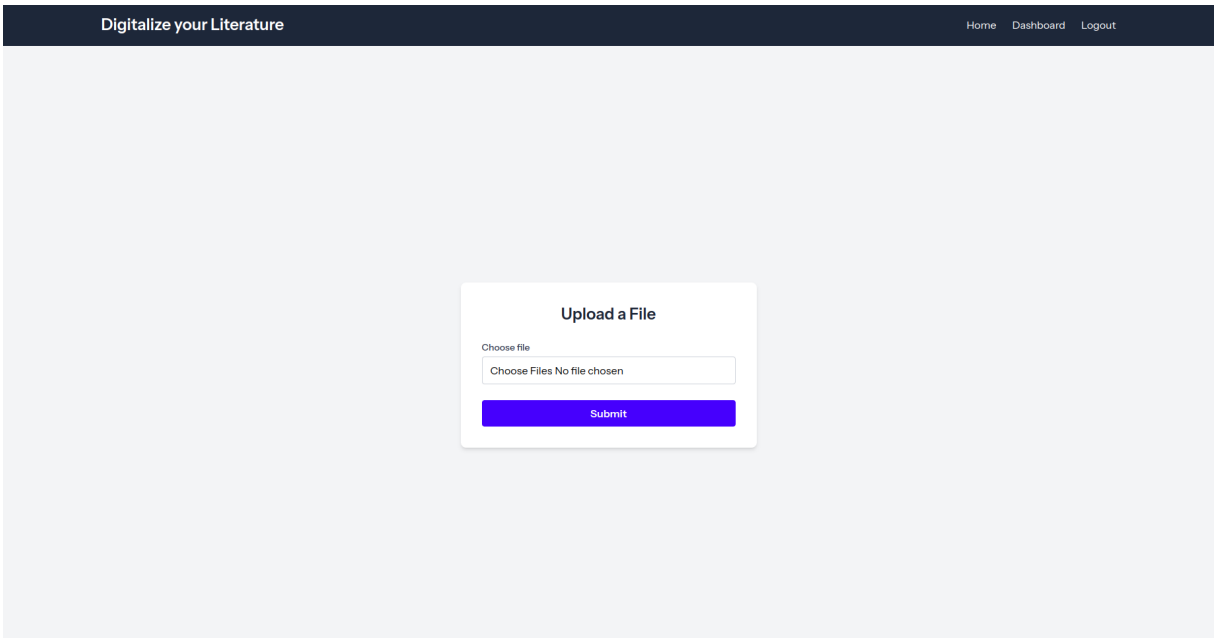

Figura 6 – Tela principal

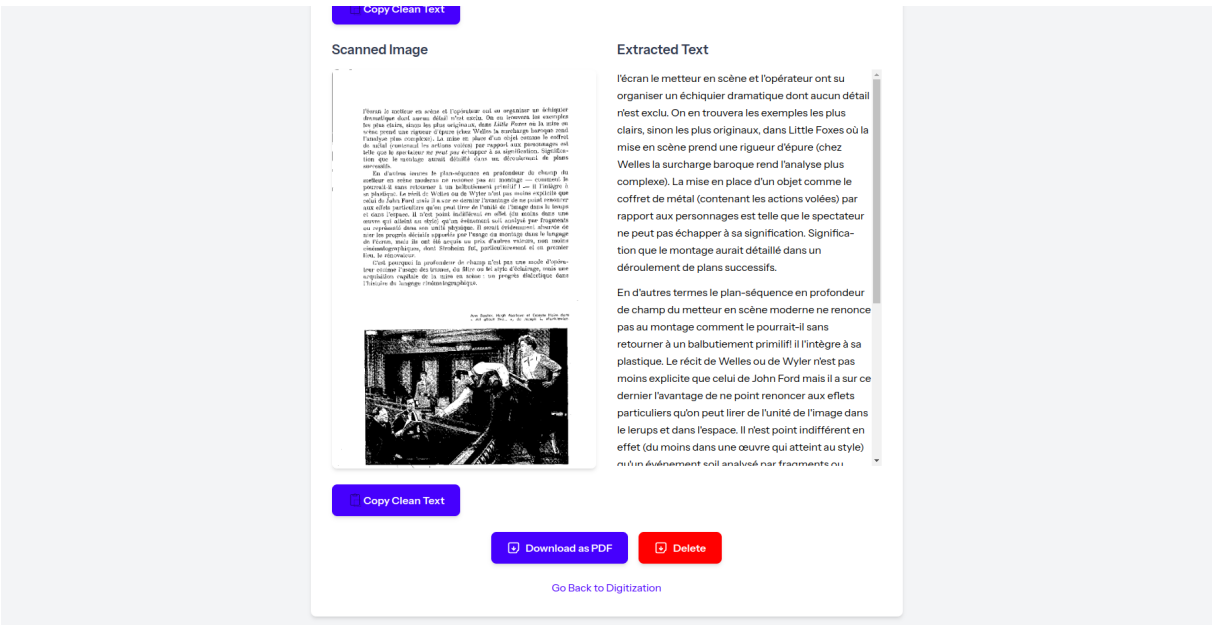

Figura 7 – Resultado Digitalização

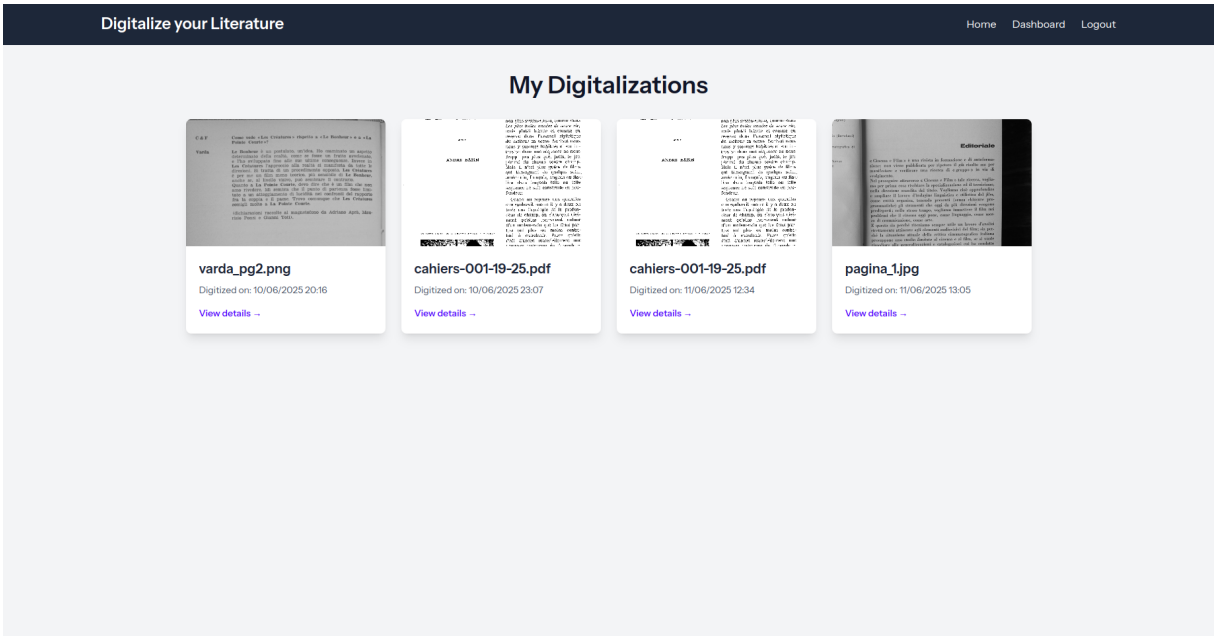

Figura 8 – Resultados das digitalizações

```php
class DigitalizesFactory
{
    João Paulo Abdala Bohaczk *
    public static function make()
    {
        $provider = config( key: 'ocr-service.provider');

        return match ($provider) {
            'gemini' => new GeminiAdapter(),
            default => throw new \Exception( message: "Provider '{$provider}' not supported")
        };
    }
}
```

Figura 9 – Factory do provedor OCR

cessárias demais alterações no código geral da aplicação, somente a reconstrução do *service* desse *provider*.

5.2 Testes iniciais com as ferramentas

Um teste foi realizado com a Figura 3a, apresentada na seção de Materiais. Foram avaliadas algumas ferramentas já para ambientação de como utilizá-las nos próximos experimentos. Para o primeiro teste foi utilizada a ferramenta Gemini e foram obtidos resultados satisfatórios quanto a transcrição. O tempo de processamento do Gemini foi de 9,6 segundos. Esse tempo é consideravelmente maior do que o de uma ferramenta OCR, como o Tesseract, que processou a mesma imagem em 1,4 segundos.

Um problema encontrado nos testes manuais da aplicação é a inconsistência de *outputs* do Gemini, mesmo que o *prompt* instrua que, por exemplo: não devem ser retornados caracteres

como "\n"ou "\t", por vezes os mesmos acabam sendo retornados. Também houve problemas com o envio de *jsons* com a formatação quebrada.

Foi feito uma breve comparação com as transcrições utilizando o Tesseract, Paddle, Docling e Gemini com a biblioteca Jiwer no Python. Essas transcrições foram feitas com a mesma imagem da Figura 3a, sem nenhum tratamento na imagem.

