

APLICAÇÃO DE TÉCNICAS DE MACHINE LEARNING E DEEP LEARNING EM TECNOLOGIAS ASSISTIVAS EM USO DE LINGUAGEM DE SINAIS: UMA REVISÃO (2019–2025)

Autores

Renato Wessner dos Santos¹

Fabício José Piacente²

Resumo

As tecnologias assistivas são essenciais para ajudar as pessoas com qualquer grau de deficiência. Este artigo tem como objetivo identificar e analisar, os principais pesquisadores, instituições e artigos que têm desenvolvido pesquisas sobre aplicação de técnicas de *machine learning* e *Deep learning* em tecnologias assistivas em uso de linguagem de sinais. Nas bases de dados do ACM Digital Library, arXiv, IEEE, ScienceDirect, SCOPUS, Springer Link e Web of Science, foram pesquisados os artigos, com um retorno 331 artigos, após a aplicação dos critérios de seleção, o acesso aberto das publicações e o período de 2019 a 2025, retornou-se 34 estudos selecionados. As publicações extraídas foram analisadas utilizando os softwares VOSviewer, Microsoft Excel® e Zotero 7.0.24 (64-bit). O primeiro foi utilizado para criação de redes de cooperação entre países e de redes de palavras chave; o segundo, para a criação de gráficos de séries temporais e tabelas; e o terceiro, para filtrar e padronizar as publicações. Observou-se crescimento das publicações a partir do ano de 2022, destacando-se modelos de redes neurais convolucionais (CNNs), LSTMs e baseados em atenção. Os padrões temáticos identificados estão relacionados a detecção de gestos em tempo real, tradução bidirecional sinal-texto, uso de sensores vestíveis. A análise revelou concentração geográfica das publicações em países como Índia e Arábia Saudita, além da predominância do periódico IEEE Access. As tendências encontradas na pesquisa estão relacionadas a redes neurais de grafos, fusão de características e decodificação neural por EEG. Espera-se que este estudo sirva como orientação inicial para pesquisadores, leitores e profissionais de programação interessados em aplicar os métodos abordados para criação de um sistema de reconhecimento de sinais.

Palavras-chave: Linguagem de sinais. *Deep learning*. Tecnologias assistivas. Reconhecimento de gestos. Aprendizado de máquina.

APPLICATION OF MACHINE LEARNING TECHNIQUES AND DEEP LEARNING IN ASSISTIVE TECHNOLOGIES USING SIGN LANGUAGE: A REVIEW (2019–2025)

Abstract

Assistive technologies are essential for helping people with any degree of disability. This article aims to identify and analyze the leading researchers, institutions, and articles that have developed research on the application of machine learning and Deep learning techniques in assistive technologies for sign language use. The ACM Digital Library, arXiv, IEEE, ScienceDirect, SCOPUS, Springer Link, and Web of Science databases were searched for articles, returning 331 articles. After applying the selection criteria, open access to publications, and the period 2019–2025, 34 selected studies were returned. The extracted publications were analyzed using VOSviewer, Microsoft Excel®, and Zotero 7.0.24 (64-bit) software. The first was used to create cooperation networks between countries and keyword networks; the second, to create time series graphs and tables; and the third, to filter and standardize the

¹ ORCID 0000-0002-1009-8238

² ORCID 0000-0001-8306-4541

publications. A growth in publications was observed from 2022 onward, with emphasis on convolutional neural network (CNN), LSTM, and attention-based models. The thematic patterns identified are related to real-time gesture detection, bidirectional text-to-text translation, and the use of wearable sensors. The analysis revealed a geographic concentration of publications in countries such as India and Saudi Arabia, in addition to the predominance of the IEEE Access journal. The trends identified in the research relate to graph neural networks, feature fusion, and neural decoding using EEG. This study is expected to serve as initial guidance for researchers, readers, and programming professionals interested in applying the methods discussed to create a signal recognition system.

Keywords: Sign language. Deep learning. Assistive technologies. Gesture recognition. Machine learning.

INTRODUÇÃO

A linguagem de sinais é um sistema de comunicação que utiliza gestos, expressões faciais e os movimentos do corpo para comunicar ideias e sentimentos, no Brasil (2002) a Lei nº 10.436/02 reconhece a Linguagem Brasileira de Sinais (LIBRAS) como meio legal de comunicação e expressão, determinando sua adoção como parte integrante do currículo dos cursos de formação de professores e fonoaudiólogos, bem como que os meios de comunicação oficiais sejam adaptados às necessidades dos portadores de surdez.

Segundo Ameer et al. (2024), a população mundial com deficiência auditiva hoje é de mais de 5%, o que equivale a aproximadamente 360 milhões de pessoas, já o Instituto Brasileiro de Geografia e Estatística (IBGE) (2019a) por meio de sua plataforma sidra divulgou em seu último estudo em 2019 que a quantidade total de pessoas com deficiência auditiva no Brasil é de 2.330.442 milhões de pessoas, sendo que a Região Sudeste representa a maior concentração com 40.82%, seguida das Regiões Nordeste com 29.08%, Sul com 16.02%, Norte com e Centro-Oeste com 6.33%.

O uso de tecnologias assistivas, começa a ter uso em grande volume, uma vez que a base de linguagem de programação atual bem como o treinamento de máquinas permite grandes avanços permitindo a melhora na comunicação entre oralizados e não oralizados, Rodríguez-Correa, Valencia-Arias, Patiño-Toro, Díaz e La Puente (2023) identificaram em seus estudos cinco categorias com maior incidência de estudos para tecnologias assistivas: a) reconhecimento de gestos, que é utilizada para a tradução da língua de sinais em fala e texto, podendo também ser utilizada no caminho contrário, ideias suportadas pelo estudo de (Moraes; Almeida; Rego, 2025) que desenvolveu e avaliou uma abordagem de baixo custo de aprendizado de máquina usada para extrair as coordenadas espaciais 3D das mãos no reconhecimento de 44 gestos em LIBRAS, já (Benevides et al., 2024) que demonstraram uma

