



UNIVERSIDADE FEDERAL RURAL DO SEMI-ÁRIDO
PRÓ-REITORIA DE GRADUAÇÃO
CENTRO MULTIDISCIPLINAR - PAU DOS FERROS
CURSO DE CIÊNCIAS E TECNOLOGIA

ANA KELLY NOBRE COSTA

**Reconhecimento gestual da língua de sinais com técnicas de inteligência
artificial: uma revisão sistemática da literatura**

PAU DOS FERROS/RN

2025

ANA KELLY NOBRE COSTA

Reconhecimento gestual da língua de sinais com técnicas de inteligência artificial: uma revisão sistemática da literatura

Monografia apresentada à Universidade Federal Rural do Semi-Árido como requisito para obtenção do título de Bacharel em Ciências e Tecnologia.

Orientadora: **Rosana Cibely B Rego**, Prof.^a Dra.

Coorientadora: **Náthalee Cavalcanti de Almeida Lima**, Prof. Dra.

PAU DOS FERROS/RN

2025

© Todos os direitos estão reservados a Universidade Federal Rural do Semi-Árido. O conteúdo desta obra é de inteira responsabilidade do (a) autor (a), sendo o mesmo, passível de sanções administrativas ou penais, caso sejam infringidas as leis que regulamentam a Propriedade Intelectual, respectivamente, Patentes: Lei nº 9.279/1996 e Direitos Autorais: Lei nº 9.610/1998. O conteúdo desta obra tomar-se-á de domínio público após a data de defesa e homologação da sua respectiva ata. A mesma poderá servir de base literária para novas pesquisas, desde que a obra e seu (a) respectivo (a) autor (a) sejam devidamente citados e mencionados os seus créditos bibliográficos.

C
838r Costa, Ana Kelly Nobre.
Reconhecimento gestual da língua de sinais com técnicas de inteligência artificial: uma revisão sistemática da literatura / Ana Kelly Nobre Costa. - 2025.
41 f. : il.

Orientadora: Rosana Cibely Batista Rego.
Coorientadora: Náthalee Cavalcanti de Almeida Lima.
Monografia (graduação) - Universidade Federal Rural do Semi-árido, Curso de Ciência e Tecnologia, 2025.

1. Reconhecimento gestual. 2. Língua Brasileira de Sinais (LIBRAS). 3. Inteligência Artificial (IA). 4. Aprendizado de máquina. 5. Língua de sinais. I. Rego, Rosana Cibely Batista, orient. II. Lima, Náthalee Cavalcanti de Almeida, co-orient. III. Título.

Ficha catalográfica elaborada por sistema gerador automático em conformidade com AACR2 e os dados fornecidos pelo(a) autor(a).

Biblioteca Campus Pau dos Ferros
Bibliotecária: Erlanda Maria Lopes da Silva
CRB: 15/966

O serviço de Geração Automática de Ficha Catalográfica para Trabalhos de Conclusão de Curso (TCC's) foi desenvolvido pelo Instituto de Ciências Matemáticas e de Computação da Universidade de São Paulo (USP) e gentilmente cedido para o Sistema de Bibliotecas da Universidade Federal Rural do Semi-Árido (SISBI-UFERSA), sendo customizado pela Superintendência de Tecnologia da Informação e Comunicação (SUTIC) sob orientação dos bibliotecários da instituição para ser adaptado às necessidades dos alunos dos Cursos de Graduação e Programas de Pós-Graduação da Universidade.

ANA KELLY NOBRE COSTA

Reconhecimento gestual da língua de sinais com técnicas de inteligência artificial: uma revisão sistemática da literatura

Monografia apresentada à Universidade Federal Rural do Semi-Árido como requisito para obtenção do título de Bacharel em Ciências e Tecnologia.

Defendida em: 25 / 03 / 2025.

BANCA EXAMINADORA

Rosana Cibely Batista Rego, Prof. Dra. (UFERSA)
Presidente



Documento assinado digitalmente
NATHALEE CAVALCANTI DE ALMEIDA LIMA
Data: 30/03/2025 20:31:38-0300
Verifique em <https://validar.iti.gov.br>

Náthalee Cavalcanti de Almeida Lima, Prof. Dra. (UFERSA)
Coorientadora

George Felipe Fernandes Vieira, Prof. (UFERSA)
Membro Examinador

Huliane Medeiros da Silva, Prof. Dra. (UFERSA)
Membro Examinador

AGRADECIMENTOS

Agradeço primeiramente a Deus pela dádiva de vida, pela saúde, e por me guiar através dos desafios, permitindo alcançar este marco significativo.

Aos meus familiares e amigos, em especial aos meus pais, desejo manifestar minha sincera apreciação pelo amor incondicional, incentivo constante e apoio incansável que ofereceram em todas as fases da minha jornada.

Às orientadoras, expresso minha profunda gratidão por todo o respaldo, cuidado, conhecimento compartilhado e serenidade demonstrada durante o processo de construção deste projeto conclusivo.

A Banca Examinadora cuja participação, tempo dedicado e as contribuições valiosas contribuíram para aprimorar a qualidade e o contínuo desenvolvimento das habilidades acadêmicas e profissionais.

A tecnologia é apenas uma ferramenta. Em termos de motivação e colaboração, os professores e os alunos são os que fazem a diferença.

Bill Gates

RESUMO

As línguas de sinais são sistemas linguísticos completos e naturais utilizados por comunidades surdas em todo o mundo. Cada uma delas possui características próprias, estruturadas em diferentes níveis, como fonologia, morfologia, sintaxe e semântica. No Brasil, a Língua Brasileira de Sinais (LIBRAS) é reconhecida oficialmente e desempenha um papel essencial na comunicação e inclusão social da comunidade surda. Este estudo apresenta uma revisão sistemática da literatura, baseada no protocolo proposto por Kitchenham (2007), para investigar como técnicas de inteligência artificial (IA) estão sendo aplicadas no reconhecimento gestual da língua de sinais e em especial a LIBRAS. A metodologia incluiu a definição da questão de pesquisa, busca na base Scopus, seleção de estudos por critérios de inclusão e exclusão, extração de dados e avaliação da qualidade. Foram analisados 93 artigos, que evidenciaram o uso predominante de redes neurais convolucionais (CNN) na identificação de padrões visuais. Entre os desafios enfrentados estão a variabilidade dos gestos, a necessidade de bases de dados mais robustas e a influência de fatores ambientais, como iluminação e posição da câmera. Os banco de dados mais utilizados incluem *Sign Language MNIST*, *ArSL2018* e *ASL Fingerspelling Images*. As principais métricas de avaliação foram acurácia, precisão, recall e F1-score. Conclui-se que, apesar dos avanços, ainda há desafios a serem superados para tornar o reconhecimento gestual da língua de sinais mais preciso e acessível, fortalecendo a inclusão da comunidade surda.

Palavras-chave: Reconhecimento gestual. Língua Brasileira de Sinais (LIBRAS). Inteligência Artificial (IA). Aprendizado de máquina. Língua de sinais

ABSTRACT

Sign languages are complete and natural linguistic systems used by deaf communities around the world. Each language has its own characteristics, structured at different levels, such as phonology, morphology, syntax and semantics. In Brazil, the Brazilian Sign Language (LIBRAS) is officially recognized and plays an essential role in the communication and social inclusion of the deaf community. This study presents a systematic review of the literature, based on the protocol proposed by Kitchenham (2007), to investigate how artificial intelligence (AI) techniques are being applied in the gestural recognition of sign language and LIBRAS in particular. The methodology included the definition of the research question, search in the Scopus database, selection of studies by inclusion and exclusion criteria, data extraction and quality assessment. A total of 93 articles were analyzed, which evidenced the predominant use of convolutional neural networks (CNN) in the identification of visual patterns. Among the challenges faced are the variability of gestures, the need for more robust databases and the influence of environmental factors, such as lighting and camera position. The most widely used databases include Sign Language MNIST, ArSL2018 and ASL Fingerspelling Images. The main evaluation metrics were accuracy, precision, recall and F1-score. It is concluded that, despite the advances, there are still challenges to be overcome to make sign language gesture recognition more accurate and accessible, strengthening the inclusion of the deaf community.

