

**PROTEA-M: FRAMEWORK MULTIMODAL PARA COMUNICAÇÃO INCLUSIVA EM SITUAÇÕES DE INUNDAÇÃO****PROTEA-M: MULTIMODAL FRAMEWORK FOR INCLUSIVE COMMUNICATION IN FLOOD SITUATIONS****PROTEA-M: MARCO MULTIMODAL PARA LA COMUNICACIÓN INCLUSIVA EN SITUACIONES DE INUNDACIÓN**Danilo Monteiro Souza¹; Sérgio Murilo Maciel Fernandes²

e778278

<https://doi.org/10.47820/recima21.v7i7.8278>

PUBLICADO: 07/2026

RESUMO

Os sistemas de alerta precoce constituem a principal ferramenta para notificação e orientação da população em situações de emergência, porém ainda utilizam mensagens padronizadas que não consideram diferenças cognitivas e comunicativas. Essa limitação impacta de forma direta pessoas com Transtorno do Espectro Autista, que demandam formas estruturadas e previsíveis de organização da informação para compreensão e tomada de decisão em contextos de risco. Este trabalho apresenta o *framework* PROTEA-M (*Program for Readiness and Organized Training in Emergencies for Autistic Individuals - Multimodal*), um modelo preditivo-generativo multimodal voltado à produção de conteúdos inclusivos para preparação em cenários de inundação. O modelo estima o perfil comunicativo e o plano de intervenção e, a partir dessa estimativa, gera Histórias Sociais personalizadas. O módulo preditivo utiliza *ensemble* de *Extreme Learning Machines* com fusão de evidências e calibração probabilística, apresentando desempenho superior aos *baselines*, com acurácia de 0,6923 e ROC-AUC de 0,9782, além de melhor qualidade probabilística. O módulo generativo produz narrativas multimodais por meio de modelos de linguagem, traduzindo variáveis clínicas em sequências visuais e textuais organizadas. O PROTEA-M contribui para a evolução dos sistemas de alerta ao incorporar personalização comunicacional e acessibilidade cognitiva.

PALAVRAS-CHAVE: Sistemas de alerta. Autismo. Histórias sociais. Aprendizado de máquina.**ABSTRACT**

Early warning systems are the main tool for notifying and guiding the population in emergency situations; however, they still rely on standardized messages that do not consider cognitive and communicative differences. This limitation directly affects individuals with Autism Spectrum Disorder, who require structured and predictable forms of information organization for understanding and decision-making in risk contexts. This study presents the PROTEA-M framework (Program for Readiness and Organized Training in Emergencies for Autistic Individuals - Multimodal), a multimodal predictive-generative model designed to produce inclusive content for preparedness in flood scenarios. The model estimates the communicative profile and intervention plan and, based on this estimation, generates personalized Social Stories.

¹ Graduado em Engenharia da Computação pela Universidade Paulista (UNIP), Mestre em Engenharia da Computação pela Escola Politécnica da Universidade de Pernambuco (POLI - UPE), Doutorando no Programa de Pós-Graduação em Engenharia da Computação da Escola Politécnica da Universidade de Pernambuco (POLI - UPE)

² Graduado em Engenharia Elétrica Universidade Federal de Pernambuco (UFPE), Mestre em Engenharia Elétrica pela Universidade Federal de Pernambuco (UFPE), Doutorado pelo Centro de Informática da Universidade Federal de Pernambuco (Cin - UFPE).



The predictive module employs an ensemble of Extreme Learning Machines with evidence fusion and probabilistic calibration, achieving superior performance compared to baselines, with accuracy of 0.6923 and ROC-AUC of 0.9782, in addition to improved probabilistic quality. The generative module produces multimodal narratives using language models, translating clinical variables into structured visual and textual sequences. PROTEA-M contributes to the advancement of early warning systems by incorporating communicative personalization and cognitive accessibility.