A comparação foi feita com um arquivo *Ground Truth*, uma transcrição feita à mão da página. O texto resultante de cada ferramenta passou por uma normalização para não levar em conta aspectos de formatação, somente a sequência de palavras. O resultado de *WER* (Word Error Rating) e *CER* (Character Error Rating) de cada ferramenta pode ser visto na Tabela 2 .

Tabela 2 – Trabalhos relacionados

Ferramenta	**Tempo de processamento (ms)**	**WER (%)**	**CER(%)**
Gemini	9,681	0,77	0,20
Tesseract	1,490	69,60	40,65
Docling	33,502	85,96	74,21
Paddle	14,499	33,33	16,91

É possível observar que a ferramenta que levou mais tempo de processamento foi a Docling, a mesma na qual ocorreram mais erros em caracteres e palavras. Já o mais eficiente, em tempo de processamento foi o Tesseract, contudo, os menores erros foram observados utilizando o Gemini. Deve-se levar em consideração que esses são resultados preliminares, as imagens não passaram por nenhum pré-processamento ou pós-correção, as ferramentas não foram optimizadas ou treinadas.

5.3 Experimentos com Paddle

Os experimentos com a ferramenta Paddle foi desafiante, devido ao formato de treinamento. Visto que além do *dataset* ter de ser preparado especificamente para a ferramenta de treinamento as instruções da documentação oficial podem ser um pouco desconexas, fazendo com que o treinamento seja também um processo de aprendizado [1].

Além disso, é necessário uma máquina potente para rodar treinamentos grandes, dificultando com que um indivíduo com computador modesto faça treinamentos de maior escala em tempo eficiente. A configuração do treinamento, quando muito pesada, pode resultar em erros de *Out of Memory* da placa gráfica.

[1] As principais informações para o treinamento dos modelos de *detection* e *recognition* estão disponíveis em três páginas: https://www.paddleocr.ai/latest/en/version3.x/pipeline_usage/OCR.html#41-model-fine-tuning, https://www.paddleocr.ai/main/en/version3.x/module_usage/text_detection.html#4-custom-development, https://www.paddleocr.ai/main/en/version3.x/module_usage/text_recognition.html#412-download-the-pre-trained-model.