Keywords: Gesture recognition. Brazilian Sign Language (LIBRAS). Artificial Intelligence (AI). Machine learning. Sign languages

SUMÁRIO

1	INTRODUÇÃO	10
1.1	OBJETIVOS.....	12
1.2	APRESENTAÇÃO DO TRABALHO.....	13
2	REVISÃO SISTEMÁTICA DA LITERATURA.....	14
3	METODOLOGIA	16
3.1	QUESTÕES DE PESQUISA.....	17
3.2	CRITÉRIOS DE INCLUSÃO E EXCLUSÃO.....	18
3.3	STRING DE BUSCA.....	19
3.4	EXTRAÇÃO DE DADOS.....	21
3.5	CRITÉRIOS DE QUALIDADE.....	21
4	RESULTADOS E DISCUSSÕES.....	23
4.1	TÉCNICAS DE IA.....	24
4.2	ATRIBUTOS UTILIZADOS.....	26
4.3	MÉTRICAS.....	28
4.4	DESAFIOS E LIMITAÇÕES.....	29
4.5	BASES DE DADOS.....	31
4.6	ANÁLISE DE QUALIDADE.....	32
5	CONSIDERAÇÕES FINAIS	34
5.1	TRABALHOS FUTUROS.....	35
	REFERÊNCIAS	36

1 INTRODUÇÃO

De acordo com ROCHA e STUMPF (1996), a Língua de Sinais não é um idioma universal e, assim como ocorre com as línguas orais, apresenta variações entre diferentes países. Além disso, pode haver diferenças regionais e entre comunidades de surdos dentro de um mesmo território. SABAUDO (2022) afirma que enquanto as línguas orais são baseadas na comunicação sonora, a Língua de Sinais é estruturada como um sistema gestual-visual, no qual os gestos englobam elementos linguísticos manuais, corporais e faciais responsáveis pela articulação dos sinais.

Cada Língua de Sinais apresenta características próprias, organizadas em diferentes níveis estruturais. O nível fonológico envolve as configurações e movimentos necessários para a formação dos sinais; o nível morfológico refere-se à construção e combinação desses sinais; o nível sintático define regras específicas para a organização das expressões; e o nível semântico diz respeito à construção e atribuição de significado (CASTRO, 2019).

A comunicação em Língua Brasileira de Sinais (LIBRAS) trata-se de uma forma de comunicação não verbal que se expressa por meio de gestos, expressões faciais e movimentos do corpo, permitindo a transmissão de ideias, pensamentos e sentimentos de maneira natural e intuitiva (RODRIGUES e VALENTE, 2012). A LIBRAS é a língua oficial das pessoas surdas no Brasil e é reconhecida como uma língua natural e completa (RODRIGUES e VALENTE, 2012). O reconhecimento gestual da LIBRAS com técnicas de inteligência artificial (IA) tem sido um estudo desafiador, mas é uma tecnologia amplamente estabelecida e empregada nos últimos anos, o que contribui significativamente para o avanço contínuo de softwares relacionados a essa esfera no cotidiano (SABAUDO, 2022).

Segundo a Google Cloud (2025), a IA é um campo da ciência que desenvolve máquinas capazes de aprender, raciocinar e executar tarefas complexas. Seu funcionamento baseia-se na análise de grandes volumes de dados por meio de algoritmos e redes neurais, como o aprendizado de máquina (machine learning) e o aprendizado profundo (deep learning). Modelos como as redes neurais convolucionais (CNNs) e recorrentes (RNNs) são amplamente utilizados em aplicações como reconhecimento de imagens, processamento de linguagem natural e previsões. Além de automatizar processos e reduzir erros, a IA proporciona maior velocidade e disponibilidade contínua, acelerando pesquisas e otimizando setores como segurança cibernética, indústria e saúde. Seu avanço tem impulsionado

inovações em diversas áreas, incluindo o desenvolvimento de novos tratamentos médicos e a análise precisa de grandes quantidades de dados.

No contexto da inclusão social e da comunicação, a IA tem sido aplicada no reconhecimento de línguas de sinais, como a LIBRAS. Esta língua, a qual é complexa, com uma gramática própria e uma grande variedade de sinais, o que torna a tarefa de reconhecimento de gestos um desafio para uma IA, mas existem propostas de solução através de softwares que utilizam técnicas de IA e Processamento Digital de Imagens (PDI), que podem ser utilizadas para o reconhecimento gestual da LIBRAS (COMUNELLO, PARREIRA, CUNHA e LOPES, 2019).

Em PASSOS (2019) é abordada a importância da comunicação na sociedade e destaca a língua de sinais como uma forma essencial de permitir a interação entre pessoas surdas e ouvintes. A língua de sinais visa a inclusão dos surdos na sociedade e atua como uma ponte entre esses dois grupos. No entanto, a falta de conhecimento sobre a língua de sinais é um obstáculo, frequentemente a presença de intérpretes de LIBRAS para facilitar a comunicação entre surdos e ouvintes. A LIBRAS é composta por diversos sinais representativos que correspondem às palavras da língua oral, mas algumas palavras ainda não têm uma representação adequada e são indicadas por sinais do alfabeto (PASSOS, 2019).

Diante dessa realidade, compreender como a tecnologia pode contribuir para a acessibilidade e inclusão dos surdos, especialmente por meio do reconhecimento gestual por IA, torna-se fundamental. Para isso, utiliza-se a revisão sistemática da literatura, uma metodologia que possibilita a análise crítica e a organização das evidências sobre um tema específico. Segundo Kitchenham (2007), uma revisão sistemática é um método rigoroso e estruturado de identificação, avaliação e síntese de todas as evidências disponíveis sobre uma questão de pesquisa específica. Esse tipo de revisão busca minimizar vieses e fornecer uma visão abrangente do estado atual do conhecimento em determinada área, utilizando uma metodologia transparente e reaplicável.

Diferente das revisões tradicionais, que podem ser influenciadas pela subjetividade do pesquisador, a revisão sistemática segue um protocolo previamente definido, que inclui critérios claros de inclusão e exclusão de estudos, estratégias de busca detalhadas e técnicas de extração e análise de dados. Além disso, sua importância reside no fato de permitir a identificação de lacunas na literatura, a avaliação da qualidade das evidências disponíveis e o suporte à tomada de decisões baseadas em evidências (KITCHENHAM, 2007).

A metodologia adotada para essa Revisão Sistemática da Literatura (RSL) seguiu o protocolo de Kitchenham (2007). Inicialmente, foi realizada a identificação das abordagens mais utilizadas de inteligência artificial e aprendizado de máquina aplicadas a esse reconhecimento. Em seguida, foram analisados os atributos mais relevantes para a descrição e classificação dos sinais, a fim de compreender quais características são essenciais para o funcionamento dos modelos de reconhecimento. Além disso, investigaram-se as finalidades das soluções de reconhecimento destacando seus principais usos e aplicações. Também foram mapeados os desafios e obstáculos mencionados na literatura, e para assegurar a validade dos estudos analisados, a pesquisa incluiu a identificação das principais fontes de dados utilizadas para o treinamento e validação dos modelos de reconhecimento. Além de que, foram examinados os critérios e métricas aplicados na avaliação da eficácia dessas técnicas.

Para a pesquisa, foi selecionada a base de dados Scopus, a qual, segundo IEEE (2024) incorpora bases como a IEEE Xplore. O Scopus também inclui os registros dos bancos de dados MEDLINE e EMBASE, entre outras fontes. (MEMORIAL SLOAN KETTERING CANCER CENTER, 2015). Dessa forma, ao realizar a busca na Scopus, foi possível acessar um conjunto abrangente de publicações, garantindo que a revisão não estivesse restrita a uma única base de dados.

1.1 OBJETIVOS

O objetivo geral deste trabalho é realizar uma revisão sistemática da literatura sobre a aplicação da inteligência artificial na língua de sinais, com ênfase na LIBRAS. A proposta é mapear as contribuições já existentes, identificar desafios e tendências, além de fornecer uma base sólida para futuras pesquisas na área.