KEYWORDS: *Early warning systems. Autism. Social stories. Machine learning.*

RESUMEN

Los sistemas de alerta temprana constituyen la principal herramienta para la notificación y orientación de la población en situaciones de emergencia; sin embargo, aún utilizan mensajes estandarizados que no consideran diferencias cognitivas y comunicativas. Esta limitación afecta directamente a las personas con Trastorno del Espectro Autista, que requieren formas estructuradas y predecibles de organización de la información para la comprensión y la toma de decisiones en contextos de riesgo. Este trabajo presenta el framework PROTEA-M (Program for Readiness and Organized Training in Emergencies for Autistic Individuals - Multimodal), un modelo predictivo-generativo multimodal orientado a la producción de contenidos inclusivos para la preparación en escenarios de inundación. El modelo estima el perfil comunicativo y el plan de intervención y, a partir de esta estimación, genera Historias Sociales personalizadas. El módulo predictivo utiliza un ensemble de Extreme Learning Machines con fusión de evidencias y calibración probabilística, presentando un rendimiento superior a los baselines, con una precisión de 0.6923 y ROC-AUC de 0.9782, además de una mejor calidad probabilística. El módulo generativo produce narrativas multimodales mediante modelos de lenguaje, traduciendo variables clínicas en secuencias visuales y textuales organizadas. PROTEA-M contribuye a la evolución de los sistemas de alerta al incorporar personalización comunicativa y accesibilidad cognitiva.

PALABRAS-CLAVE: *Sistemas de alerta. Autismo. Historias sociales. Aprendizaje automático.*

INTRODUÇÃO

Nas últimas décadas, os desastres associados a eventos climáticos extremos passaram a ocupar posição central nas agendas de redução de risco, pois afetam populações, infraestruturas e serviços essenciais. Entre esses eventos, as inundações se destacam pela recorrência e pelo impacto humano e econômico, em um contexto agravado pelo aquecimento global e pela intensificação de eventos extremos (UNDRR, 2022; WMO, 2021; IPCC, 2023).

Como resposta a esse quadro, os sistemas de alerta precoce assumem papel estratégico ao combinar monitoramento, previsão, comunicação e orientação para ação antecipada. A efetividade desses sistemas, contudo, não depende apenas da detecção do risco, mas também da capacidade de transformar informação técnica em mensagens compreensíveis e acionáveis para diferentes grupos da população (UNDRR, 2015; BASHER, 2006).

Essa dimensão comunicacional revela uma limitação relevante dos sistemas atuais: a predominância de mensagens padronizadas, pouco sensíveis a diferenças cognitivas, sensoriais e comunicacionais. Estudos sobre acessibilidade em contextos de desastre mostram que pessoas com deficiência enfrentam barreiras no acesso, na compreensão e no uso das mensagens de alerta, o que



reduz a capacidade de resposta diante de situações críticas (UNICEF, 2023; SHAH *et al.*, 2023; WORLD BANK, 2022).

Entre os grupos afetados por essa lacuna comunicacional, pessoas com Transtorno do Espectro Autista (TEA) demandam atenção específica. Diferenças no processamento sensorial, na previsibilidade de rotinas e na interpretação de informações ambíguas podem dificultar a compreensão de sirenes, alarmes, mensagens curtas e instruções emergenciais (ROBERTSON; BARON-COHEN, 2017; BOGDASHINA, 2016).

Diante dessa necessidade, recursos de Comunicação Aumentativa e Alternativa, a Matriz de Comunicação e as Histórias Sociais oferecem fundamentos para organizar informações de modo estruturado, previsível e ajustado ao perfil comunicacional do indivíduo. Esses recursos apoiam a antecipação de eventos, a compreensão de rotinas e a orientação de comportamentos esperados, mas sua elaboração ainda exige conhecimento especializado e alto grau de personalização (ROWLAND, 2011; GRAY, 2010; KOKINA; KERN, 2010).