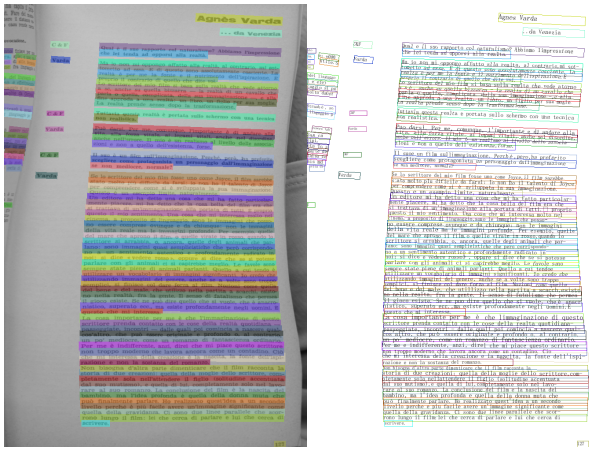

Figura 10 – Bounding boxes e transcrição do Paddle sem treinamento

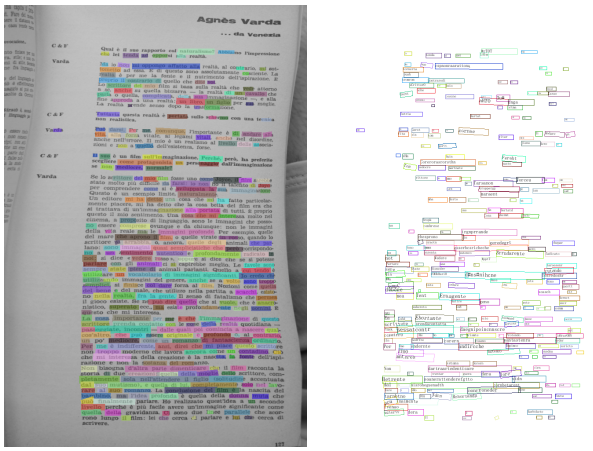

Figura 11 – Bounding boxes e transcrição do Paddle com treinamento

Após o treinamento, uma outra dificuldade encontrada foi a integração do modelo treinado com o *pipeline* do Paddle, que causa erros constantes. A falta de clareza da documentação nessa parte é notória.

O treinamento foi realizado utilizando o *Total Text dataset* [2] que é composto por 1555 imagens que possuem texto horizontais, multi orientados e curvados. Para o modelo de *detection* foi possível fazer uma iteração de 100 *epochs* para o treinamento, mas, devido a limitações do *hardware* utilizado, o modelo de *recognition* só teve 10 *epochs*. O resultado foi uma piora significativa tanto da detecção quanto do reconhecimento de caracteres, de forma tão notória que não valeria a pena um teste de WER e CER desses resultados.

A própria ferramenta do paddle oferece *outputs* em imagem dos resultados das *bounding boxes* junto com a transcrição da imagem, que pode ser visto na Figura 10:

Com esse resultado se pode especular que a carga de treinamento não foi o suficiente, ou que foi erroneamente aplicada. Isso se deve ao nível de especialização que as ferramentas requerem.

[2] (CH'NG; CHAN; LIU, 2020)

5.4 Experimentos com Tesseract

Ao ler a própria documentação de treinamento do *Tesseract*, foi encontrada uma recomendação para não ser realizado treinamentos na ferramenta, conforme a descrição abaixo:

> *There are a variety of reasons you might not get good quality output from Tesseract. It's important to note that, unless you're using a very unusual font or a new language, retraining Tesseract is unlikely to help.* [3]

Em conjunto disso as tentativas de treinamento se demonstraram problemáticas, portanto se optou por realizar ajustes indicados pela documentação da ferramenta na sessão *Improving the quality of the output* [4].

Ao utilizar a opção de *output* da imagem processada pelo Tesseract, que pode ser vista na Figura 12 , se pode observar que ele faz um bom trabalho na parte de binarização da imagem, as letras ficaram bem claras e destacadas. Porém, as *bounding boxes* geradas são excessivas e confusas.

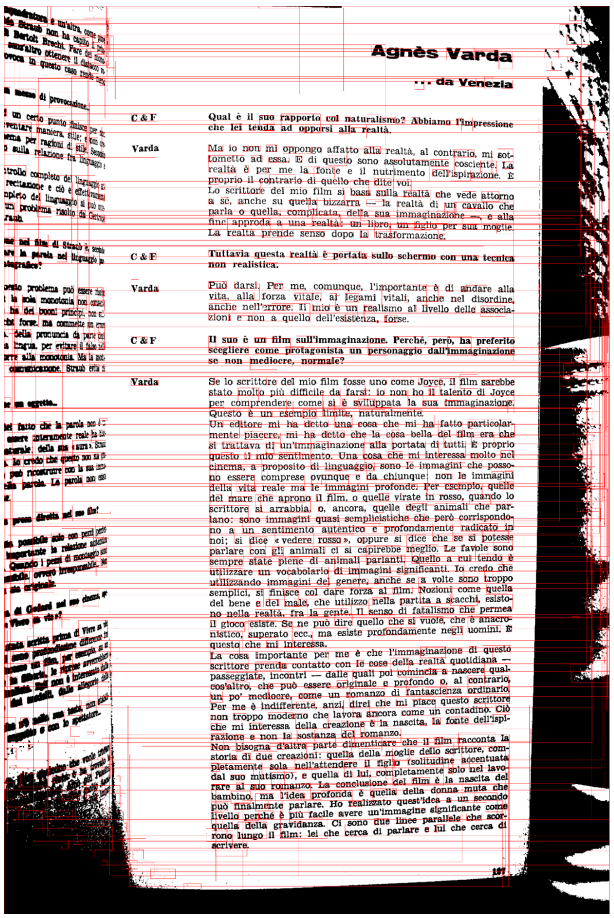

Figura 12 – Bounding Boxes Tesseract

[3] https://tesseract-ocr.github.io/tessdoc/ImproveQuality.html
[4] https://tesseract-ocr.github.io/tessdoc/ImproveQuality.html