Para alcançar esse objetivo, este estudo busca identificar e analisar as principais técnicas de inteligência artificial aplicadas ao reconhecimento gestual, bem como investigar os atributos mais relevantes para a classificação dos gestos e os fatores que influenciam o desempenho dos modelos. Ademais, são avaliados os desafios e limitações enfrentados pelos pesquisadores, as bases de dados utilizadas no treinamento e validação dos sistemas de reconhecimento gestual, assim como as principais métricas aplicadas na avaliação desses modelos, a fim de compreender quais critérios são mais utilizados para medir seu desempenho e confiabilidade.


Dessa forma, serão examinadas e analisadas publicações relevantes, com o objetivo de responder à questão principal: como a pesquisa em língua de sinais tem se desenvolvido com o uso da inteligência artificial?

1.2 APRESENTAÇÃO DO TRABALHO

A estrutura do trabalho segue com a Seção 2, que aborda a RSL. Na Seção 3, são detalhados os procedimentos metodológicos adotados. A Seção 4 expõe e analisa os resultados obtidos a partir da revisão. Em seguida, a Seção 5 apresenta as considerações finais, destacando as principais conclusões do estudo. Por fim, a Seção 6 reúne as referências utilizadas.

2 REVISÃO SISTEMÁTICA DA LITERATURA

A RSL, realizada com base no protocolo proposto por Kitchenham (2007) e amplamente utilizado na área de engenharia de software, foi adaptada para este estudo para garantir rigor e confiabilidade na pesquisa. Esse protocolo estabelece um processo estruturado em três etapas principais: planejamento, condução e relato dos resultados. A Figura 1 ilustra esse fluxo metodológico.



Fonte: Elaborado pelo autor, adaptado de Kitchenham (2007)

Na etapa de planejamento, foi definida a questão de pesquisa e elaborado um protocolo. A pergunta de pesquisa deve ser específica, relevante e estruturada de maneira a orientar a busca e a análise dos estudos selecionados (GALVÃO, 2014). Seguindo as diretrizes de Kitchenham (2007), a pergunta foi definida de maneira precisa e concisa, garantindo que a revisão sistemática fosse direcionada a um problema específico e investigável. A partir dessa definição, elaborou-se o protocolo de revisão, documentando os critérios de inclusão e exclusão, as bases de dados a serem consultadas e a estratégia de extração e análise dos dados.

O protocolo de revisão é uma abordagem estruturada que estabelece de forma objetiva como os estudos serão selecionados, quais métodos serão usados para extrair e analisar as informações, e como será feita a avaliação da qualidade dos artigos selecionados. Esse protocolo assegura a transparência, reprodutibilidade e confiabilidade da revisão sistemática (Kitchenham, 2007; Donato H, 2019).

Logo, foram estabelecidos os critérios de inclusão e exclusão para pesquisa dos estudos, as bases de dados a serem consultadas e os métodos para extração e análise dos dados. A estratégia de busca tem papel na recuperação de estudos relevantes e na abrangência da revisão sistemática. É importante que a estratégia de pesquisa seja rigorosamente desenvolvida com alta sensibilidade para encontrar todos os potenciais artigos relevantes (Donato H, 2019). Para isso, é essencial desenvolver estratégias de busca rigorosas, utilizando palavras-chave, operadores booleanos e bases de dados científicas de forma estruturada, conforme recomendado por Kitchenham (2007).

Na etapa de condução da revisão, foi realizada uma busca sistemática na base Scopus, que foi escolhida por sua reputação e por agregar fontes reconhecidas, como IEEE Xplore e outras. A utilização das palavras-chave relacionadas ao reconhecimento gestual de língua de sinais, e de LIBRAS com inteligência artificial, foi estratégica para assegurar um levantamento amplo e abrangente da literatura existente sobre o tema, permitindo incluir estudos diretamente relacionados ao reconhecimento de sinais com o uso de tecnologias emergentes. Essas decisões visam garantir que a revisão inclua os estudos mais relevantes e atuais, cobrindo diferentes abordagens e perspectivas.

Após os estudos filtrados, foram analisados seus títulos, resumos e, posteriormente, os textos completos, de acordo com os critérios estabelecidos. Além disso, foi aplicada uma estratégia de extração de dados padronizada para assegurar a comparabilidade entre os estudos. Por fim, na fase de relato dos resultados, os artigos selecionados foram organizados e analisados de maneira sistemática

A metodologia seguiu as diretrizes de Kitchenham (2007), permitindo uma avaliação crítica das abordagens utilizadas, dos desafios encontrados, das bases de dados empregadas e das métricas utilizadas para avaliar os modelos de reconhecimento gestual. Esse processo estruturado possibilitou um panorama confiável sobre o estado da IA no reconhecimento gestual de língua de sinais e LIBRAS, fornecendo informações sólidas para futuras pesquisas.

3 METODOLOGIA

O objetivo deste estudo consiste em realizar uma RSL para o estudo de reconhecimento gestual da língua de sinais com técnicas de IA que seguiu o protocolo de Kitchenham (2007) como já citados anteriormente, estruturado em três fases principais: Planejamento, Condução da Revisão e Relato dos Resultados.

A primeira etapa consistiu na definição da pergunta de pesquisa, para isso foram considerados o objetivo da revisão, o escopo da pesquisa e os critérios que guiaram a seleção dos estudos. A pergunta final estabelecida foi: "Como a pesquisa em língua de sinais tem se desenvolvido com o uso da inteligência artificial?". Para responder a essa questão, a busca por estudos relevantes foi realizada na base de dados Scopus, que incorpora fontes como IEEE Xplore, utilizando palavras-chave como "*sign languages, convolutional neural network, artificial Intelligence, machine learning, brazilian sign languages*", combinadas com operadores booleanos ("AND", "OR") para forma a string de busca.

O quantitativo de artigos foi filtrado no dia 2 de setembro de 2024, utilizando duas strings de busca, sem a aplicação de critérios de inclusão ou exclusão, resultando em 11.237 artigos para a primeira string e 435 artigos para a segunda, que serão abordadas mais adiante. Para refinar esses resultados, foram aplicados filtros, como a restrição ao período de publicação entre 2019 e 2024 (cinco anos), além da limitação aos idiomas português e inglês, uma vez que essas línguas são as mais amplamente utilizadas em publicações acadêmicas relacionadas à área de estudo. Outros critérios também foram aplicados e serão detalhados a seguir.

Os critérios de inclusão consideraram estudos que abordam reconhecimento de sinais de LIBRAS e língua de sinais no geral utilizando inteligência artificial, enquanto os critérios de exclusão descartaram trabalhos sem validação experimental ou que não apresentavam métricas de desempenho quantitativas.

Os artigos encontrados após a busca com os critérios passaram por um processo de triagem em três etapas:

1. Leitura de títulos e resumos para identificar pesquisas potencialmente relevantes.
2. Análise do texto completo, considerando apenas aqueles que atendiam aos critérios de inclusão.

3. Avaliação final da qualidade dos estudos, baseada nos critérios estabelecidos por Kitchenham (2007).

Para garantir a padronização na análise, utilizou-se um tabela de extração de dados, contendo informações sobre modelo de IA utilizado, base de dados empregada, métricas de avaliação e outros principais resultados. A qualidade dos estudos foi avaliada considerando critérios como: clareza na descrição da metodologia empregada, reprodutibilidade dos experimentos, robustez das métricas de validação utilizadas. Assim, os dados extraídos foram sintetizados de forma qualitativa e quantitativa, destacando tendências, lacunas na literatura e desafios enfrentados pelas abordagens estudadas.

Desse modo, durante a fase de planejamento, foi definida a pergunta de pesquisa e as diretrizes para a seleção dos estudos. Na condução da revisão, foram implementadas estratégias de busca e critérios para a triagem e avaliação da qualidade dos artigos. Finalmente, os resultados foram organizados e analisados de forma sistemática, permitindo uma visão ampla do reconhecimento gestual de línguas de sinais com o uso de inteligência artificial. A partir do protocolo, os erros são evitados, a pesquisa é bem estruturada e as informações são analisadas e mostradas com precisão.