tecnologia assistiva baseada em inteligência artificial para o reconhecimento em tempo real de 13 mil imagens de gestos em LIBRAS chamada de *SignTalk*, por outro lado (Saw et al., 2024) trabalharam o processamento e tradução de gestos em tempo real com o aprendizado de máquina, por meio da utilização de Redes Neurais Convolucionais (CNNs) e Redes Neurais Recorrentes (RNNs), o trabalho de (De Avellar Sarmento; Antonelli Ponti, 2023) por outro lado trabalhou a questão de gestos por meio de duas abordagens, a primeira utilizando CNNs pré-treinadas e a segunda utilizando *landmarks*, ambas abordagens submetidas a um *Long Short-Term Memory* (LSTM) para classificação dos gestos em tempo real, já o estudo de (Rezende; Almeida; Guimarães, 2021) apresenta um desenvolvimento e validação de um *dataset* público de gestos em língua de sinais, utilizando CNNs 3D, b) geração automática de legendas automatizadas, nessa linha tem-se o trabalho realizado por (Martino; Christinele, 2024) que aborda a tradução automática de texto em português utilizado por oralizados em representação escrita (glosas) de LIBRAS, c) ensino de língua de sinais e d) conteúdo online, nesses campos temos o trabalho de (Silveira et al., 2022), que atua na geração e sintetização de imagens, ele pega a aparência de uma Pessoa A, e a o gesto de uma Pessoa B, então junta os dois dados, ou seja a Pessoa A realizando o gesto da Pessoa B, e) redes baseadas em texto e iluminação.

González Rodríguez et al. (2024) e Mahmud et al. (2023) demonstram que as pessoas com deficiência auditiva enfrentam desafios no acesso a serviços como os educacionais, de saúde e no mercado de trabalho, pois a barreira linguística existente dificulta as interações. O IBGE (2019b) por meio de sua plataforma sidra corrobora a informação, pois em sua Pesquisa Nacional de Saúde (PNS) demonstra que 70,96% dos deficientes auditivos não possuem instrução ou tem o fundamental incompleto, 8,63% possuem fundamental completo e médio incompleto, 14,50% possuem ensino médio completo e superior incompleto e somente 5,91% possuem o ensino superior completo. De acordo com (Dyzel et al., 2020) as tecnologias assistivas ajudam a aumentar as oportunidades de instrução para deficientes auditivos, sendo uma delas o videofone.

1.1 Objetivos

1.1.1 Objetivo Geral

O objetivo geral desse trabalho de pesquisa é investigar, por meio de um estudo bibliométrico, como as técnicas de *machine learning* e *Deep learning* estão sendo aplicadas em tecnologias assistivas que envolvem o reconhecimento da linguagem dos sinais, além de

identificar as principais tendências e desafios encontrados nas pesquisas publicadas sobre o tema.

1.1.2 Objetivos Específicos

- I. Identificar as palavras-chave e os padrões temáticos relacionados ao uso das tecnologias assistivas no reconhecimento de linguagem de sinais;
- II. Analisar a sintaxe de busca estabelecida na base científica Web of Science, Science Direct, Scopus, IEEE, nos campos título, resumo e palavras-chave;
- III. Tratar os dados obtidos por meio da bibliometria utilizando o software VOSviewer e filtros previamente definidos, além de realizar a estatística descritiva dos dados coletados.

2 REFERENCIAL TEÓRICO

2.1 Machine learning

Os três paradigmas fundamentais no campo de *machine learning* trabalha com três diferentes tipos de aprendizado, o supervisionado, não supervisionado e por reforço, cada método cria modelos distintos de como abordar os problemas desde a classificação, regressão, padronização e tomada de decisão sequencial.

O Aprendizado de Máquina (*machine learning*) é uma área de pesquisa que desenvolve programas de computador com a capacidade de aprender a executar uma dada tarefa a partir de sua própria experiência. Isso leva ao desenvolvimento de programas capazes de aprender por si mesmos, utilizando um conjunto de dados que representam experiências passadas. Trata-se de uma área multidisciplinar que abrange inteligência artificial, probabilidade e estatística, teoria da complexidade computacional, teoria da informação, filosofia, psicologia, neurobiologia, entre outros. Seu objetivo é construir programas que aprimorem seu desempenho por meio de exemplos. Para isso, é necessária uma grande quantidade de exemplos para gerar o conhecimento do computador, ou seja, as hipóteses são geradas automaticamente a partir dos dados apresentados (NATARAJAN et al., 2022).

A capacidade de aprendizado automático difere da programação básica, pois na segunda precisa-se codificar cada linha do que será executado pelo seu desenvolvedor, Taye (2023) explica que a vantagem do *machine learning* está no uso da construção de modelos computacionais com a capacidade de aumentar seu poder preditivos e de generalização, aplicando de forma mais eficiente em diversas situações que se entende como cenário padrão dentro do escopo do modelo.

Em diversas áreas existe a aplicação do *machine learning*, Jordan e Mitchell (2015) identificaram a sua adoção em setores como saúde, educação, manufatura, educação, modelagem financeira, policiamento, marketing, *cybersecurity* e construção civil. Raschka et al. (2020) evidenciaram em seu trabalho que a linguagem de programação *Python* é a mais utilizada na área de *machine learning*, pois permite o uso extensivo de bibliotecas e integra bibliotecas de baixo nível e APIs de alto nível, o que ainda é um desafio em outras linguagens, dessa forma torna o código barato para a escalabilidade.

2.2 *Deep learning*

Deep learning está inserido dentro da área de *machine learning* que se utiliza de redes neurais profundas de múltiplas camadas para extrair automaticamente representações hierárquicas de dados complexos.

O estudo de Zhou et al. (2021) mostra que essa tecnologia vem sendo utilizada em processos que envolvem a área médica para detecção de doenças, já Otter et al. (2021) identificaram que o uso do *deep learning* está associado ao campo do processamento de linguagem natural utilizando arquiteturas como redes neurais convolucionais (CNNs), redes neurais recorrentes (RNNs), *Transformers* e redes adversariais generativas (GANs).

Inteligências artificiais que utilizam técnicas de *deep learning*, estão ajudando na identificação e classificação de imagens clínicas, segundo Suganyadevi et al. (2022) essas ferramentas que utilizam modelos de *deep learning* tem precisão superior a 95% em tarefas na identificação e classificação de tumores cerebrais e câncer de mama por meio da análise de mamografias, já Sistaninejhad et al. (2023) em seu trabalho demonstra o uso de redes neurais convolucionais 3D em segmentação de imagens médicas alcançou resultados melhores em comparação ao uso de modelos como *U-Net*, Rana e Bhushan (2020) notaram o aumento do uso *deep learning* e *machine learning* na área médica para diagnóstico de doenças.