Na tabela 4 são comparadas as transcrições geradas pelo Tesseract e o *ground truth* das mesmas linhas (há um ruído de texto da página que aparece ao lado da principal, que nesse processo de comparação será ignorado)

Tabela 3 – Ground Truth Tesseract

	Tesseract	GT
Parágrafo 1	Qual e il suo rapporto col naturalismo? Abbi ” ” che lei tenda ad opporsi alla realta,. lamo limpressione	Qual è il suo rapporto col naturalismo? Abbiamo l’impressione che lei tenda ad opporsi alla realtà.
Parágrafo 2	Ma 10 non mi oppongo affatto alla realta, al c tometto ad essa. E di questo sono Fn rie, a realta € per me la fonte e il nutrimento dell’ispirazione B proprio il contrario di quello che dite voi. :	Ma io non mi oppongo affatto alla realtà, al contrario, mi sot-tometto ad essa. E di questo sono assolutamente cosciente. La realtà è per me la fonte e il nutrimento dell’ispirazione. È proprio il contrario di quello che dite voi.

No primeiro parágrafo há um corte da sequência de texto da primeira linha, fazendo que “[Abbi]amo limpressione” só apareça na segunda linha de texto. Isso provavelmente acontece pela angulação da imagem, que não está centralizada, pois não é um escaneamento e sim uma foto tirada com o celular.

Diferente do Paddle que possui uma solução nativa para rotacionar páginas, o Tesseract, em sua documentação, pede para que a rotação/*deskwing* seja feita manualmente. Foi utilizado o editor de fotos nativo do Iphone para gerar uma imagem rotacionada e que tentasse amenizar as distorções espaciais da imagem original, também foi optado por recortar as “rebarbas” de texto que aparecem da outra página, pois elas causam muito ruído na leitura dos dados.

Tabela 4 – Ground Truth Tesseract com imagem Recortada

	Tesseract	GT
Parágrafo 1	Qual é il suo rapporto col naturalismo? Abbiamo limpressione che lei tenda ad opporsi alla realta.	Qual è il suo rapporto col naturalismo? Abbiamo l’impressione che lei tenda ad opporsi alla realtà.
Parágrafo 2	Ma io non mi oppongo affatto alla realta, al contrario, mi sot- | tometto ad essa. E di questo sono assolutamente cosciente. La | realta € per me la fonte e il nutrimento dell’ispirazione. E proprio il contrario di quello che dite voi.	Ma io non mi oppongo affatto alla realtà, al contrario, mi sot-tometto ad essa. E di questo sono assolutamente cosciente. La realtà è per me la fonte e il nutrimento dell’ispirazione. È proprio il contrario di quello che dite voi.

Se tem uma enorme melhora no resultado, porém, há o surgimento de vários “|”, talvez como uma forma da ferramenta informar o salto de linhas, ou por erro de leitura mesmo.

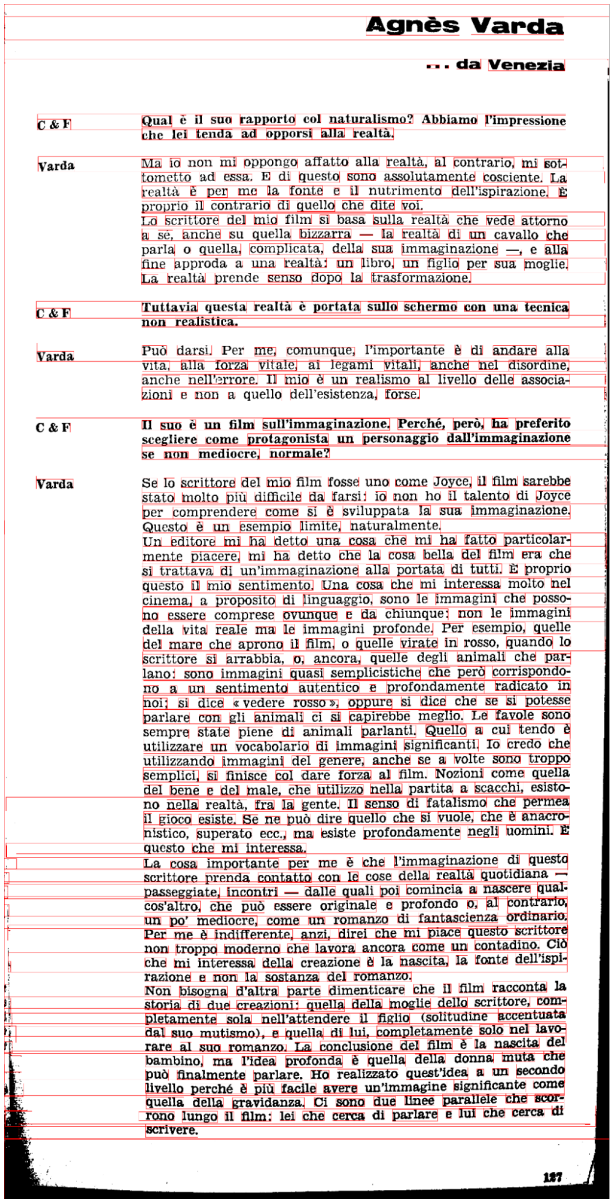

Agnès Varda

... da Venezia

C & F — Qual è il suo rapporto col naturalismo? Abbiamo l'impressione che lei tenda ad opporsi alla realtà.