3.1 QUESTÕES DE PESQUISA

Seguindo o protocolo estabelecido, as questões de pesquisa fazem parte da etapa de planejamento. Tendo como objetivo da RSL explorar como a IA tem sido usada no reconhecimento de gestos da língua de sinais, busca entender como essa tecnologia interpreta os sinais, quais são os aspectos principais envolvidos na classificação e os desafios que surgem nesse processo. A Tabela 1 apresenta as questões de pesquisa utilizadas nesta RSL, seguindo os princípios recomendados por Kitchenham (2007) para a estruturação de Revisões Sistemáticas da Literatura.

Essas questões são essenciais para guiar a discussão e estruturar os resultados encontrados. Com elas, entende-se quais técnicas de IA são mais utilizadas, quais são os atributos mais comuns na classificação dos sinais, o que motiva a identificação dos gestos, as limitações apontadas pelos autores, os bancos de dados mais usados e as métricas mais aplicadas para avaliar os modelos.

Tabela 1: Questões de pesquisas

Número da questão	Pergunta de Pesquisa
1	Quais são as técnicas de IA e aprendizado de máquina mais utilizadas na literatura para o reconhecimento gestual de sinais em língua de sinais?
2	Quais são os atributos mais utilizados na classificação ?
3	Quais os propósitos da identificação?
4	Quais são as principais limitações encontradas pelos os autores ?
5	Quais bancos de dados são mais utilizados para treinar modelos de IA no reconhecimento de gestos em língua de sinais?
6	Quais métricas são mais empregadas para avaliar modelos de IA?

Fonte: Elaboração própria.

3.2 CRITÉRIOS DE INCLUSÃO E EXCLUSÃO

Estabelecer os critérios de inclusão e exclusão é também uma etapa essencial, os quais esses critérios funcionam como um guia para selecionar os estudos mais relevantes, assegurando que a pesquisa se concentre em artigos que agreguem valor ao tema, ao mesmo tempo em que evitam possíveis vieses ou distorções nos resultados.

A seguir, a Tabela 2 apresenta os parâmetros utilizados para determinar quais estudos serão incluídos ou excluídos. Os critérios de inclusão levam em conta diversos fatores, como a atualidade dos artigos, restringindo-os ao período de 2019 até o presente, e para garantir que só os estudos mais relevantes entrem na pesquisa, precisamos que os artigos contenham os termos de busca no título, no resumo ou nas palavras-chave. Só foram aceitos os artigos revisados por pares com foco no uso de inteligência artificial para o reconhecimento de gestos da língua de sinais no geral e em LIBRAS, além de que precisam ser artigos em português ou inglês.

Por outro lado, para manter o filtro conciso, e descartar estudos que, apesar de parecerem relevantes, não se encaixam nos objetivos da pesquisa, aplica-se critérios de exclusão. Os quais são: ano anterior a 2019; não possuir os termos da string de busca no

resumo, título ou palavra-chave; literatura não revisada por pares; estudos secundários; artigo duplicado ou redundante de mesma autoria; fugir do tema, e artigo resumido ou incompleto.

É relevante mencionar que, antes de 2019, o reconhecimento de linguagem de sinais e a detecção de gestos eram conduzidos principalmente por redes neurais convolucionais (CNNs) em arquiteturas como VGG16 e R-CNN. Yan et al. (2017) exploraram técnicas multiescala para detecção de mãos, enquanto Kishore et al. (2018) desenvolveram modelos baseados em CNNs para reconhecimento de gestos em modo selfie, aprimorando a precisão dentro das limitações tecnológicas da época. Esses estudos estabeleceram a base para os avanços entre 2019 e 2024, período em que novas arquiteturas e técnicas aprimoraram a precisão e adaptabilidade do reconhecimento gestual.

Tabela 2: Critérios de inclusão e exclusão

Critérios de Inclusão	Critérios de Exclusão
Ano de publicação: 2019 até 2024	(1º) Ano de publicação anterior a 2019 (5 anos de intervalo)
Possuir os termos da string de busca no abstract(resumo), título ou palavras-chave	(2º) Não possuir os termos da string de busca no abstract(resumo), título ou palavras-chave
Artigos completos revisados por pares	(3º) Livros ou outras formas de literatura cinza (literatura não revisada por pares)
Tratar do uso de IA para reconhecer língua de sinais	(4º) Estudos secundários (revisões)
Artigo em Português ou Inglês	(5º) Artigo duplicado ou redundante de mesma autoria (considera-se o mais completo)
	(6º) Fugir do tema, utilizando a IA para outros focos
	(7º) Artigo resumido ou incompleto

Fonte: Elaboração própria.

3.3 STRING DE BUSCA

Com relação as strings de busca, foram usadas duas na pesquisa: "*sign languages AND (convolutional neural network OR artificial intelligence OR machine learning)*" e "*brazilian sign languages AND (convolutional neural network OR artificial intelligence OR machine learning)*". A primeira busca por artigos que falam sobre linguagens de sinais de uma maneira geral, explorando o uso de tecnologias como redes neurais convolucionais (CNNs),

inteligência artificial e aprendizado de máquina. Já a segunda foca na LIBRAS, procurando estudos sobre como essas tecnologias são aplicadas para reconhecer os gestos dessa língua.

Inicialmente, foram identificados 119 artigos relevantes ao tema do estudo, publicados nos últimos cinco anos em fontes reconhecidas e acessíveis, ou seja, a partir dos critérios de inclusão. Em seguida, ao aplicar os critérios de exclusão para garantir a relevância e a qualidade dos artigos selecionados, foram descartados aqueles que não estavam diretamente relacionados ao tema. Após essa filtragem, 93 artigos foram considerados válidos, como mostra a Tabela 3.

Tabela 3: Quantidade de artigos de acordo com os critérios

Quantidade de artigos geral com os critérios de inclusão	Quantidade de artigos geral com os critérios de inclusão e exclusão
119	93

Fonte: Elaboração própria.

A quantidade final de artigos após a aplicação dos filtros baseados nas strings de busca foi distribuída da seguinte maneira: 91 artigos foram identificados a partir da primeira string de busca, enquanto 2 artigos foram encontrados utilizando a segunda string, resultando em um total de 93 estudos. Essa distribuição evidencia uma maior concentração de pesquisas associadas à primeira string, possivelmente devido à abrangência dos termos empregados e à maior quantidade de trabalhos relacionados ao tema. A Tabela 4 apresenta essa divisão detalhadamente, permitindo uma visão mais clara da representatividade dos artigos encontrados em cada abordagem de busca.

Tabela 4: Strings de busca

Strings	Quantidade de artigos lidos
sign languages AND (convolutional neural network OR artificial Intelligence OR machine learning)	91
brazilian sign languages AND (convolutional neural network OR artificial Intelligence OR machine learning)	2

Fonte: Elaboração própria.

A string de busca "*brazilian sign languages AND (convolutional neural network OR artificial intelligence OR machine learning)*", resultou em um número menor de estudos. Diante disso, é essencial destacar as técnicas de inteligência artificial identificadas nesses trabalhos, conforme apresentado na Tabela 5.

Tabela 5: Artigos da string com menor número de estudos.

Título	Ano	Autores	Técnica utilizada
<i>Using convolutional neural networks for fingerspelling sign recognition in Brazilian sign language</i>	2019	Lima, D.F.L. ; Salvador Neto, A.S.; Santos, E.N.; Araujo, T.M.U.; Do Rêgo, T.G.	Redes Neurais Convolucionais (CNNs): <i>MobileNet</i> , <i>NASNetMobile</i> , <i>VGG16</i> e <i>InceptionResNetV2</i>
<i>Development and validation of a Brazilian sign language database for human gesture recognition</i>	2021	Tamires Martins Rezende ,Silvia Grasiella Moreira Almeida, Frederico Gadelha Guimarães	Redes Neurais Convolucionais 2D e 3D (CNN2D e CNN3D).

Fonte: Elaboração própria.

No artigo '*Using convolutional neural networks for fingerspelling sign recognition in Brazilian sign language*', os autores utilizaram modelos de aprendizado profundo baseados em Redes Neurais Convolucionais (CNNs), incluindo *MobileNet*, *NASNetMobile*, *VGG16* e *InceptionResNetV2*. Já no artigo '*Development and validation of a Brazilian sign language database for human gesture recognition*', foram aplicadas tanto CNNs 2D quanto 3D (CNN2D e CNN3D) para reconhecimento de gestos.