Soori et al. (2023) trazem uma nova área dentro de estudos de *deep learning* que é o *deep reinforcement learning*, que é utilizado na área da robótica autônoma, permitindo a aprendizagem de comportamentos complexos por meio de interação reais e ambientes de simulação computacional, dessa forma tornando os robôs mais adaptáveis a tarefas e ambientes complexos, como os cirúrgicos, onde são utilizados auxiliar a realizar operações complexas com maior precisão e exatidão, outra aplicação identificada foi a aplicação de medicamentos no tratamento de doenças infecciosas por intermédio do uso de modelos de *deep learning*.

2.3 Tecnologia assistivas

Com o passar dos anos a tecnologia vem sofrendo diversos avanços e existe um grande interesse de utilizar essa tecnologia como auxílio para pessoas com deficiência de forma a as assistir em seu dia a dia.

Segundo Nascimento et al. (2024) as tecnologias assistivas (TA) são estratégias utilizadas para promover o aumento da funcionalidade da pessoas com deficiência (PCD) possibilitando desenvolver sua autonomia por meio de equipamentos e serviços, já para Dyzel et al. (2020) a tecnologia assistiva é a aplicação de qualquer tecnologia que permita a uma pessoa realizar uma atividade de forma considerada normal, que antes ela não poderia realizar de forma quando estivesse sozinha, já Benevides et al. (2024) enxergam que adaptar os equipamentos por intermédio das tecnologias para servir as necessidades do indivíduo deve ser uma preocupação na inclusão de pessoas que necessitam o uso de TA.

No espectro especialmente para pessoas com deficiência auditiva essas tecnologias se tornam imperativas, segundo Silveira et al. (2022) em seu trabalho ele expõe um dado da Organização Mundial da Saúde (OMS) que aproximadamente 430 milhões de pessoas no mundo apresentam algum grau de perda auditiva incapacitante e as e para ele as TA desempenham papel crucial para aliviar as dores sociais desse problema, sendo por meio de *wearables* como luvas que transformam sinais em fala ou mesmo a computação gráfica para traduzir texto e som em linguagem de sinais em tempo real.

3 MÉTODO

Nesta seção, foi desenvolvida uma estratégia metodológica para a análise bibliométrica acerca da aplicação de técnicas de *machine learning* e *deep learning* em tecnologias assistivas para usuários de LIBRAS. Dessa forma, pode-se observar a evolução das publicações ao longo do tempo, variações por periódicos, regiões e instituições. Para este trabalho foi realizada uma pesquisa quantitativa.

Para a realização desta pesquisa, utilizou-se uma abordagem bibliométrica e uma análise de conteúdo. Na concepção de Silva e Hayashi (2011), bibliometria pauta-se pelo princípio de analisar a atividade científica ou técnica pelos estudos quantitativos das publicações. Ainda, sobre o estudo bibliométrico, Silva e Hayashi (2011) apontam que se trata de um estudo útil para mapear um campo científico, avaliar a pesquisa acadêmica, bem como para orientar rumos e estratégias de financiamento de pesquisas e apontar o alcance analítico para o estudo de um campo científico.

O tema abordado tem evoluído à medida que as ferramentas tecnológicas possibilitam seu desenvolvimento para as tecnologias assistivas. Para a análise bibliométrica, foi selecionado um recorte temporal entre os anos de 2019 até 2025, artigos de Open *acesss*, utilizando a expressão de pesquisa:

("Assistive technology" OR "Assistive device") AND ("Sign language" OR "LIBRAS") AND ("*machine learning*" OR "*deep learning*") AND DOCUMENT TYPE: (research article) AND PUBLISHED YEAR: (>2019) INDEX: (ACM Digital Library), (arXiv), (IEEE), (ScienceDirect), (SCOPUS), (SpringerLink) e (Web of Science).

Para a estruturação da sintaxe de busca, utilizou-se complementarmente de conectores booleanos AND e OR e aspas (“ ”). Por fim, foram empregadas três ferramentas para o tratamento dos dados e para a análise bibliométrica dos resultados obtidos nas buscas: software VOSviewer, Microsoft Excel® e Zotero 7.0.24 (64-bit).

4 RESULTADOS E DISCUSSÃO

A **Figura 1** demonstra que a primeira etapa envolveu a coleta massiva de literatura nas 6 bases pesquisadas (ACM Digital Library, arXiv, IEEE, ScienceDirect, SCOPUS, SpringerLink e Web of Science), considerando todos os tipos de artigos sendo os de acesso públicos e os pagos, pegando tempo máximo de artigos disponibilizados pelas bases 2002 até 2025, o ano de 2002 foi escolhido, pois algumas plataformas começavam a partir dessa data, totalizando 1254 artigos, podendo-se observar a relevância do tema, pois a partir do ano de 2014 começam a existir mais publicações sobre a aplicação de técnicas de *machine learning* e *deep learning* em tecnologias assistivas para usuários de libras.


Figura 1 - Distribuição das publicações anuais das bases de dados de 2002 a 2025.



Fonte: Autor (2024).

Posteriormente, a pesquisa se concentrou entre os anos de 2019 e 2025 como demonstrado na **Figura 2**, resultando em 331 publicações com acesso gratuito. Observou-se um crescimento nas pesquisas a partir de 2022 em 4 das 6 bases pesquisadas, no entanto, em 2025, o número de publicações foi inferior ao de 2024, possivelmente porque o ano de 2025 ainda não se encerrou, somente com uma exceção que é a base do Science Direct que continuou com o crescimento.

Figura 2 - Distribuição das publicações anuais de reconhecimento de linguagem de sinais na base.



Fonte: Autor (2024).

Na terceira busca, se retirou os artigos repetidos das bases, sendo que houveram 217 artigos que se encontravam nas múltiplas bases, ao final foram avaliados os artigos baseados em sua metodologia, os que não possuíam aderência com a proposta da revisão sobre a aplicação de técnicas de *machine learning* e *deep learning* em tecnologias assistivas em linguagem de sinais foram excluídos, restando somente 34 artigos, como demonstrado na **Tabela 1** abaixo.