Varda — Ma io non mi oppongo affatto alla realtà, al contrario, mi sottometto ad essa. E di questo sono assolutamente cosciente. La realtà è per me la fonte e il nutrimento dell'ispirazione. È proprio il contrario di quello che dite voi.
Lo scrittore del mio film si basa sulla realtà che vede attorno a sé, anche su quella bizzarra — la realtà di un cavallo che parla o quella, complicata, della sua immaginazione —, e alla fine approda a una realtà: un libro, un figlio per sua moglie. La realtà prende senso dopo la trasformazione.

C & F — Tuttavia questa realtà è portata sullo schermo con una tecnica non realistica.

Varda — Può darsi. Per me, comunque, l'importante è di andare alla vita, alla forza vitale, ai legami vitali, anche nel disordine, anche nell'errore. Il mio è un realismo al livello delle associazioni e non a quello dell'esistenza, forse.

C & F — Il suo è un film sull'immaginazione. Perché, però, ha preferito scegliere come protagonista un personaggio dall'immaginazione se non mediocre, normale?

Varda — Se lo scrittore del mio film fosse uno come Joyce, il film sarebbe stato molto più difficile da farsi: io non ho il talento di Joyce per comprendere come si è sviluppata la sua immaginazione. Questo è un esempio limite, naturalmente.
Un editore mi ha detto una cosa che mi ha fatto particolarmente piacere, mi ha detto che la cosa bella del film era che si trattava di un'immaginazione alla portata di tutti. È proprio questo il mio sentimento. Una cosa che mi interessa molto nel cinema, a proposito di linguaggio, sono le immagini che possono essere comprese ovunque e da chiunque: non le immagini della vita reale ma le immagini profonde. Per esempio, quelle del mare che aprono il film, o quelle virate in rosso, quando lo scrittore si arrabbia, o, ancora, quelle degli animali che parlano: sono immagini quasi semplicistiche che però corrispondono a un sentimento autentico e profondamente radicato in noi; si dice « vedere rosso », oppure si dice che se si potesse parlare con gli animali ci si capirebbe meglio. Le favole sono sempre state piene di animali parlanti. Quello a cui tendo è utilizzare un vocabolario di immagini significanti. Io credo che utilizzando immagini del genere, anche se a volte sono troppo semplici, si finisce col dare forza al film. Nozioni come quella del bene e del male, che utilizzo nella partita a scacchi, esistono nella realtà, fra la gente. Il senso di fatalismo che permea il gioco esiste. Se ne può dire quello che si vuole, che è anacronistico, superato ecc., ma esiste profondamente negli uomini. È questo che mi interessa.
La cosa importante per me è che l'immaginazione di questo scrittore prenda contatto con le cose della realtà quotidiana — passeggiate, incontri — dalle quali poi comincia a nascere qualcos'altro, che può essere originale e profondo o, al contrario, un po' mediocre, come un romanzo di fantascienza ordinario. Per me è indifferente, anzi, direi che mi piace questo scrittore non troppo moderno che lavora ancora come un contadino. Ciò che mi interessa della creazione è la nascita, la fonte dell'ispirazione e non la sostanza del romanzo.
Non bisogna d'altra parte dimenticare che il film racconta la storia di due creazioni: quella della moglie dello scrittore, completamente sola nell'attendere il figlio (solitudine accentuata dal suo mutismo), e quella di lui, completamente solo nel lavorare al suo romanzo. La conclusione del film è la nascita del bambino, ma l'idea profonda è quella della donna muta che può finalmente parlare. Ho realizzato quest'idea a un secondo livello perché è più facile avere un'immagine significante come quella della gravidanza. Ci sono due linee parallele che scorrono lungo il film: lei che cerca di parlare e lui che cerca di scrivere.

127

Figura 13 – Bounding Boxes Tesseract Recortado

5.5 Resultados com layout detection

Foram realizados experimentos utilizando as ferramentas OCR Tesseract, Paddle e Docling com e sem o layout PaddleOCR, apresentado na seção 4.2.1. Foi possível notar que, ao se comparar a taxa de WER e CER de cada ferramenta OCR com o *layout detection,* o resultado teve desempenho mais baixo . Isso ocorre por que o *layout detection* se provou ineficiente, removendo colunas e títulos do texto, fazendo com que parte do conteúdo fosse perdido ou ignorado. A expectativa de que, ao se enviar partes menores da imagem em vez de uma página inteira, tornaria o reconhecimento mais eficiente, se demonstra pouco eficiente. Por mais que ferramentas como o Paddle sejam projetadas para reconhecer poucas palavras em uma imagem, como por exemplo, textos de fotografias tiradas ao ar-livre ou placas, elas demonstram um nível de eficiência regular com as páginas da revista utilizada nos experimentos.

A seguir, a Tabela 5 apresenta os resultados obtidos da Figura 3a, a página 127 da revista utilizada nos experimentos.

Tabela 5 – Trabalhos relacionados

Ferramenta	WER (%)	CER(%)
Tesseract	69,60	40,65
Tesseract com layout	77,01	97
Docling	85,96	74,21
Docling com layout	95,99	85,73
Paddle	33,33	16,91
Paddle com layout	72,53	50,46

Com os resultados observados se conclui que é melhor deixar a ferramenta lidar com a segregação das partes da imagem por ela mesma. Isso surte pouco efeito no processamento final, utilizar técnicas de *deskewing* é o que mais surte efeitos positivos até então.

5.6 Experimentos com Gemini

Para se realizar o teste com o Gemini optou-se por usar o Google AI Studio, uma ferramenta *web* que utiliza o Gemini como motor, mas que permite a troca fácil entre modelos e a visualização do uso de tokens, dentre outras informações.

Como teste inicial, a imagem da Figura 3a foi enviada para o modelo Nano Banana, que é especialista em geração e edição de imagens, com o seguinte prompt: “Transcreva o conteúdo da imagem”. O resultado foi muito além do que as ferramentas OCR tendo um WER de 35.19% e um CER de 18.76%. A taxa de Erros se deve a pequenas alterações nas palavras, trocas como: *venezia* por *veneza*, *è* por *é*, *il* por *o*. Ou seja, parece haver uma confusão na língua italiana quando o modelo tenta fazer a transcrição.