3.4 EXTRAÇÃO DE DADOS

Na etapa de extração de dados, foi elaborada uma planilha para sistematizar as informações dos artigos selecionados. A extração de dados foi gerenciada utilizando Microsoft Excel, devido à sua flexibilidade para organização de informações, então durante a leitura dos estudos, a planilha foi preenchida, registrando dados relevantes para a pesquisa, incluindo os pontos que serão abordados nos resultados desse estudo, como: técnicas empregadas, métricas utilizadas, limitações identificadas, bancos de dados utilizados e outros aspectos pertinentes dos estudos.

3.5 CRITÉRIOS DE QUALIDADE

No presente estudo, foi realizada uma análise da qualidade dos 93 artigos filtrados e lidos. Essa avaliação garante que os artigos sejam qualificados de acordo com critérios

escolhidos, conferidos na Tabela 6 . Para isso, foram aplicadas questões específicas, chamadas de "análise de qualidade", além dos critérios convencionais de inclusão e exclusão, foram incorporados novos parâmetros para tornar a análise ainda mais detalhada. As perguntas utilizadas para a avaliação e o sistema de pontuação adotado foram adaptados de Silva et al. (2021), que também se baseiam nas diretrizes de Kitchenham para estruturar sua análise de qualidade.

Tabela 6: Critérios de qualidade

Critério	Descrição
C1	Os objetivos ou motivações do estudo estão bem definidos?
C2	As metodologias utilizadas são descritas de maneira clara?
C3	Os dados de entrada para os modelos de IA (atributos) foram devidamente especificados?
C4	O artigo disponibilizou a base de dados utilizada?
C5	As técnicas de IA aplicadas estão devidamente descritas?
C6	As métricas para validação das técnicas foram claramente indicadas?
C7	Os resultados obtidos foram discutidos de forma abrangente?
C8	As limitações do estudo foram identificadas e explicadas?
C9	A ferramenta ou sistema proposto foi testado em um cenário prático?


Fonte: Adaptado de SILVA et al. (2021) e KITCHENHAM et al. (2007).

A avaliação foi realizada por meio de uma escala ordinal, seguindo a abordagem utilizada por Silva et al. (2021). Cada critério recebeu uma pontuação de 0, 0,5 ou 1, dependendo do grau de atendimento aos requisitos estabelecidos, assim a pontuação foi atribuída de forma simples: 1 para os critérios que foram totalmente atendidos, 0,5 para os parcialmente cumpridos e 0 para os que não foram atendidos. A pontuação final de cada artigo foi calculada pela média aritmética das notas atribuídas aos nove critérios. Para que um artigo seja considerado "aprovado" nessa análise, precisa alcançar a média mínima de 7 pontos, caso não alcance essa pontuação, o artigo é classificado como "reprovado".

4 RESULTADOS E DISCUSSÕES

A pesquisa efetuada na base de dados Scopus gerou dois gráficos que ajudam a visualizar os 116 estudos filtrados inicialmente a partir da string de busca "sign languages AND (convolutional neural network OR artificial intelligence OR machine learning)". Essa foi a combinação que trouxe mais trabalhos alinhados com os critérios de inclusão definidos na metodologia.

Gráfico 1: Documentos por área.




Fonte: SCOPUS (2024)

No primeiro gráfico, mostra a distribuição dos artigos por área temática, a Ciência da Computação domina o cenário, representando 33,7% das publicações. Em seguida, a Engenharia, com 23,5%, e depois áreas como Matemática e Física e Astronomia, ambas com 6,3%. Outras áreas, como Materiais (4,9%), Bioquímica, Genética e Biologia Molecular (3,9%), Medicina (3,5%) e Química (3,2%). Já Neurociência e Engenharia Química têm uma participação menor, com 2,1% e 1,8%, respectivamente. As demais áreas, que foram agrupadas na categoria "Outros", correspondem a 10,9% dos documentos. Essa análise mostra como as pesquisas são bem variadas, mas com um foco especial em ciência, tecnologia e engenharia.

Sobre o gráfico 2, nota-se que o número de artigos publicados por ano cresceu nos últimos anos (2019 -2024). Entre 2020 e 2022, teve um leve crescimento, mas a partir de 2023 o número de estudos deu um salto, mostrando que a pesquisa na área ganha força, dando continuidade no crescimento em 2024.

Gráfico 2: Artigos por ano.



Fonte: SCOPUS (2024)

4.1 TÉCNICAS DE IA

As técnicas de IA têm sido aplicadas para o desenvolver sistemas de tradução, reconhecimento e interpretação. A figura 2, mostra as técnicas mais utilizadas nos 93 artigos lidos, com suas respectivas porcentagens de aplicação. Entre as técnicas, as CNNs se destacam com uma aplicação de 35%, são especialmente eficazes em tarefas de processamento de imagens, o que as torna ideais para o reconhecimento de sinais em língua de sinais a partir de vídeos ou imagens, e podem identificar padrões e características visuais essenciais, permitindo a tradução dos sinais em textos ou palavras.

As LSTM (Long Short-Term Memory) ocupam a segunda posição, com 22% de uso nos estudos. O artigo de Lin et al. (2023) demonstra a aplicação dessa técnica para o

reconhecimento de atividades humanas utilizando sinais Wi-Fi em smartphones, evidenciando sua eficiência no tratamento de dados temporais. Sua principal vantagem é a capacidade de preservar informações a longo prazo ao longo de sequências temporais, o que é essencial para o reconhecimento contínuo de sinais em contextos de linguagem gestual, onde a sequência e a temporalidade dos sinais são determinantes para a precisão da tradução.

As Máquinas de Vetores de Suporte (SVM), com 15%, são técnicas de aprendizado supervisionado amplamente usadas para classificações, como a identificação de sinais específicos em língua de sinais. As SVMs funcionam separando dados em diferentes categorias com uma margem ótima, permitindo que o sistema identifique e classifique sinais de forma eficiente, mesmo em situações com poucos exemplos de treinamento. O estudo de Güney e Erkuş (2021), por exemplo, utiliza essa técnica no reconhecimento em tempo real da linguagem de sinais turca.

Com 10% de aplicação, o Random Forest é outra abordagem relevante. Trata-se de um método de aprendizado supervisionado que combina várias árvores de decisão para realizar classificações mais robustas e precisas. No contexto de língua de sinais, esse método pode ser utilizado para distinguir entre diferentes sinais, utilizando um conjunto diversificado de características extraídas de dados visuais ou de movimento. Conforme proposto por Breiman (2001), essa abordagem melhora a precisão da classificação ao reduzir a variabilidade das árvores individuais, tornando-o uma ferramenta eficaz para o reconhecimento de padrões complexos, como os sinais.


As Redes Neurais Recorrentes (RNNs), com 8%, são técnicas de IA que lidam bem com dados temporais ou sequenciais. Embora as LSTM sejam uma forma avançada das RNNs, as RNNs tradicionais ainda têm seu papel no reconhecimento de padrões temporais, como os movimentos em sinais, onde o tempo e a sequência de sinais desempenham papel fundamental. O estudo de G e K (2022) utiliza RNNs integradas com CNN para realizar classificações mais precisas em aplicações em tempo real.

Os Transformers, que são uma tecnologia emergente em IA, representam 5% dos estudos analisados. Sua principal vantagem é a capacidade de lidar com grandes volumes de dados de forma paralela, o que é útil para analisar rapidamente grandes conjuntos de sinais. A arquitetura Transformer, introduzida por Vaswani et al. (2017), se destaca pela sua eficiência

no processamento de dados, sendo amplamente aplicada em tarefas sequenciais, como tradução automática e reconhecimento de padrões temporais, incluindo sinais.

Além dessas técnicas mais comuns, 5% dos artigos mencionam outras técnicas, que podem incluir algoritmos como o K-means, utilizado para clustering, ou métodos de aprendizado por reforço, que ajudam no aprimoramento contínuo de sistemas de tradução de língua de sinais com base no feedback recebido.

Figura 2: Técnicas de IA



Fonte: Elaboração própria.