Tabela 1 - Estratificação das bases de dados do período de 2019 - 2025

Bases	Total sem exclusão	Total após exclusão dos repetidos	Total após exclusão por falta de aderência	Artigos selecionados
ACM Digital Library, arXiv, IEEE, ScienceDirect, SCOPUS, SpringerLink, Web of Science.	331	114	80	34

Fonte: Autor (2024).

A **Figura 3** apresenta o número de publicações indexadas dos artigos após a terceira busca selecionados nos bancos de dados utilizados no período de 2020 a 2025. O maior número de publicações foi observado em 2023 e 2024, com 9 e 8 artigos respectivamente, o que equivale a 50% das publicações, já as publicações dos demais anos somam os outros 50% dos artigos, sendo 1 publicação em 2020, 2 publicações em 2021, e, 7 publicações em cada um dos anos de 2022 e 2025.

Figura 3 - Distribuição temporal das publicações anuais entre 2019 a 2024.



Fonte: Autor (2024).

A **Tabela 2** apresenta as palavras-chave e em qual área temática ela se encaixa e os padrões temáticos de aplicação de *Machine learning* e *Deep learning* em tecnologias assistivas, no campo de Tecnologias e Modelos de IA. Observa-se o alto uso de redes neurais e LSTM, evidenciando a preocupação de sequências temporais nos estudos, já no Processamento de Dados e Características é observado uma integração entre dados de vídeo RGB, esqueletos, expressões por meio de modelos de *landmarks* para melhorar a acurácia do reconhecimento.

No campo de Tarefas e Aplicações tem-se a aplicação em foco na tradução contínua e bidirecional da linguagem de sinais, o que também se relaciona com a criação de *datasets* específicos para o atendimento mais amplo para diferentes padrões da língua de sinais bem como seu modo de captura.

Na parte Métodos e Dispositivos de Captura tem-se o foco em *Wearables*, *Sensors*, já nas aplicações relacionados aos Desafios, Avaliação e Boas Práticas, tem-se uma contantes

preocupação em soluções de baixo custo e validação com usuários surdos, para se desenvolver tecnologias verdadeiramente assistivas e inclusivas.

Tabela 2 - Palavras-chave e padrões temáticos

Área Temática	Palavra-chave / Conceito	Padrão Temático Identificado nos Artigos
1. Tecnologias e Modelos de IA	<i>Deep learning</i> (CNN, LSTM, RNN)	Uso de arquiteturas como Redes Neurais Convolucionais (CNNs) para extração de características espaciais e Redes Neurais Recorrentes (LSTMs, GRUs) para modelar a natureza sequencial e temporal dos gestos.
	Transformer Models e Attention Mechanism	Aplicação de modelos baseados em atenção para capturar dependências de longo prazo em sequências de sinais, melhorando o contexto da tradução.
	YOLO (v5-v11)	Utilização de modelos da família YOLO para detecção e reconhecimento de gestos em tempo real, destacando-se pela alta velocidade e precisão em aplicações práticas.
	Transfer Learning e Modelos Pré-treinados	Aproveitamento de modelos de <i>Deep learning</i> já treinados (como ResNet50 e VGG16) e seu refinamento (fine-tuning) para a tarefa específica de reconhecimento de sinais, acelerando o treinamento e melhorando a acurácia.
	Diffusion Models	Exploração de modelos de difusão para a geração de vídeos de linguagem de sinais a partir de texto ou poses esqueléticas, focando na criação de transições suaves e realistas entre os sinais.
2. Processamento de Dados e Características	3D ConvNets (3DCNN)	Emprego de Redes Neurais Convolucionais 3D para capturar simultaneamente as características espaciais e temporais dos vídeos de sinais, tratando o vídeo como um único bloco de dados.
	MediaPipe e Pose Estimation	Emprego da biblioteca MediaPipe para extrair pontos-chave (keypoints) do corpo, mãos e face em tempo real, fornecendo dados esqueléticos para os modelos de reconhecimento.
⋮	⋮	⋮

(Continua...)

Tabela 3 - Palavras-chave e padrões temáticos (continuação)

Área Temática	Palavra-chave / Conceito	Padrão Temático Identificado nos Artigos
2. Processamento de Dados e Características	Skeletal Data e Hand Tracking	Foco no uso de dados do esqueleto e no rastreamento preciso das mãos como uma forma eficiente de representar gestos, reduzindo a complexidade computacional.
	Feature Extraction e Feature Fusion	Técnicas para extrair e combinar diferentes tipos de características (ex: contornos, texturas, movimento) de Fontes de dados multimodais para criar representações mais robustas dos sinais. Integração de múltiplos fluxos de dados, como vídeo RGB, imagens de profundidade, dados esqueléticos e sinais de sensores (IMU, sEMG), para melhorar a precisão do reconhecimento.
	Multi-modal Learning	Reconhecimento da importância de incorporar marcadores não manuais, como expressões faciais e movimentos do corpo, que são cruciais para o significado gramatical e emocional na linguagem de sinais.
	Non-manual Markers (Expressões Faciais)	Utilização de sistemas de notação fonética como HamNoSys e anotações de glosas para criar representações intermediárias dos sinais, facilitando o processo de tradução automática.
	HamNoSys e Gloss Notation	Foco principal da pesquisa, desenvolvendo sistemas para o reconhecimento automático de diversas línguas de sinais, como Americana (ASL), Árabe (ArSL), Indiana (ISL) e Turca (TSL).
	Sign Language Recognition (SLR)	Construção de sistemas de tradução bidirecional que convertem da linguagem de sinais para texto/fala e vice-versa.
3. Tarefas e Aplicações	Sign Language Translation	Diferenciação e desenvolvimento de modelos capazes de reconhecer tanto gestos isolados (uma única palavra ou letra) quanto sentenças contínuas, um desafio maior devido à coarticulação e segmentação.
	Continuous vs. Isolated SLR	
⋮	⋮	⋮
		(Continua...)