Ao utilizar o modelo gemini 2.5 pro o problema da confusão com a língua italiana é sanado, tendo um WER de 4.01% e um CER de 1.71%, a maioria dos erros se deve a algo que foi optado ao fazer o arquivo GT, que é a separação das palavras por hífen quando elas são divididas entre as linhas ao acabar a página sem espaço para escrever elas inteiras, fazendo com que uma palavra como “sottometto” se torne “sot-tometto”, através da contextualização o gemini já faz o trabalho de juntar os caracteres em uma só palavra. Também há uma adição, que não estava no arquivo GT, mas que faz parte do canto inferiro esquerdo da imagem, pertencente à página anterior: “magnetofono da Gianfranco Albano”. Portanto, mesmo sem nenhuma instrução para ignorar o que está fora da região de interesse da imagem, o Gemini já fez um bom trabalho em determinar isso, somente com essa pequena falha.

Como é do interesse da pesquisa utilizar os modelos em uma aplicação é interessante a realização de testes nos mais variados modelos, mirando o com menor preço e melhor eficiência.

Ao utilizar o modelo 2.0 flash-lite com o mesmo prompt se tem como resultado não uma transcrição, mas uma tradução do conteúdo. Em alguns casos, mesmo ao pedir uma transcrição fiel é retornada uma tradução do conteúdo. A estruturação em que o texto é retornado também não é satisfatória, a divisão de linhas é confusa. Já o 2.0 flash possui um desempenho semelhante ao 2.5 pro, tendo um WER de 6.48% e um CER de 2.48%. No 2.5 flash-lite encontrou-se os mesmo problemas que o 2.0 flash-lite, como são modelos mais leves eles parecem não conseguir determinar bem os limites da imagem, também não há a junção de palavras em que as letras estão separadas, algo que é feito automaticamente pelo modelo flash.

Portanto, como se pode observara na Tabela 6 o modelo com melhor eficiência nesse caso acaba sendo o 2.0 flash, sendo um modelo tão eficiente para o propósito quanto o 2.5 pro, mas possuindo um custo muito abaixo dele. Também é curioso observar que o modelo especialista em imagem, o Nano Banana, tem desempenho piorado devido a sua deficiência em diagnosticar a língua do texto.

Tabela 6 – Resultados com modelos do Gemini

Ferramenta	WER (%)	**CER(%)**
Nano Banana	35,19	18,76
2.5 pro	4,01	1,71
2.0 flash	6,48	2,48

5.7 Discussões

Com relação aos experimentos realizados, com WER de 33,33% e CER de 16,91%, o Paddle é certamente a melhor ferramenta OCR pura sem treinamento. As ferramentas de análise oferecidas por ele são melhores e mais fáceis de serem aplicadas do que, por exemplo, a do tesseract.

O treinamento só foi realizado com o PaddleOCR, que, como visto anteriormente, deixou o modelo com uma piora significativa. A falta de meios para diagnosticar qualquer erro cometido no processo de treinamento e, posteriormente, o desencorajamento ao treinamento que a documentação do Tesseract trás, em conjunto com os resultados muito bons com o Gemini, levaram ao maior foco em analisar os modelos sem treinamento do que em descobrir como treiná-los.

O Gemini é de longe a melhor ferramenta para OCR, possuindo os melhores resultados e o melhor nível de praticidade. Porém, se deve estar atento para a mudança que cada modelo pode trazer aos resultados, bem, como se observou com o modelo 2.0 flash-lite, como a falta de precisão e nível de aleatoriedade de resultado que a LLM pode trazer, devido a sua própria natureza, sendo inconsistente em sua saída, mesmo preservando as mesmas informações de *input*.

6 CONCLUSÃO

Diante da inacessibilidade de determinados livros (VARELLA; FERREIRA, 2012) e outros textos publicados antes da era digital, bem como do tratamento secundário da comunidade de OCR para com o uso dos documentos analisados em texto digital próprio para a leitura casual, determina-se a necessidade de uma ferramenta que, trabalhando com OCR, dedique-se na extração de textos de imagens ou arquivos PDF, visando facilitar a leitura e disseminação desses textos.

Para atingir esse objetivo foi realizada uma pesquisa comparativa entre ferramentas OCR, sendo selecionada aquela que mais se destacar no acerto de palavras e no retorno da formatação original do texto. Conforme os experimentos realizados, a ferramenta selecionada não foi um OCR convencional, mas sim uma LLM multimodal, o Gemini, por possuir os melhores resultados.

Desta forma, foi desenvolvida uma ferramenta *web*, integrada ao Gemini, que possibilita a extração de textos de imagens e de arquivos PDF em texto puro, bem como a geração desse texto em um novo arquivo PDF limpo.

Nos experimentos realizados, observou-se que o Tesseract possui bom desempenho em ambiente controlado, onde se sabe que as imagens estarão devidamente alinhadas, sem distorção espacial, ou seja, imagens que passaram por um processo de escaneamento. Já quando se utilizam fotos capturadas de celulares, se considera um ambiente fora do padrão, que possui ruídos e objetos fora do contexto que se espera encontrar. Já para ambientes diversos, o Paddle resultou em melhor desempenho, pois ele possui correção espacial nativa, podendo até mesmo lidar com caracteres em um *layout* arredondado.

Contudo, nos experimentos, a AI multimodal do Gemini se revelou muito mais eficiente no processamento de texto, na detecção de layout e no nível de praticidade com que se consegue os resultados. Isso provavelmente também tem correlação com o contexto, pois a AI multimodal tem uma capacidade generalista de inferir contexto na imagem, extraindo aquilo que é de real interesse ao mesmo tempo que consegue fazer pós-correção daquilo que está falho.