Ao mesmo tempo, técnicas de aprendizado de máquina e modelos generativos ampliam as possibilidades de automatizar parte desse processo. Modelos preditivos podem estimar padrões a partir de dados comunicacionais, enquanto *Large Language Models* (LLMs) permitem gerar conteúdo textual condicionado por instruções e restrições (BROWN *et al.*, 2020; REIMERS; GUREVYCH, 2019). Mesmo assim, permanece uma lacuna na integração entre estimativa de perfil comunicacional, recomendação de plano de intervenção e geração de conteúdo multimodal para preparação em desastres.

A partir dessa lacuna, formula-se a seguinte pergunta de pesquisa: os sistemas de alerta precoce atendem adequadamente às necessidades comunicacionais de pessoas com TEA em cenários de inundação, considerando suas particularidades cognitivas, sensoriais e comunicacionais?

A hipótese deste trabalho sustenta que a integração entre estimativa do perfil comunicacional e geração automatizada de conteúdos multimodais personalizados pode produzir mensagens mais claras, estruturadas e acionáveis, contribuindo para reduzir sobrecarga sensorial e ampliar prontidão de ação em situações de risco.

Para responder a essa questão e sustentar essa hipótese, este artigo propõe o *framework* PROTEA-M, um modelo preditivo e generativo multimodal voltado à produção de conteúdos inclusivos para preparação de pessoas com TEA em cenários de inundação. A proposta articula inferência de perfil, seleção de plano de intervenção e geração de Histórias Sociais personalizadas em um fluxo único e integrado.

O objetivo do estudo é propor, desenvolver e avaliar o PROTEA-M. Para alcançá-lo, buscase: (i) estruturar uma base de dados autoral, validada por especialistas e representativa de perfis comunicacionais; (ii) desenvolver um módulo preditivo para estimar perfil comunicacional e plano de intervenção; (iii) implementar um módulo generativo para produção de Histórias Sociais multimodais;



e (iv) avaliar o desempenho do modelo por métricas de classificação, calibração e adequação comunicacional.

O escopo concentra-se em conteúdos comunicacionais para cenários de inundação, considerando variáveis comunicacionais, sensoriais e contextuais. Espera-se que a abordagem proposta contribua para sistemas de alerta mais inclusivos, ao associar personalização comunicacional, modelagem probabilística e geração de materiais estruturados para preparação em situações de risco.

1. REFERENCIAL TEÓRICO

1.1. Sistemas de alerta precoce e o paradigma da comunicação inclusiva

Os Sistemas de Alerta Precoce (SAP) são estruturas voltadas ao monitoramento, previsão e disseminação de informações relacionadas a riscos e desastres naturais (BASHER, 2006). Segundo o Marco de Sendai, a efetividade desses sistemas depende não apenas da detecção do risco, mas da capacidade de a população compreender a mensagem e convertê-la em ação protetiva (UNDRR, 2015). Nesse contexto, a comunicação de risco assume papel central. BALOG-WAY, MCCOMAS e BESLEY (2020) destacam que mensagens eficazes devem considerar fatores sociais, cognitivos e comunicacionais do público-alvo. Entretanto, muitos sistemas ainda utilizam mensagens padronizadas e estímulos sonoros genéricos, desconsiderando diferenças cognitivas e sensoriais presentes em grupos vulneráveis (MILETI; SORENSEN, 1990; WMO, 2021).

Estudos recentes mostram que pessoas com deficiência enfrentam barreiras no acesso, compreensão e utilização das mensagens de emergência, comprometendo a adoção de comportamentos protetivos (UNICEF, 2023; WORLD BANK, 2022). SHAH *et al.* (2023) reforçam que limitações comunicacionais persistem mesmo em sistemas tecnologicamente avançados, especialmente quando grupos vulneráveis não são considerados no planejamento da disseminação dos alertas.