Tabela 4 - Palavras-chave e padrões temáticos (continuação)

Área Temática	Palavra-chave / Conceito	Padrão Temático Identificado nos Artigos
3. Tarefas e Aplicações	Fingerspelling Recognition	Criação de modelos específicos para o reconhecimento do alfabeto manual (soletração), que é um componente crucial de muitas línguas de sinais. Enquadramento da pesquisa como tecnologia assistiva, com o objetivo final de melhorar a comunicação, inclusão social e acessibilidade para pessoas surdas e com deficiência auditiva.
	Assistive Technology e Acessibilidade	Desenvolvimento de ferramentas para o ensino e aprendizado de línguas de sinais, permitindo que os usuários pratiquem e recebam feedback sobre sua execução.
	Aplicações Educacionais	Utilização de câmeras (RGB, profundidade) como principal sensor para a captura de gestos, aplicando algoritmos de visão computacional para interpretar os movimentos.
4. Métodos e Dispositivos de Captura	Computer Vision e Gesture Recognition	Uso de dispositivos vestíveis, como luvas e pulseiras, com sensores inerciais (IMU), eletromiografia (sEMG) e força miografia (FMG) para capturar os movimentos e a atividade muscular.
	Wearable Sensors (IMU, sEMG, FMG)	Foco no desenvolvimento de sistemas que funcionam em tempo real e com baixo custo computacional, permitindo sua execução em dispositivos comuns como smartphones e webcams.
	Real-time Processing e Soluções de Baixo Custo	Esforços para criar e disponibilizar novos conjuntos de dados para diversas línguas de sinais, um passo fundamental para superar a escassez de dados e permitir o avanço da área.
5. Desafios, Avaliação e Boas Práticas	Criação de <i>Datasets</i>	Avaliação rigorosa dos modelos utilizando métricas padrão como acurácia, precisão, recall, F1-score e mean Average Precision (mAP) para comparar o desempenho.
	Otimização de Métricas de Acurácia	
⋮	⋮	⋮

(Continua...)

Tabela 5 - Palavras-chave e padrões temáticos (continuação)

Área Temática	Palavra-chave / Conceito	Padrão Temático Identificado nos Artigos
5. Desafios, Avaliação e Boas Práticas	Foco em Línguas Específicas	Desenvolvimento de modelos e <i>datasets</i> dedicados a línguas de sinais específicas, como a Árabe (ArSL), Americana (ASL) e outras, para atender às suas particularidades linguísticas.
	User Studies e Usabilidade	Realização de estudos com usuários da comunidade surda para validar a eficácia e a usabilidade das tecnologias desenvolvidas em cenários do mundo real.

Fonte: Autor (2024).


Na amostra analisada, 34 artigos foram publicados em 17 periódicos. A **Tabela 3** apresenta essa distribuição por título de periódico: o *IEEE Access* concentra 17 publicações, o *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 2 publicações e os 15 artigos restantes distribuem-se, um por periódico, entre outros 15 títulos.

Tabela 6 - Distribuição dos resultados por periódico publicado

Nome da Revista	Total de publicações	Frequência
IEEE Access	17	50%
IEEE Transactions on Neural Systems and Rehabilitation Engineering	2	6%
Computers	1	3%
Computers Materials and Continua	1	3%
IEEE Open Journal of the Communications Society	1	3%
IEEE Transactions on Computational Social Systems	1	3%
IEEE Transactions on Pattern Analysis and Machine Intelligence	1	3%
IEEE Transactions on Systems Man and Cybernetics Systems	1	3%
International Journal of Advanced Computer Science and Applications	1	3%
International Journal of Basic and Applied Sciences	1	3%
International Journal of Cognitive Computing in Engineering	1	3%
International Journal of Computational Intelligence Systems	1	3%
International Journal of Computing and Digital Systems	1	3%
International Journal of Electrical and Computer Engineering	1	3%
Ksii Transactions on Internet and Information Systems	1	3%
Scientific Reports	1	3%
Sensors	1	3%

Fonte: Autor (2024).

Figura 4 - Países de publicação x número de publicação total



Fonte: Autor (2024).

A **Figura 4** acima demonstra uma comparação entre os países que pesquisam na área e seu respectivo número total de publicações relacionadas à aplicação de técnicas de *Machine learning* e *Deep learning* em tecnologias assistivas. Os países que demonstram o maior número de publicações são Arábia Saudita e Índia, cada um com 9 publicações, seguidos por Bangladesh, China, Japão e Estados Unidos das Américas com aproximadamente 3 publicações cada um dos países, percebe-se também uma participação significativa dos países Paquistão, Portugal e Espanha, com 2 publicações cada país.

Alguns fatores que podem explicar essa concentração de publicações são:

- o investimento governamental em tecnologias assistivas;
- a presença de comunidades surdas que precisam de soluções específicas;
- políticas de incentivo à pesquisa em inteligência artificial e acessibilidade.

Baseado na diversidade geográfica das publicações, que abrange mais de 31 países diferentes, pode-se inferir que existe uma preocupação na adoção de tecnologias assistivas para o reconhecimento de linguagem de sinais.

A **Tabela 4** apresenta os 34 artigos analisados relacionados ao uso de técnicas de *Machine learning* e *Deep learning* em tecnologias assistivas para linguagem de sinais, sendo acompanhados de métricas que representam seu impacto científico, expressos por meio do total de citações e pelo FWCI (*Field-Weighted Citation Impact*) que mede o impacto de citação em relação à média mundial de citações para artigos similares em conteúdo.