Para resultados mais robustos, o uso de uma ferramenta OCR pura, evitando o processo de treinamento, pode ser mais indicada a depender da aplicação (por exemplo: detecção de informações em documentos). Isso se deve pois os resultados são mais rápidos e diretos, sem precisar depender de requisições HTTP, possuindo um *output* padronizado. Para o caso específico de aplicação de OCR em páginas de livros/revistas multi-idiomas, que não seguem um padrão específico, o uso de uma AI multimodal parece ser o mais eficiente e recomendado.

Como trabalhos futuros, seria interessante explorar ferramentas de OCR baseadas em mLLMs, bem como observar a mudança de trajetória de ferramentas tradicionais, se suas atualizações levam em conta integrações com mLLMs. O principal desafio, agora que os resultados de *output* são qualitativamente eficientes, seria o foco em garantia de formatação desses *outputs*, bem como evitar a alucinação da LLM.

Na ferramenta web muita coisa pode ser aprimorada e adicionada. Em relação a qualidade de vida para o usuário final, seria interessante poder editar o *output* final, visto que o processamento pode ser falho, a opção de ajuste manual pode ser de enorme interesse. Quanto a estruturação interna da ferramenta, é utilizado um banco SQL para gerenciar a localização das imagens, o resultado do *output* é salvo em um arquivo *json* correspondente a essa imagem. Seria mais eficiente utilizar um banco NoSQL, fazendo com que o caminho para a imagem e o seu *output* fossem salvos no mesmo documento.

REFERÊNCIAS

BIENIECKI, W.; GRABOWSKI, S.; ROZENBERG, W. Image preprocessing for improving ocr accuracy. *In*: **2007 International Conference on Perspective Technologies and Methods in MEMS Design**. [*S.l.*: *s.n.*], 2007. p. 75–80.

BOENIG, M. *et al.* Labelling ocr ground truth for usage in repositories. *In*: **Proceedings of the 3rd International Conference on Digital Access to Textual Cultural Heritage (DATeCH2019)**. New York, NY, USA: ACM, 2019. p. 3–8. Disponível em: https://doi.org/10.1145/3322905.3322916.

CH'NG, C. K.; CHAN, C. S.; LIU, C. Total-text: Towards orientation robustness in scene text detection. **International Journal on Document Analysis and Recognition (IJDAR)**, v. 23, p. 31–52, 2020.

Docling Team. **Docling**. 2024. https://github.com/docling-project/docling. Acesso em: 17 abr. 2025. Veja também: https://arxiv.org/abs/2408.09869. Disponível em: https://github.com/docling-project/docling.

DROBAC, S. **DATeCH2019 - Session 4. Senka Drobac**. 2019. Apresentação do artigo "Improving OCR of Historical Newspapers and Journals Published in Finland". Disponível em: https://www.youtube.com/watch?v=3ZhHPx00wjg.

GABRIAL, B. History of writing technologies. *In*: BAZERMAN, C. (Ed.). **Handbook of Research on Writing: History, Society, School, Individual, Text**. [*S.l.*]: Taylor & Francis Group, 2009. p. 27–39.

GIROD, B. **Digital Image Processing: Morphological Image Processing**. 2018. Course material, Stanford University. Available from EE368/CS232 Digital Image Processing course, Stanford University. Disponível em: https://stanford.edu/class/ee368/.

GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing, Global Edition**. 4. ed. London, England: Pearson Education, 2017.

GREIF, G.; GRIESSHABER, N.; GREIF, R. **Multimodal LLMs for OCR, OCR Post-Correction, and Named Entity Recognition in Historical Documents**. arXiv, 2025. Disponível em: https://arxiv.org/abs/2504.00414.

KRISHNA, R. **Computer Vision: Foundations and Applications**. Stanford University, 2017. First printing, December 2017. Licensed under the Apache License, Version 2.0. Disponível em: http://www.apache.org/licenses/LICENSE-2.0.

KUMAR, B.; TANWAR, S.; TIWARI, S. Ocr using traditional and dnn approach. *In*: ____. **Mechatronics**. CRC Press, 2025. p. 196–210. ISBN 9781003494478. Disponível em: http://dx.doi.org/10.1201/9781003494478-11.

LI, C. *et al.* **Dive into OCR**. PaddleOCR Community, 2022. Disponível em: https://github.com/PaddleOCR-Community/Dive-into-OCR.

LIU, Y. *et al.* Ocrbench: on the hidden mystery of ocr in large multimodal models. **Science China Information Sciences**, Springer Science and Business Media LLC, v. 67, n. 12, dez. 2024. ISSN 1869-1919. Disponível em: http://dx.doi.org/10.1007/s11432-024-4235-6.

MINAEE, S. *et al.* **Large Language Models: A Survey**. arXiv, 2024. Disponível em: https://arxiv.org/abs/2402.06196.

NGUYEN, T. T. H. *et al.* Survey of post-ocr processing approaches. **ACM Computing Surveys**, Association for Computing Machinery (ACM), v. 54, n. 6, p. 1–37, jul. 2021. ISSN 1557-7341. Disponível em: http://dx.doi.org/10.1145/3453476.

PaddlePaddle Community. **PaddleOCR**. 2020. https://github.com/PaddlePaddle/PaddleOCR. Acesso em: 17 abr. 2025. Disponível em: https://github.com/PaddlePaddle/PaddleOCR.

SCHMANDT-BESSERAT, D.; ERARD, M. Origins and forms of writing. *In*: BAZERMAN, C. (Ed.). **Handbook of Research on Writing: History, Society, School, Individual, Text**. [*S.l.*]: Taylor & Francis Group, 2009. p. 7–24.