1.2. Transtorno do Espectro Autista e as barreiras dos alertas convencionais

O Transtorno do Espectro Autista (TEA) é um transtorno do neurodesenvolvimento caracterizado por diferenças na comunicação social e por padrões comportamentais restritivos ou repetitivos (APA, 2013). Além disso, alterações no processamento sensorial podem dificultar a interpretação de estímulos auditivos, visuais e contextuais (ROBERTSON; BARON-COHEN, 2017).

Em situações de emergência, sirenes, alarmes e mensagens genéricas podem desencadear ansiedade, sobrecarga sensorial e dificuldades de compreensão em pessoas com TEA (BOGDASHINA, 2016). Soma-se a isso a dificuldade de interpretar linguagem abstrata e instruções ambíguas em cenários de estresse, reduzindo a efetividade dos alertas convencionais (FRITH, 2003).



Essas características evidenciam a necessidade de estratégias comunicacionais mais acessíveis, estruturadas e personalizadas para esse público.

1.3. Histórias Sociais como estratégia de previsibilidade

As Histórias Sociais são narrativas estruturadas que utilizam linguagem simples e suportes visuais para antecipar situações, orientar comportamentos e ampliar previsibilidade (GRAY; GARAND, 1993; GRAY, 2010). No contexto do TEA, esse recurso auxilia na compreensão de rotinas, redução da ansiedade e adaptação a novos cenários.

KOKINA e KERN (2010) apontam que Histórias Sociais favorecem mediação comportamental e compreensão contextual em indivíduos autistas. De forma complementar, RUTHERFORD *et al.* (2020) destacam que suportes visuais contribuem para organização funcional e antecipação de eventos em ambientes cotidianos.

A efetividade dessas estratégias depende de personalização compatível com o perfil comunicacional do indivíduo. Nesse sentido, a Matriz de Comunicação organiza o desenvolvimento comunicacional em diferentes níveis e funções pragmáticas, permitindo caracterização funcional das capacidades expressivas e receptivas do usuário (ROWLAND, 2011).

Apesar dos benefícios, a produção manual de conteúdos personalizados demanda tempo, adaptação contínua e conhecimento especializado, limitando sua aplicação em cenários de emergência.

1.4. Inteligência Artificial Generativa na personalização da comunicação de risco

Os avanços recentes da Inteligência Artificial Generativa ampliaram as possibilidades de produção automatizada de conteúdos personalizados. Modelos baseados em arquiteturas *Transformer* e *Large Language Models* (LLMs) demonstraram elevada capacidade de síntese textual e adaptação contextual (VASWANI *et al.*, 2017; BROWN *et al.*, 2020).

No campo da acessibilidade comunicacional, essas tecnologias permitem gerar conteúdos ajustados a diferentes perfis cognitivos e linguísticos. FENG *et al.* (2025) propõem um *framework* baseado em LLMs para geração automatizada de Histórias Sociais voltadas a indivíduos autistas. Embora a abordagem apresente potencial para personalização textual, ela não incorpora mecanismos formais de inferência do perfil comunicacional.

Paralelamente, AHMED *et al.* (2022) demonstram que modelos de aprendizado de máquina baseados em *Extreme Learning Machines* (ELM) podem alcançar elevado desempenho na classificação de padrões relacionados ao TEA. Contudo, essas abordagens permanecem concentradas no domínio preditivo, sem integração com mecanismos automatizados de geração multimodal.

Dessa forma, permanece uma lacuna relacionada à integração entre estimativa do perfil comunicacional, recomendação de intervenção e geração automatizada de conteúdos acessíveis para contextos de desastre. É nesse cenário que se insere a proposta do *framework* PROTEA-M.

2. ESTADO DA ARTE

O *modus operandi* dos sistemas de alerta precoce (SAP) tradicionais prioriza a precisão técnica da detecção de ameaças, negligenciando frequentemente a acessibilidade comunicacional na "última milha" da disseminação. Dada a insuficiência de mensagens uniformes para públicos neurodivergentes, o estado da arte propõe o uso de Inteligência Artificial (IA) para automatizar a triagem e a geração de suportes de compreensão, como as Histórias Sociais. No entanto, conforme listado na Tabela 1, as abordagens atuais apresentam lacunas críticas quanto ao embasamento clínico estruturado e à integração entre os módulos de predição e geração.