Tabela 7 - Total de citações entre 2019 a 2025 e FWCI

Títulos	Total de citações	FWCI
<i>Deep learning</i> based assistive technology on audio visual speech recognition for hearing impaired	84	6.33
SignBERT+: Hand-Model-Aware Self-Supervised Pre-Training for Sign Language Understanding	76	7.90
SIGNFORMER: DeepVision Transformer for Sign Language Recognition	71	7.80
Helping Hearing-Impaired in Emergency Situations: A <i>Deep learning</i> -Based Approach	59	4.63
Using Motion History Images with 3D Convolutional Networks in Isolated Sign Language Recognition	57	4.47
An automatic arabic sign language recognition system based on deep CNN: An assistive system for the deaf and hard of hearing	49	1.70
Sign Language Recognition Using Graph and General Deep Neural Network Based on Large Scale <i>Dataset</i>	47	9.65
Technological Solutions for Sign Language Recognition: A Scoping Review of Research Trends, Challenges, and Opportunities	44	1.03
SignExplainer: An Explainable AI-Enabled Framework for Sign Language Recognition With Ensemble Learning	39	4.41
An Efficient Two-Stream Network for Isolated Sign Language Recognition Using Accumulative Video Motion	37	2.84
Dynamic Korean Sign Language Recognition Using Pose Estimation Based and Attention-Based Neural Network	33	3.50
A Geometric Model-Based Approach to Hand Gesture Recognition	29	1.91
Automatic recognition of Arabic alphabets sign language using <i>Deep learning</i>	26	2.04
IDF-Sign: Addressing Inconsistent Depth Features for Dynamic Sign Word Recognition	25	2.82
Recognizing British Sign Language Using <i>Deep learning</i> : A Contactless and Privacy-Preserving Approach	23	3.45
Korean Sign Language Alphabet Recognition Through the Integration of Handcrafted and <i>Deep learning</i> -Based Two-Stream Feature Extraction Approach	20	4.36
Two-Stage <i>Deep learning</i> Solution for Continuous Arabic Sign Language Recognition Using Word Count Prediction and Motion Images	20	1.92
Empowering Communication: A <i>Deep learning</i> Framework for Arabic Sign Language Recognition with an Attention Mechanism	14	2.45
Neural Decoding of Chinese Sign Language with <i>Machine learning</i> for Brain-Computer Interfaces	13	0.80
Low-Frequency Entrainment to Visual Motion Underlies Sign Language Comprehension	11	0.80
<i>Deep learning</i> -Based Standard Sign Language Discrimination	8	0.79
⋮	⋮	⋮
(Continua...)		

Tabela 8 - Total de citações entre 2019 a 2025 e FWCI (continuação)

Títulos	Total de citações	FWCI
Joint Motion Affinity Maps (JMAM) and Their Impact on <i>Deep learning</i> Models for 3D Sign Language Recognition	6	1.38
A Real-Time Intelligent System Based on Machine-Learning Methods for Improving Communication in Sign Language	5	5.09
Semantic Communications for Image-Based Sign Language Transmission	5	1.06
MultiModal Ensemble Approach Leveraging Spatial, Skeletal, and Edge Features for Enhanced Bangla Sign Language Recognition	4	0.69
Automatic SignWriting Recognition: Combining <i>Machine learning</i> and Expert Knowledge to Solve a Novel Problem	4	0.45
An Efficient Bidirectional Android Translation Prototype for Yemeni Sign Language Using Fuzzy Logic and CNN Transfer Learning Models	2	0.46
Real-Time American Sign Language Interpretation Using <i>Deep learning</i> and Keypoint Tracking	1	1.24
Comparative Study of Hybrid <i>Deep learning</i> Models for Kannada Sign Language Recognition	0	0
Diagnosis and classification of neuromuscular disorders using Bi-LSTM optimized with grey Wolf optimizer for EMG signals	0	0
Gesture Language Recognition Through Computer Vision and a Spatial-Temporal Mathematical Model	0	0
Real-Time Lightweight Sign Language Recognition on Hybrid Deep CNN-BiLSTM Neural Network with Attention Mechanism	0	0
ALCTS—An Assistive Learning and Communicative Tool for Speech and Hearing Impaired Students	0	0
<i>Deep learning</i> -based Arabic Sign Recognition System for Automated Communication with Hearing Impaired Individuals	0	0

Fonte: Autor (2024).

Os artigos com maior número de citações são "*Deep learning based assistive technology on audio visual speech recognition for hearing impaired*" com 84 citações e FWCI de 6,33, "*SignBERT+: Hand-Model-Aware Self-Supervised Pre-Training for Sign Language Understanding*" com 76 citações e FWCI de 7,90, e "*SIGNFORMER: DeepVision Transformer for Sign Language Recognition*" com 71 citações e FWCI de 7,80, o que pode sugerir que começa-se a existir uma adoção de arquiteturas do tipo *Transformer* e modelos pré-treinados no reconhecimento de linguagem de sinais.


A média de citações por artigo é de 23,88, enquanto o FWCI médio de 2,53 indica que os trabalhos nesta área têm um impacto científico significativamente acima da média mundial para o campo, nota-se que 22 artigos possuem FWCI acima de 1,0 o que denota que os artigos foram citados acima da média mundial, como exemplo o artigo "*Sign Language Recognition Using Graph and General Deep Neural Network Based on Large Scale Dataset*" apresenta o

maior FWCI de 9,65 o que significa que ele foi citado 9,65 vezes mais que a média mundial de artigos da mesma linha de pesquisa, o que sugere uma metodologia do artigo é amplamente reconhecida como base para novos desenvolvimentos, de outro lado teve-se 12 artigos com FXCI abaixo de 1,0 o que significa que tiveram metade da média de citações esperadas mundialmente para artigos da mesma linha de pesquisa.

Quanto as citações nota-se que 41,18 % dos artigos têm entre 0 a 10 citações o que pode ser devido a fase de consolidação do artigo nas bases de pesquisa, em uma segunda faixa, os artigos têm entre 11 a 49 citações correspondendo a 44,12% dos artigos analisados, sugerindo que os artigos encontram-se em fase de maturação e relevância na base de dados, ao final tem-se um terceiro grupo, acima de 50 citações que correspondem a 14,71% das citações que podem ser tomados como referências que assumem papel fundamental na área tecnologias assistivas.

A **Figura 5** é uma representação de uma rede que mostra o acoplamento bibliográfico das publicações no período de 2019 a 2025, nas pesquisas desenvolvidas sobre aplicação de técnicas de *machine learning* e *Deep learning* em tecnologias assistivas em uso de linguagem de sinais. O acoplamento bibliográfico das publicações demonstra a relação entre duas ou mais obras que compartilham referências. Dessa forma, é possível identificar semelhanças temáticas e relações entre publicações, pesquisadores, centros de pesquisas e instituições, além de rastrear temas em áreas correlatas e a correlação entre países.

Figura 5 - Imagem da rede de cooperação entre diferentes países (2019 a 2024).



Fonte: Autor (2024).