SUBRAMANI, N. *et al.* **A Survey of Deep Learning Approaches for OCR and Document Understanding**. arXiv, 2020. Disponível em: https://arxiv.org/abs/2011.13534.

SZELISKI, R. **Computer Vision: Algorithms and Applications**. Springer, 2010. August 18, 2010 draft. For non-commercial personal use only. Disponível em: http://szeliski.org/Book/.

TEAM, T. T. O. **Tesseract OCR**. 2024. https://github.com/tesseract-ocr/tesseract. Acesso em: maio de 2025.

TRAUB, M. C.; OSSENBRUGGEN, J. van; HARDMAN, L. Impact analysis of ocr quality on research tasks in digital archives. *In*: ____. **Research and Advanced Technology for Digital Libraries**. Springer International Publishing, 2015. p. 252–263. ISBN 9783319245928. Disponível em: http://dx.doi.org/10.1007/978-3-319-24592-8_19.

VARELLA, G.; FERREIRA, I. M. **Livros inacessíveis, lei antiquada**. 2012. Acesso em: 28 abr. 2025. Disponível em: https://idec.org.br/em-acao/artigo/livros-inacessiveis-lei-antiquada.

APÊNDICE A – *Prompts* Utilizados no Gemini

Neste apêndice, estão listados os *prompts* fornecidos ao modelo Gemini durante a fase de extração e organização de texto a partir de imagens digitalizadas.

Prompt 1

> Transcreva o conteúdo da imagem mantendo a formatação. A imagem é uma página de livro ou de uma revista. Foque somente na página principal, ignore o conteúdo das bordas. O conteúdo deve ser retornado em json classificando o título, subtítulo, o número da página, qualquer header com o título do livro/-capítulo. O conteúdo principal deve ser retornado por parágrafos, mantendo ao máximo a estrutura original do texto, mas as quebras de linha originais não precisam ser especificadas como quebras, o importante é saber o início e fim dos parágrafos, ""e "" ̂ não devem ser retornados. No caso de tabulações no formato de entrevistas separar o nome do falante como se fosse um novo parágrafo. Caso alguma dessas informações esteja faltando deve ser retornado null. Caso a imagem tenha mais de uma página o conteúdo deve retornar várias páginas. Exemplo de construção do json: "page": "headerTitle": null "title": null, "subtitle": null, "paragraphs": ["parágrafo1", "parágrafo2", "parágrafo3",] "pageNumber": null

Prompt 2

> Transcreva o conteúdo textual da imagem. A imagem representa uma página de livro ou revista. Concentre-se **exclusivamente no conteúdo principal da página**, ignorando elementos das margens, rodapés ou cabeçalhos que não sejam o título do livro/capítulo e imagens.
>
> O resultado deve ser um objeto JSON formatado rigorosamente conforme o exemplo fornecido. Para cada página detectada, o JSON deve conter um objeto "page"com as seguintes chaves:
>
> - **"headerTitle"**: (string ou null) O título do livro, capítulo ou seção que aparece no cabeçalho da página (se existir). - **"title"**: (string ou null) O título principal da página (se houver). - **"subtitle"**: (string ou null) O subtítulo da página (se houver). - **"pageNumber"**: (inteiro ou null) O número da página (se detectável). - **"paragraphs"**: (array de strings) Uma lista de parágrafos. Cada string no array deve representar um parágrafo completo.
>
> **Instruções detalhadas para "paragraphs":**
>
> 1. **Preservação da Estrutura**: Mantenha a estrutura original do texto o máximo possível, respeitando a separação lógica dos parágrafos. 2. **Remoção

de Caracteres Especiais**: **Remova estritamente** quaisquer caracteres de nova linha (“) e tabulação (“͡) do texto dos parágrafos. Eles não devem aparecer no JSON final. Esse tipo de será lidada na separação por parágrafos. 3. **Diálogos/Entrevistas**: Se houver diálogos ou entrevistas com nomes de falantes (ex: "Nome do Falante: Texto"), o nome do falante deve ser tratado como um novo parágrafo. 4. **Conteúdo Faltante**: Se alguma das informações solicitadas (título, subtítulo, etc.) não for encontrada na imagem, seu valor correspondente no JSON deve ser **null**.

Estrutura do JSON (obrigatório):

Se a imagem contiver múltiplas páginas, o JSON deve ser um array de objetos "page". Se contiver apenas uma página, será um único objeto "page".

Exemplo de JSON esperado:

“‘json "page": "headerTitle": "Introdução à Inteligência Artificial", "title": "A Evolução das Máquinas Pensantes", "subtitle": "Desde a Lógica Simbólica à Aprendizagem Profunda", "paragraphs": ["A inteligência artificial (IA) tem sido um campo de estudo fascinante e em constante evolução, buscando replicar e aprimorar capacidades cognitivas humanas em sistemas computacionais.", "Desde os primórdios da lógica simbólica, que tentava codificar o conhecimento de forma explícita, até as abordagens modernas de aprendizado de máquina, que permitem aos sistemas aprender com dados, a IA tem percorrido um longo caminho.", "O impacto da IA é vasto e crescente, influenciando setores como saúde, finanças e transporte, e prometendo transformar radicalmente a forma como interagimos com a tecnologia."], "pageNumber": 15 , "headerTitle": "Introdução à Inteligência Artificial", "title": null, "subtitle": "Desafios Atuais e Futuros", "paragraphs": ["Apesar dos avanços notáveis, a IA enfrenta desafios significativos, como a interpretabilidade de modelos complexos e a ética no uso de algoritmos preditivos.", "A garantia de que os sistemas de IA sejam justos, transparentes e responsáveis é crucial para a sua aceitação e integração na sociedade.", "Pesquisas futuras se concentram em áreas como a IA explicável (XAI) e o aprendizado federado, buscando superar essas barreiras e expandir as fronteiras do que é possível."], "pageNumber": 16