Tabela 1. Sumário das principais técnicas de IA aplicadas ao TEA e preparação para riscos

Trabalho	Base de Dados Estruturada	Grounding Clínico (Matriz)	Módulo Preditivo Formal	Saída Generativa	Contexto de Emergência (EWS)
Trabalho proposto	Sim (MARSOCH)	Sim	Sim (ELM <i>Ensemble</i>)	Multimodal (Quadrinhos)	Sim
FENG <i>et al.</i> (2025)	Sim (SS-GEN)	Não	Não	Multimodal (Quadrinhos)	Não
ABDULLAH <i>et al.</i> (2022)	Não	Não	Não	Não	Não
AHMED <i>et al.</i> (2022)	Não	Não	Sim	Apenas Classificação	Não
RUTHERFORD <i>et al.</i> (2020)	Não	Parcial	Não	Suporte Visual Manual	Não
SHAH <i>et al.</i> (2023)	Não	Não	Não	Não	Sim

Fonte: Autor

O trabalho de FENG *et al.* (2025) propõe o *framework* SS-GEN, que utiliza *Large Language Models* (LLMs) para geração automatizada de Histórias Sociais sob restrições estruturais voltadas à clareza textual e segurança contextual. Embora a abordagem demonstre potencial para síntese de narrativas adaptativas, o processo de personalização permanece dependente de instruções fornecidas manualmente por cuidadores, sem incorporar mecanismos formais de inferência do perfil comunicacional do usuário. Dessa forma, o sistema não estabelece garantias de compatibilidade entre a complexidade narrativa produzida e os níveis cognitivos, simbólicos e comunicacionais do indivíduo autista.

No campo da acessibilidade comunicacional, ABDULLAH *et al.* (2022) apresentam uma revisão sistemática sobre tecnologias assistivas baseadas em Inteligência Artificial aplicadas ao TEA.



Os autores demonstram que soluções computacionais vêm sendo utilizadas para apoio à comunicação, interação social e adaptação comportamental. Entretanto, a maior parte das abordagens permanece concentrada em ambientes clínicos e educacionais, sem foco específico em cenários críticos de emergência e disseminação de alertas.

Sob a perspectiva da modelagem preditiva, AHMED *et al.* (2022) exploram algoritmos de *Machine Learning* baseados em *Extreme Learning Machines* (ELM) para classificação de padrões associados ao TEA, alcançando elevado desempenho analítico. Apesar dos resultados promissores, o modelo permanece restrito ao domínio preditivo, sem integração com mecanismos automatizados de geração de conteúdo acessível. Assim, a inferência estatística obtida não é convertida em estratégias comunicacionais voltadas à preparação do usuário para situações de risco.

De forma complementar, RUTHERFORD *et al.* (2020) investigam o uso de suportes visuais para organização funcional e previsibilidade em indivíduos autistas. Os autores destacam que recursos visuais favorecem compreensão contextual, redução da ansiedade e antecipação de eventos cotidianos. Contudo, a elaboração desses materiais permanece predominantemente manual e dependente da atuação contínua de especialistas e cuidadores, limitando escalabilidade em contextos de emergência.

No domínio dos sistemas de alerta precoce, SHAH *et al.* (2023) demonstram que barreiras sociais e comunicacionais continuam comprometendo a efetividade da disseminação de alertas de inundação, especialmente na denominada “última milha” da comunicação. Embora o estudo evidencie limitações importantes relacionadas à acessibilidade da informação, a abordagem não incorpora mecanismos de personalização cognitiva ou adaptação multimodal voltados a indivíduos neurodivergentes.