Revista H-Tec Humanidades e Tecnologia, v.14, dez., 2025, Ed. Especial XX SIMPROFI. ISSN 2595-3699 161

demais palavras-chave e demais clusters da pesquisa, isso indica que essa palavra chave é a integradora da revisão proposta.

Ele se conecta ao cluster vermelho e laranja, que está com o foco segundo a análise nos métodos de *Deep learning* aplicados para o reconhecimento de linguagens de sinais, possuindo como palavras chaves de maior peso *convolutional networks*, *Deep learning* e *action recognition*, já o cluster verde, apresenta temas relacionados fundamentos sobre o aprendizado de máquina, tem as suas palavras chave mais representativas como *machine learning*, *feature extraction*, *classification* e *humans*, indicando um trabalho com base nos algoritmos utilizados nesses processo, o cluster azul trabalha com as palavras chave de processamento de imagem e modelagem computacional, utilizando tecnologias como *video signal processing*, *pattern recognition* e *musculoskeletal system*, sendo que a ponte entre esse cluster e o vermelho é a palavra-chave *convolução* que remete as redes convolucionais, já o cluster rosa trabalha com o processamento de biossinais para tecnologias assistivas, tendo como palavra chave processamento de biossinais, interface cérebro-computador e eletroencefalografia.

Na **Figura 7** também é possível reconhecer cluster menores como os de cor roxa, cinza e amarelo que trabalham com palavras temáticas como língua de sinais americana, reconhecimento de emoção e interação humano-computador.

Dessa forma podendo-se ver que o mapa de palavras chave traz que a pesquisa em “tecnologia assistiva” é um campo multidisciplinar, com forte abordagem de técnicas de *machine learning* e *Deep learning*, com *feature extraction* e redes convolucionais, conectando tecnologias assistivas que conectam diferentes aplicações na área de reconhecimento de linguagens de sinais e gestos.

CONSIDERAÇÕES FINAIS

O recente avanço tecnológico na área de *machine learning* em reconhecimento de linguagem de sinais continua a atrair pesquisadores e profissionais da indústria, pois pode fornecer ideias para o desenvolvimento social de maneira equitativa, se assim desejado.

O presente estudo apresentou uma revisão sobre aplicação de técnicas de *machine learning* e *Deep learning* em tecnologias assistivas em uso de linguagem de sinais entre 2019 a 2025. Esse recorte temporal das tendências de pesquisa teve como base 34 artigos filtrados das bases de dados ACM Digital Library, arXiv, IEEE, ScienceDirect, SCOPUS, SpringerLink e Web of Science.

Os países com colaborações internacionais significativas foram identificados e apresentados neste artigo, assim como os periódicos que mais publicaram sobre o tema. As limitações para um estudo mais amplo residem na dificuldade de acesso a mais publicações, uma vez que, neste recorte, foram utilizadas apenas versões gratuitas.

Os tópicos emergentes, descobertos estão relacionados a tecnologias assistivas na área de hardware de baixo custo e acessível com microcontrolador raspberry pi 3 model b, sensores mpu-6050 e sensores flex, para treinamentos, wearables sensorados com dispositivo MPU-6050 (acelerômetro e giroscópio) para capturar a orientação e o movimento da mão em um espaço tridimensional sem depender de câmeras ou do ambiente externo para captura do gesto, fusão de características manuais e de *Deep learning*, a primeira extrai informações geométricas como distância e ângulos entre as juntas do esqueleto, capturando relações intrínsecas do gesto e a segunda utiliza modelos de ResNet, para extrair representações hierárquicas da imagem, tradução bidirecional, sinal para texto e texto para sinal em tempo real permitindo a conversação natural e interativa, redes neurais de grafos representando os dados do esqueleto por meio de esqueleto podem ser representados como um grafo (articulações como nós e ossos como arestas), as redes neurais de grafos são utilizadas para modelar as relações espaciais e temporais entre as articulações no esqueleto de forma mais eficaz do que as CNNs convencionais, decodificação neural utiliza dados de eletroencefalografia (EEG) para registrar a atividade cerebral de um indivíduo enquanto ele executa ou imagina sinais, possibilitando classificar esses sinais neurais para o reconhecimento da palavra ou letra da linguagem de sinais ao invés de usar o método tradicional com treinamento de máquinas e gravação.

Como sugestão, pode-se expandir este estudo para revisão sistemática da literatura, considerando um aprofundamento grandes bases de divulgação de conhecimento.

Espera-se que este estudo seja uma oportunidade para pesquisadores de países com menos colaborações expandirem suas redes de cooperação.

Referências

- ABDUL AMEER, R. S. *et al.* Empowering Communication: A *Deep learning* Framework for Arabic Sign Language Recognition with an Attention Mechanism. **Computers**, v. 13, n. 6, p. 153, 19 jun. 2024.
- BENEVIDES, Marcello Pereira *et al.* Sign Talk Assistive Technology: Real-Time Recognition of the Libras Typical Alphabet Using Artificial Intelligence. **Revista de Gestão Social e Ambiental**, v. 18, n. 12, p. e010610, 31 dez. 2024.

BRASIL. **Dispõe sobre a Língua Brasileira de Sinais - Libras e dá outras providências.**

Lei nº 10.436/2002, 24 abr. 2002. Disponível em:

<https://www.planalto.gov.br/ccivil_03/leis/2002/110436.htm>. Acesso em: 8 set. 2025

DE AVELLAR SARMENTO, Amanda Hellen; ANTONELLI PONTI, Moacir. A Cross-Dataset Study on the Brazilian Sign Language Translation. In: 2023 IEEE/CVF INTERNATIONAL CONFERENCE ON COMPUTER VISION WORKSHOPS (ICCVW). **2023 IEEE/CVF International Conference on Computer Vision Workshops (ICCVW)**. Paris, France: IEEE, 2 out. 2023. Disponível em:

<<https://ieeexplore.ieee.org/document/10350372/>>. Acesso em: 26 set. 2025

DYZEL, Vernandi *et al.* Assistive Technology to Promote Communication and Social Interaction for People With Deafblindness: A Systematic Review. **Frontiers in Education**, v. 5, p. 578389, 17 set. 2020.