4.2 ATRIBUTOS UTILIZADOS

Os atributos, ou seja, as entradas de dados utilizadas no treinamento dos modelos de IA, citados nos artigos analisados na RSL, apresentam grande diversidade. Essa variedade reflete a riqueza das abordagens e metodologias empregadas no desenvolvimento e aprimoramento dos modelos. A Figura 3 mostra as palavras-chave das entradas de dados que tiveram maior abrangência nos 93 artigos, observa-se que as entradas mais utilizadas incluem imagens estáticas de gestos manuais representando 30,2%, bem como características espaciais, temporais e dinâmicas dos gestos. Entre os atributos visuais, destaca-se o uso de


dados RGB (vermelho, verde e azul) ou segmentação em escala de cinza, que representam 16,8% dos estudos. Esses dados, frequentemente convertidos para escala de cinza, são processados para segmentação e extração de características específicas, como a posição e o movimento das mãos. O formato RGBA, que inclui um valor adicional de transparência (alpha), é uma variação utilizada para manipular cores e opacidade em imagens digitais.

Além disso, os vídeos de gestos dinâmicos são mencionados em 12,6% dos artigos, enquanto os dados de sensores, como sistemas de captura de movimento, aparecem em 9,5%. Esses sensores fornecem dados adicionais sobre a cinemática dos gestos, como flexão dos dedos, ângulos de rotação e pressão exercida durante o movimento.

Já os dados de expressões faciais, presentes em 8,7% dos estudos, envolvem a captura de pontos de articulação corporal e facial, que são frequentemente extraídos por ferramentas de estimativa de pose, como o Mediapipe. O Mediapipe é uma biblioteca de código aberto desenvolvida pelo Google, que facilita a detecção e o rastreamento de posições corporais e faciais, permitindo a interpretação automatizada de gestos. Quando combinado com aprendizado de máquina, o Mediapipe viabiliza sistemas interativos, como tradutores automáticos de sinais. Esses dados permitem um mapeamento mais detalhado dos gestos em contexto, incorporando expressões faciais e movimentos corporais que complementam a análise das mãos.

Ademais, outro grupo relevante são os sinais temporais, que aparecem em 7,9% dos artigos. Isso demonstra um interesse crescente em compreender a língua de sinais para além das mãos, incorporando elementos como expressões faciais e características cinemáticas, como velocidade e aceleração, para capturar a dinâmica dos movimentos. A categoria "Outros", com 14,3%, sugere que há uma variedade de abordagens menos convencionais ou combinações de diferentes técnicas.

A análise e a figura evidenciam que, embora a maioria dos estudos ainda se baseie em imagens estáticas, há um esforço contínuo para tornar o reconhecimento da língua de sinais mais sofisticado, integrando novas fontes de informação e superando os desafios de interpretação dos sinais.

Figura 3: Atributos utilizados

Fonte: Elaboração própria.

4.3 MÉTRICAS


Acerca de uma das perguntas de pesquisa, as métricas de avaliação, é de natureza avaliativa sobre o desempenho de modelos de aprendizado de máquina, particularmente em pesquisas que usam inteligência artificial para resolver problemas complexos. Nos artigos lidos, foi feito o levantamento dos dados em relação à eficácia e à precisão das técnicas de IA utilizadas, então as métricas no geral mais utilizadas são acurácia, precisão, recall, F1-score e especificidade. De acordo com Vilela Júnior et al. (2022), a acurácia mede a proporção de previsões corretas feitas pelo modelo. A precisão avalia a quantidade de previsões positivas corretas em relação ao total de previsões positivas feitas. O recall, por sua vez, indica a capacidade do modelo de identificar todas as instâncias positivas corretamente. O F1-score é a média harmônica entre precisão e recall, sendo útil quando há desequilíbrio entre as classes. Já a especificidade indica a proporção de negativos que foram corretamente identificados pelo modelo, em outras palavras, ela mostra a capacidade do modelo de evitar falsos positivos.

Além disso, o Erro Médio Quadrático (MSE - *Mean Squared Error*), juntamente com outras métricas mais comuns, representa 7% das métricas utilizadas. O MSE é amplamente utilizado para avaliar a acurácia de modelos, sendo especialmente útil por atribuir maior peso aos maiores erros. Ao calcular o MSE, os erros são elevados ao quadrado individualmente, e a

média desses valores quadráticos é então computada (JAMES et al., 2013). Entre as métricas mais raramente abordadas estão a especificidade e a área sob a curva ROC (AUC-ROC). De acordo com Fawcett (2006), a AUC quantifica a habilidade do modelo em distinguir entre classes, calculando a área sob a curva ROC. Esse valor reflete a probabilidade de que duas previsões sejam classificadas corretamente, considerando diferentes pontos de decisão.

Uma observação interessante de expor é que os modelos muitas vezes utilizam mais de uma métrica para avaliá-los. Com base nisso, ao verificarmos em conjunto essas métricas, podemos obter uma avaliação mais precisa do desempenho do modelo, percebe-se que a combinação de acurácia, precisão, recall e F1-score proporciona uma visão ampla e minuciosa do desempenho do modelo. Então, além de mostrar a taxa de acertos, permite avaliar se o modelo aplicado no estudo está realmente diferenciando os casos positivos e negativos, garantindo que os resultados a partir dessa etapa se tornem mais confiáveis.

Figura 4: Métricas



Fonte: Elaboração própria.

4.4 DESAFIOS E LIMITAÇÕES

Os resultados dos desafios e limitações encontrados nos estudos ajudam a entender as barreiras e lacunas que ainda precisam ser abordadas, testadas e resolvidas no campo da IA com reconhecimento gestual da língua de sinais. A partir da leitura dos artigos, foi possível

identificar os principais problemas mencionados em relação ao uso da IA para essa aplicação. A Figura 5 apresenta as palavras-chave dos desafios mais frequentemente citados nos estudos, sendo que, em sua maioria, essas dificuldades estão associadas à sensibilidade das condições ambientais, especialmente a iluminação. A palavra-chave “iluminação” refere-se a um fator crucial, pois as variações na intensidade da luz em relação às sombras ou mudanças na cor da pele dos usuários podem impactar significativamente a precisão dos modelos de reconhecimento, prejudicando a detecção dos gestos. Esse problema é relevante em ambientes externos ou mal controlados, onde a iluminação pode ser imprevisível. Essa dependência de cenários com condições ideais de luz ainda representa uma barreira importante para a aplicação prática da IA em contextos do mundo real, onde as condições de iluminação são frequentemente variáveis e difíceis de controlar.

A palavra-chave “dados” refere-se à escassez de informações variadas e bem estruturadas. Sem uma base ampla e representativa, os modelos de reconhecimento de gestos enfrentam dificuldades para se adaptar a diferentes cenários e identificar movimentos que não foram previamente registrados. Essa limitação se torna ainda mais evidente no reconhecimento de “gestos dinâmicos”, outra palavra-chave presente na nuvem de palavras. Enquanto muitos modelos apresentam um bom desempenho na interpretação de gestos estáticos, a identificação de movimentos contínuos e mais complexos representa um desafio maior, exigindo arquiteturas avançadas, como CNNs e RNNs, o que torna o treinamento significativamente mais complexo.

Além disso, a palavra-chave “computação” está relacionada ao alto custo computacional, um fator crítico no desenvolvimento desses modelos. As redes neurais profundas, utilizadas nos sistemas mais avançados, demandam grande capacidade de processamento e alto consumo de energia, o que pode dificultar sua aplicação em dispositivos embarcados ou sistemas em tempo real. Muitos artigos ressaltam que um único modelo pode enfrentar múltiplos desafios, tornando necessária a busca por soluções eficientes para otimizar o desempenho sem comprometer a precisão.

Outro obstáculo relevante, representado pela palavra-chave “semelhança”, está na dificuldade de diferenciar gestos com formatos visuais parecidos, como algumas letras ou números. Esse problema exige métodos mais robustos para evitar erros de classificação e garantir um reconhecimento mais preciso.

Por fim, a palavra-chave “variações” refere-se às diferenças na execução dos gestos entre usuários, como alterações na velocidade e no estilo do movimento. Além disso, as condições de gravação, incluindo ângulo da câmera e iluminação, podem variar, impactando diretamente a precisão do reconhecimento. Pequenas discrepâncias nestes fatores podem comprometer os resultados esperados, tornando essencial o desenvolvimento de modelos mais adaptáveis e resilientes a essas mudanças.