Diante dessas limitações, o PROTEA-M busca avançar além do estado da arte ao integrar inferência preditiva, *grounding* clínico e geração multimodal em um único pipeline computacional. Diferentemente das abordagens estáticas ou dependentes de adaptação manual, o *framework* implementa um encadeamento preditivo-generativo no qual o perfil comunicacional é estimado sistematicamente por um *ensemble* de *Extreme Learning Machines* (ELM). Após a etapa de calibração probabilística, os parâmetros inferidos são utilizados pelo módulo generativo para sintetizar Histórias Sociais multimodais compatíveis com as características cognitivas, sensoriais e comunicacionais do indivíduo.

Dessa forma, o PROTEA-M propõe automatizar a “última milha” da comunicação em cenários de inundação, traduzindo variáveis clínicas e comunicacionais em conteúdos estruturados e acessíveis voltados à preparação de pessoas com TEA para situações de risco.



3. MATERIAIS E MÉTODOS

O presente trabalho estrutura a MARSOCH (*Machine Learning Repository to Social Histories*), uma base de dados autoral composta por 200 registros sintéticos que permitem a representação e a classificação de perfis comunicativos de crianças com Transtorno do Espectro Autista (TEA). A opção pela utilização de dados sintéticos fundamenta-se na necessidade de mitigar riscos de privacidade e contornar a escassez de dados clínicos rotulados em domínios altamente especializados, permitindo o desenvolvimento de modelos preditivos robustos mesmo diante de Necessidades Complexas de Comunicação (NCC). Os registros foram projetados para representar perfis plausíveis e heterogêneos, garantindo que o *framework* PROTEA-M capture a diversidade dos níveis de desenvolvimento e funções pragmáticas previstos na Matriz de Comunicação.

A fundamentação da MARSOCH reside na transposição dos eixos conceituais da Matriz de Comunicação - níveis de desenvolvimento, funções pragmáticas e meios de expressão - para um formato computacional estruturado. Diferentemente de bases genéricas, a MARSOCH incorpora descrições textuais de comportamentos observáveis, que servem como evidência empírica para a extração de *embeddings* semânticos via *Sentence-BERT* (SBERT) e subsequente inferência de planos de intervenção. Enfatiza-se que a base passou por um processo de validação de conteúdo conduzido por especialistas da Ninho Clínica Infantil Multidisciplinar. Esta etapa concentrou-se na análise qualitativa da estrutura da base, na consistência semântica das instâncias e na fidelidade conceitual dos perfis representados em relação à prática clínica real.

Quanto aos aspectos éticos, por se tratar de uma base de dados estritamente sintética que não envolveu a participação direta de seres humanos ou o acesso a prontuários reais nesta fase de construção, o estudo é isento de submissão ao Comitê de Ética em Pesquisa (CEP). Contudo, ressalta-se que o protocolo para a futura validação clínica experimental com o público-alvo (envolvendo delineamento de caso único e múltiplas linhas de base) já está estruturado seguindo as resoluções CNS 466/12 e 510/16, encontrando-se em fase de análise pelo CEP.

Embora o tamanho da amostra ($n=200$) possa ser considerado reduzido para padrões de *big data*, o potencial viés de generalização e o risco de sobreajuste (*overfitting*) são mitigados pela adoção do protocolo de validação cruzada aninhada (*nested cross-validation*) com abordagem *group-aware*. Esta técnica garante a integridade estatística ao assegurar que registros vinculados a um mesmo identificador individual (PessoaID) nunca sejam compartilhados simultaneamente entre os conjuntos de treino e teste, provando a capacidade do *framework* em generalizar padrões comunicativos para indivíduos não observados durante o ajuste do modelo.