GONZÁLEZ-RODRÍGUEZ, Jaime-Rodrigo *et al.* Towards a Bidirectional Mexican Sign Language–Spanish Translation System: A *Deep learning* Approach. **Technologies**, v. 12, n. 1, p. 7, 5 jan. 2024.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Pesquisa Nacional de Saúde 2019: Tabela 8217 - Pessoas de 18 anos ou mais de idade, por avaliação do próprio estado de saúde, segundo o sexo e a cor ou raça**. Rio de Janeiro: Instituto Brasileiro de Geografia e Estatística, 2019a. Disponível em:

<<https://sidra.ibge.gov.br/tabela/8217#resultado>>.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Pesquisa Nacional de Saúde 2019: Tabela 8220- Pessoas de 18 anos ou mais de idade, por avaliação do próprio estado de saúde, segundo o sexo e a cor ou raça**. Rio de Janeiro: Instituto Brasileiro de Geografia e Estatística, 2019b. Disponível em:

<<https://sidra.ibge.gov.br/tabela/8220#resultado>>.

JORDAN, M. I.; MITCHELL, T. M. *Machine learning*: Trends, perspectives, and prospects. **Science**, v. 349, n. 6245, p. 255–260, 17 jul. 2015.

MAHMUD, Hasan. **BdSL47: A Complete Depth-based Bangla Sign Alphabet and Digit Dataset**. Mendeley Data, , 5 nov. 2023. Disponível em:

<<https://data.mendeley.com/datasets/pbb3w3f92y/3>>. Acesso em: 26 set. 2025

MARTINO, José Mario De; CHRISTINELE, Dener Stassun. Exploring Pre-Trained Transformers for Translating Portuguese Text to Brazilian Sign Language. In: 16TH INTERNATIONAL CONFERENCE ON COMPUTATIONAL PROCESSING OF PORTUGUESE. **Anais...** Santiago de Compostela, Galicia/Spain: ACL Anthology, mar. 2024. Disponível em: <<https://aclanthology.org/2024.propor-1.7.pdf>>

MORAIS, Letícia M. G. De; ALMEIDA, Welizangela M.; REGO, Rosana C. B. *Machine learning* approaches for efficient recognition of Brazilian Sign Language. In: SIMPÓSIO BRASILEIRO DE SISTEMAS DE INFORMAÇÃO. **Anais do XXI Simpósio Brasileiro de Sistemas de Informação (SBSI 2025)**. Brasil: Sociedade Brasileira de Computação, 19 maio 2025. Disponível em: <<https://sol.sbc.org.br/index.php/sbsi/article/view/34320>>. Acesso em: 26 set. 2025

OTTER, Daniel W.; MEDINA, Julian R.; KALITA, Jugal K. A Survey of the Usages of *Deep learning* for Natural Language Processing. **IEEE Transactions on Neural Networks and Learning Systems**, v. 32, n. 2, p. 604–624, fev. 2021.

RASCHKA, Sebastian; PATTERSON, Joshua; NOLET, Corey. *Machine learning in Python: Main Developments and Technology Trends in Data Science, Machine learning, and Artificial Intelligence*. **Information**, v. 11, n. 4, p. 193, 4 abr. 2020.

REZENDE, Tamires Martins; ALMEIDA, Sílvia Grasiella Moreira; GUIMARÃES, Frederico Gadelha. Development and validation of a Brazilian sign language database for human gesture recognition. **Neural Computing and Applications**, v. 33, n. 16, p. 10449–10467, ago. 2021.

RODRÍGUEZ-CORREA, Paula Andrea *et al.* Benefits and development of assistive technologies for Deaf people's communication: A systematic review. **Frontiers in Education**, v. 8, p. 1121597, 5 abr. 2023.

SAW, Priyanshu Kumar *et al.* Gesture Recognition in Sign Language Translation: A *Deep learning* Approach. In: 2024 INTERNATIONAL CONFERENCE ON INTEGRATED CIRCUITS, COMMUNICATION, AND COMPUTING SYSTEMS (ICIC3S). **2024 International Conference on Integrated Circuits, Communication, and Computing Systems (ICIC3S)**. Una, India: IEEE, 8 jun. 2024. Disponível em: <<https://ieeexplore.ieee.org/document/10603225/>>. Acesso em: 26 set. 2025

SILVA, Márcia Regina Da; HAYASHI, Carlos Roberto Massao; HAYASHI, Maria Cristina Piumbato Innocentini. Análise bibliométrica e cientométrica: desafios para especialistas que atuam no campo. **InCID: Revista de Ciência da Informação e Documentação**, v. 2, n. 1, p. 110–129, 15 jun. 2011.

SILVEIRA, Wellington *et al.* SynLibras: A Disentangled Deep Generative Model for Brazilian Sign Language Synthesis. In: 2022 35TH SIBGRAPI CONFERENCE ON GRAPHICS, PATTERNS AND IMAGES (SIBGRAPI). **2022 35th SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)**. Natal, Brazil: IEEE, 24 out. 2022. Disponível em: <<https://ieeexplore.ieee.org/document/9991748/>>. Acesso em: 26 set. 2025

SISTANINEJHAD, Bagher; RASI, Habib; NAYERI, Parisa. A Review Paper about *Deep learning* for Medical Image Analysis. **Computational and Mathematical Methods in Medicine**, v. 2023, n. 1, p. 7091301, jan. 2023.

SOORI, Mohsen; AREZOO, Behrooz; DASTRES, Roza. Artificial intelligence, *machine learning* and *Deep learning* in advanced robotics, a review. **Cognitive Robotics**, v. 3, p. 54–70, 2023.

SUGANYADEVI, S.; SEETHALAKSHMI, V.; BALASAMY, K. A review on *Deep learning* in medical image analysis. **International Journal of Multimedia Information Retrieval**, v. 11, n. 1, p. 19–38, mar. 2022.

TAYE, Mohammad Mustafa. Understanding of *Machine learning* with *Deep learning*: Architectures, Workflow, Applications and Future Directions. **Computers**, v. 12, n. 5, p. 91, 25 abr. 2023.

ZHOU, S. Kevin *et al.* A Review of *Deep learning* in Medical Imaging: Imaging Traits, Technology Trends, Case Studies With Progress Highlights, and Future Promises. **Proceedings of the IEEE**, v. 109, n. 5, p. 820–838, maio 2021.