Figura 5: Desafios e limitações



Fonte: Elaboração própria.


4.5 BASES DE DADOS

A escolha dos bancos de dados adequados são primordiais para o desenvolvimento de sistemas e pesquisas de reconhecimento de língua de sinais. Ao averiguar as fontes de dados utilizadas nos estudos filtrados, é possível notar uma diferença importante entre as bases, mostrada na Figura 6. Entre as bases identificadas, 41,67% possuem links públicos, o que facilita o acesso e a replicação dos experimentos, além de permitir que esses dados sejam usados abertamente para treinar modelos de aprendizado de máquina. Alguns exemplos são o *Sign Language MNIST*, *ArSL2018* e *ASL Fingerspelling Images (RGB & Depth)*, entre outros.

Enquanto, 58,33% das fontes se encaixam em grupos como "Mencionados sem links", "Ausência de dados" e "Bases específicas para estudo". Essas bases não têm links públicos para acesso ou pedem autorização para uso, o que acaba dificultando o trabalho de pesquisadores e cientistas. As bases específicas, por exemplo, muitas vezes são criadas para

atender a necessidades de estudos ou grupos que focam em detalhes como dialetos ou variações da linguagem de sinais.

Figura 6: Bases de dados



Fonte: Elaboração própria.


4.6 ANÁLISE DE QUALIDADE

A fim de garantir que os estudos selecionados fossem realmente relevantes, precisos e alinhados aos objetivos da pesquisa, foi conduzida uma análise detalhada, cujos resultados estão ilustrados abaixo na Figura 7. Para essa avaliação, foram definidos critérios específicos citados na metodologia, e cada artigo foi pontuado com 0, 0,5 ou 1, dependendo do nível de conformidade com os requisitos estabelecidos. Entre os 93 artigos analisados, 75% atingiram a pontuação mínima de 7 e foram classificados como "aprovados", os quais se destacaram por apresentarem objetivos bem delineados, metodologias claras, dados bem descritos refletindo um alto padrão de rigor científico.

Em contrapartida, 25% dos artigos não alcançaram a pontuação mínima e foram classificados como "reprovados". Esses estudos apresentaram falhas significativas, como a falta de detalhes sobre as técnicas de IA utilizadas, a ausência de informações sobre as bases de dados empregadas e uma análise superficial das limitações. Tais deficiências afetaram a qualidade e a relevância das publicações, prejudicando sua contribuição para o campo de

estudo deste trabalho e, especificamente, para o reconhecimento de gestos na língua de sinais. Esse processo de revisão reforça a importância de aplicar critérios rigorosos na seleção dos estudos, garantindo a confiabilidade dos resultados da pesquisa.

Figura 7: Análise de qualidade



Fonte: Elaboração própria.

5 CONSIDERAÇÕES FINAIS

Este estudo explorou o reconhecimento gestual da língua de sinais com o uso de inteligência artificial. Por meio de uma revisão sistemática da literatura, foram identificadas as abordagens mais utilizadas, os atributos mais relevantes para a classificação dos gestos, os desafios enfrentados pelos pesquisadores, além dos principais repositórios e métricas empregados nessa área. A análise dos artigos revelou a aplicação de técnicas como redes neurais convolucionais (CNNs) e processamento digital de imagens (PDI) no desenvolvimento de soluções voltadas à tradução automática da LIBRAS e de outras línguas de sinais, sendo foi possível observar a evolução dos métodos, que se tornaram cada vez mais sofisticados, superando limitações anteriores e oferecendo maior precisão nos sistemas de reconhecimento.

Entretanto, os desafios permanecem, destacando-se a necessidade de maior acessibilidade tecnológica, a padronização das variações regionais da língua e a dificuldade na distinção entre gestos semelhantes, que podem comprometer a precisão dos modelos de reconhecimento. Além disso, a revisão demonstrou que há poucos estudos específicos voltados à LIBRAS, enquanto pesquisas sobre a língua de sinais de forma geral são mais abundantes. Isso indica que o campo científico ainda possui um vasto espaço a ser explorado para o desenvolvimento de soluções direcionadas à LIBRAS.

A revisão também ressaltou a importância de bases de dados abrangentes e diversificadas, fundamentais para o treinamento e validação eficaz dos modelos, assim como a adoção de métricas adequadas para avaliação, garantindo a confiabilidade dos sistemas desenvolvidos. Para assegurar a qualidade da análise, os estudos foram examinados com base em critérios rigorosos, como a clareza dos objetivos e metodologias, a organização e disponibilização dos dados utilizados e a profundidade da discussão dos resultados.

Os resultados desta pesquisa demonstram que, apesar dos avanços alcançados, ainda há desafios técnicos e sociais a serem superados para que os sistemas de reconhecimento gestual sejam mais precisos, acessíveis e alinhados às necessidades da comunidade surda. Espera-se que este estudo contribua para a ampliação do conhecimento sobre a aplicação da IA no reconhecimento gestual da língua de sinais, fomentando discussões na área e

incentivando novas pesquisas que impulsionam o desenvolvimento de tecnologias mais inclusivas e eficientes.

5.1 TRABALHOS FUTUROS

Diante desse contexto, a continuidade das pesquisas tem o potencial de fortalecer a inclusão e ampliar as possibilidades de comunicação, reafirmando o papel da tecnologia como um instrumento transformador na construção de uma sociedade mais acessível e equitativa. Como uma das principais perspectivas para o futuro, destaca-se a implementação de inteligência artificial (IA) para o reconhecimento gestual em tempo real, o que pode proporcionar maior precisão e acessibilidade nos sistemas desenvolvidos, tornando-os ainda mais eficazes e abrangentes.

REFERÊNCIAS

ALURA. Métricas de avaliação para séries temporais, 2021. Disponível em:

<https://www.alura.com.br/artigos/metricas-de-avaliacao-para-series-temporais?srsltid=AfmBOop73ZkS5iGPem25VF-oEHkA6khT8nC48muYoU7pJw6rNNSjphMH>. Acesso em: 01 nov. 2024.

BIDARRA, J.; TUXI, P. T. S.; MARTINS, T. A.; CORBARI, Alcione Tereza; SERPA, Talita. Diretrizes para a construção de corpora paralelos LIBRAS-Português: uma proposta. 2022. Dissertação (Mestrado em Letras-Funcionamento Mecanismos Linguísticos) – Universidade Estadual do Oeste do Paraná, Cascavel.

BREIMAN, Leo. Random forests. *Machine Learning*, v. 45, n. 1, p. 5-32, 2001. Disponível em: <https://doi.org/10.1023/A:1010933404324>.

CARDIM, Guilherme Pina; SABAUDA, Gabriel Ângelo Perez Gasparini. Detecção de imagem para reconhecimento de sinais de LIBRAS. Londrina, 2022.

COMUNELLO, Eros; PARREIRA, W. D.; CUNHA, F. S.; LOPES, M. D. Reconhecimento de gestos do alfabeto da Língua Brasileira de Sinais utilizando técnicas de visão computacional. 2019. Trabalho de Conclusão de Curso (Graduação em Ciência da Computação) – Universidade do Vale do Itajaí, Itajaí.

DONATO, H.; DONATO, M. Etapas para a realização de uma revisão sistemática. *Acta Médica Portuguesa*, v. 32, n. 3, p. 227–235, 2019. Disponível em: <https://www.actamedicaportuguesa.com/revista/index.php/amp/article/view/11923>.

ECHER, Isabel Cristina. A revisão de literatura na construção do trabalho científico. *Revista Brasileira de Enfermagem*, v. 54, n. 1, p. 76–82, 2001.

FAWCETT, T. An introduction to ROC analysis. *Pattern Recognition Letters*, v. 27, n. 8, p. 861-874, 2006. DOI: <https://doi.org/10.1016/j.patrec.2005.10.010>

G, Arun Prasath; K, Annapurani Panaiyappan. Design of an integrated learning approach to assist real-time deaf application using voice recognition system. *Computers and Electrical*

Engineering, v. 102, p. 108145, set. 2022. Disponível em:

<https://doi.org/10.1016/j.compeleceng.2022.108145>.