A avaliação qualitativa das Histórias Sociais multimodais geradas pelo módulo generativo segue um rigoroso protocolo de julgamento clínico. Cada artefato é submetido à análise de, no mínimo, três especialistas com experiência em intervenção comunicativa no TEA. A avaliação utiliza



uma Escala Likert de 5 pontos (variando de 1-Muito inadequado a 5-Totalmente adequado) baseada em três critérios centrais:

1. Coerência semântica: verifica se a narrativa mantém a lógica contextual do desastre (inundação).
2. Adequação ao nível comunicativo: avalia se a complexidade da linguagem e os suportes visuais (como o PECS) são compatíveis com o perfil predito.
3. Plausibilidade clínica: atesta se a estratégia pedagógica proposta é segura e acionável para o usuário autista.

A MARSOCH disponibiliza livremente o conjunto de suas informações em repositório virtual, visando a transparência e a replicabilidade, a saber:

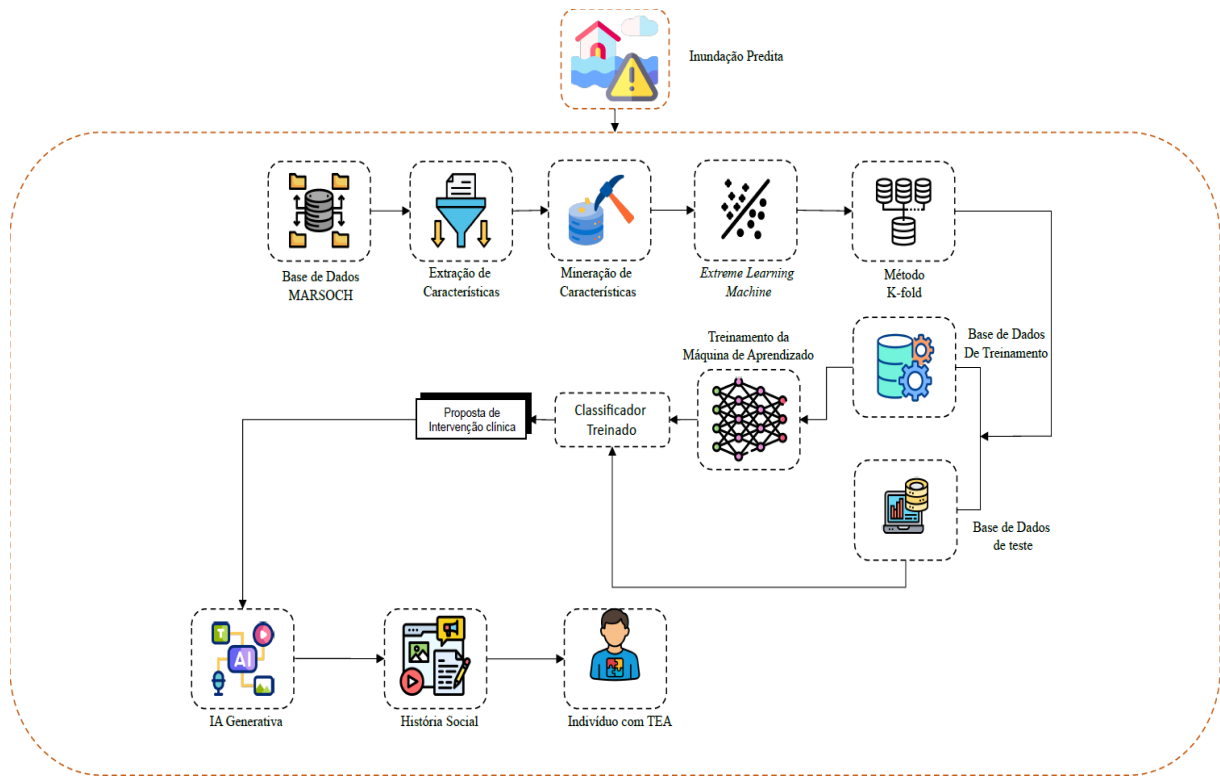
- Atributos estruturados (níveis, funções, ambientes e suportes);
- Descrições comportamentais para processamento de linguagem natural (NLP);
- Planos de intervenção e planos guia validados estruturalmente.