GALVÃO, Taís Freire; PEREIRA, Mauricio Gomes. Revisões sistemáticas da literatura: passos para sua elaboração. *Epidemiologia e Serviços de Saúde*, v. 23, n. 1, p. 183–184, 2014.

GESSER, Audrei. LIBRAS? Que língua é essa?: crenças e preconceitos em torno da língua de sinais e da realidade surda. São Paulo: Parábola Editorial, 2009.

GOOGLE CLOUD. O que é inteligência artificial (IA)?. Disponível em:

<https://cloud.google.com/learn/what-is-artificial-intelligence?hl=pt-BR>.

GÜNEY, Selda; ERKUŞ, Mehmet. A real-time approach to recognition of Turkish sign language by using convolutional neural networks. *Received: 4 August 2021 / Accepted: 27 October 2021 / Published online: 11 November 2021*. Springer-Verlag London Ltd., 2021. Disponível em: <https://link.springer.com/article/10.1007/s00542-021-06665-w>.

IEEE. Are the articles in the IEEE Xplore digital library indexed in Scopus? 2024.

Disponível em:

[https://ieeemsd.my.site.com/onlineSupport/s/article/Are-the-articles-in-the-IEEE-Xplore-digital-library-indexed-in-SCOPUS#:~:text=Scopus%20is%20an%20online%20abstract,abstract\)%20can%20be%20made%20visible](https://ieeemsd.my.site.com/onlineSupport/s/article/Are-the-articles-in-the-IEEE-Xplore-digital-library-indexed-in-SCOPUS#:~:text=Scopus%20is%20an%20online%20abstract,abstract)%20can%20be%20made%20visible). Acesso em: 07 mar. 2025.

INE EAD – INSTITUTO NACIONAL DE ENSINO. Introdução à Língua de Sinais. Coordenadora pedagógica, 2007.

JAMES, Gareth et al. *An introduction to statistical learning: with applications in R*. Springer, 2013.

KISHORE, P. V. V. et al. Selfie sign language recognition with convolutional neural networks. *International Journal of Intelligent Systems and Applications*, v. 10, n. 10, p. 63-71, 2018. Disponível em: <https://doi.org/10.5815/ijisa.2018.10.07>.

KITCHENHAM, B. Guidelines for performing Systematic Literature Reviews in Software Engineering. Technical Report EBSE-2007-01, Department of Computer Science Keele University, Keele, 2007.

KITCHENHAM, Barbara; CHARTERS, Stuart M. Guidelines for performing systematic literature reviews in software engineering. Keele University; Lincoln University, 2007.

LIN, Guiping; JIANG, Weiwei; XU, Sicong; ZHOU, Xiaobo; GUO, Xing; ZHU, Yujun; HE, Xin. Human Activity Recognition Using Smartphones With WiFi Signals. *IEEE Transactions on Human-Machine Systems*, v. 53, n. 1, p. 115-124, fev. 2023.

MARCATO, S. A.; ROCHA, H. V.; LIMA, M. C. M. P. Um ambiente para a aprendizagem da Língua de Sinais. In: *SIMPÓSIO BRASILEIRO DE COMPUTAÇÃO*, 2000. Sociedade Brasileira de Computação (SBC), 2000.

MARIANO, Diego. Métricas de avaliação em machine learning. *Diegomariano.com*, 2023. Disponível em: <https://diegomariano.com/metricas-de-avaliacao-em-machine-learning/>. Acesso em: 27 nov. 2024.

MELO, Ana Paula Tavares de. Sistema de reconhecimento de gestos para aplicação em reconhecimento de língua de sinais. 2018. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Elétrica) – Universidade Federal de Campina Grande, Centro de Engenharia Elétrica e Informática, Campina Grande. Disponível em: <http://dspace.sti.ufcg.edu.br:8080/jspui/handle/riufcg/18833>.

MEMORIAL SLOAN KETTERING CANCER CENTER. How is Scopus different than PubMed? 2015. Disponível em: <https://library.mskcc.org/blog/2015/12/how-is-scopus-different-than-pubmed/>. Acesso em: 07 mar. 2025.

NETO, Z. P. de S.; SOUSA, R. R. de. Uma revisão sistemática sobre o desenvolvimento de ferramentas de apoio à Língua de Sinais / A Systematic Review of the Development of Sign Language Support Tools. *Brazilian Journal of Development*, Curitiba, v. 6, n. 7, p. 51872–51891, 2020. DOI: <https://doi.org/10.34117/bjdv6n7-727>.

PASSOS, Bianka. Reconhecimento de gestos do alfabeto da Língua Brasileira de Sinais utilizando técnicas de visão computacional. 2019.

REZENDE, Tamires Martins. Reconhecimento automático de sinais da LIBRAS [recurso eletrônico]: desenvolvimento da base de dados MINDS-LIBRAS e modelos de redes convolucionais. 2021.

RODRIGUES, Cristiane Seimetz; VALENTE, Flávia. Aspectos linguísticos da LIBRAS. Curitiba: IESDE Brasil SA, 2012.

ROCHA, A. C.; STUMPF, M. R. Sistema de representação interna e externa das línguas de sinais. Artigo submetido ao 2º Congresso Iberoamericano de Comunicación Alternativa y Aumentativa, Viña del Mar, Chile, 1996.

SABAUDO, Gabriel Ângelo Perez Gasparini; CARDIM, Guilherme Pina. Detecção de imagem para reconhecimento de sinais de LIBRAS. Londrina, 2022.

SCOPUS. Scopus abstract and citation database. Elsevier, 2024. Disponível em: <https://www-scopus-com.ez13.periodicos.capes.gov.br/search/form.uri?display=basic#basic>.

SILVA, Édison Renato Pereira da. Métodos para Revisão e Mapeamento Sistemático da Literatura. 2009. Tese (Engenharia de Produção) — Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2009. DOI: <10.13140/RG.2.1.2582.8723>.

SILVA, A. V. da; SÁ, G. C. B. e; NASCIMENTO, S. M.; LIMA, N. C. de A. The use of artificial intelligence to forecast events related to COVID-19 in Brazil: A Systematic Literature Review / O uso da inteligência artificial na predição de eventos relacionados à COVID-19 no Brasil: Uma Revisão Sistemática da Literatura. *Brazilian Journal of Development*, v. 7, n. 12, p. 120974–120995, 2021. DOI: <https://doi.org/10.34117/bjdv7n12-729>.

SOUZA, H. S.; BOTELHO, R.; GONÇALVES, E. S. Uso de inteligência artificial para detecção de evasão escolar em instituições de ensino: um estudo de caso em uma instituição de ensino superior. 2019. Trabalho de Conclusão de Curso (Graduação em Ciência da Computação) – Instituto Ensinar Brasil, Brasília.

SOUZA, R. F.; SOARES, A. C. Análise das técnicas de reconhecimento de sinais na Língua Brasileira de Sinais (LIBRAS). *Revista Brasileira de Linguística Aplicada*, v. 18, n. 2, p. 345–361, 2018.

CASTRO, Tamara. Línguas de sinais e educação inclusiva. *Saber e Práticas*, 23 set. 2019.

Disponível em:

<https://saberesepraticas.cenpec.org.br/noticias/linguas-de-sinais-e-educacao-inclusiva>.

YAN, Shiyang et al. Multiscale convolutional neural networks for hand detection. *Applied Computational Intelligence and Soft Computing*, v. 2017, n. 9830641, 22 maio 2017.

Disponível em: <https://doi.org/10.1155/2017/9830641>.

VASWANI, Ashish et al. Attention is all you need. In: *Proceedings of the 31st International Conference on Neural Information Processing Systems*, 2017. Disponível em:

<https://arxiv.org/abs/1706.03762>.

VILELA JÚNIOR, G. B. et al. Métricas utilizadas para avaliar a eficiência de classificadores em algoritmos inteligentes. *Revista de Sistemas e Computação*, v. 14, n. 2, p. 123-130, 2022. Disponível em:

https://www.researchgate.net/publication/359541310_METRICAS_UTILIZADAS_PARA_A_VALIAR_A_EFICIENCIA_DE_CLASSIFICADORES_EM_ALGORITMOS_INTELIGENTES.