Conclui-se que a metodologia adotada viabiliza o aprimoramento da comunicação inclusiva em Sistemas de Alerta Precoce (SAP), preenchendo a falha crítica da "última milha" comunicacional.

4. METODOLOGIA PROPOSTA

A Figura 1 exibe a metodologia proposta em diagrama de blocos. Inicialmente, o perfil comunicativo do indivíduo, oriundo da base de dados MARSOCH, é processado com o objetivo de estimar as capacidades cognitivas e sensoriais fundamentadas na Matriz de Comunicação. Então, as características estruturadas (codificadas por frequência) e semânticas (extraídas via *Sentence-BERT*) dos registros são organizadas no formato de um repositório para aprendizado de máquina. Como método de mineração de características (*features mining*), utiliza-se uma estratégia baseada em combinações categóricas para identificar interações funcionais e associações estatísticas que não emergem da análise isolada de atributos. O critério adotado de mineração diz respeito à identificação de padrões de concorrência entre níveis e funções comunicativas, permitindo que regularidades clínicas sirvam como informações auxiliares no processo decisório. Após a mineração de características, os comportamentos e associações relevantes servem como atributos de entrada das máquinas de aprendizado estatístico, especificamente um *ensemble* de *Extreme Learning Machines* (ELM), empregadas como classificadores. O objetivo é agrupar os perfis em diferentes classes de Planos de Intervenção, garantindo que a estimativa resulte em uma recomendação clínica calibrada para a posterior geração da História Social multimodal.

Figura 1. PROTEA-M



Fonte: Autor

4.1. Especificação técnica da base de dados MARSOCH

A MARSOCH sistematiza a transposição de conceitos clínicos da Matriz de Comunicação para um formato computacional estruturado, permitindo o treinamento e a validação do *framework* PROTEA-M. Para garantir a transparência metodológica, os campos da base foram organizados em quatro dimensões críticas: Identificação, Perfil Comunicativo, Contexto de Suporte e Variáveis de Decisão.

4.1.1. Dimensão de perfil comunicativo

Estes atributos mapeiam a competência funcional e simbólica do indivíduo, servindo como as principais características de entrada para o classificador:

- **Nível Comunicativo (NivelComunicacao):** Representa o estágio de desenvolvimento funcional, categorizado em quatro níveis progressivos: pré-simbólico, emergente, simbólico inicial e simbólico avançado.
- **Função Comunicativa (FuncaoComunicativa):** Identifica a finalidade pragmática da interação observada, como as intenções de pedir (obter objetos ou ações), informar (compartilhar comentários) ou socializar (interação social conjunta).



- **Meio de Comunicação (FormaPreferida):** Descreve a modalidade expressiva predominante, abrangendo desde o uso de gestos e vocalizações até sistemas de Comunicação Aumentativa e Alternativa (CAA) simbólica ou abordagens multimodais.

4.1.2. Dimensão de contexto e suporte

Variáveis que condicionam a eficácia da comunicação em ambientes ecológicos:

- **Suporte Necessário (SuporteNecessario):** Quantifica o nível de mediação requerido pelo indivíduo para se comunicar de forma funcional, variando de "Nenhum" até "Assistência Integral".
- **Parceiro Comunicacional (ParceiroComunicacional):** Identifica o interlocutor envolvido na interação (e.g., familiar, professor, profissional de saúde ou agente institucional), dado essencial para prever a resposta em situações de crise.
- **Ambiente de Comunicação (Ambiente):** Contextualiza o local da observação, incluindo cenários domésticos, escolares, clínicos e, especificamente, cenários simulados de emergência, fundamentais para a preparação em desastres.

4.1.3. Evidência comportamental e decisão

- **Descrição de Comportamento (DescricaoComportamento):** Campo de texto livre destinado ao registro das evidências empíricas observadas pelo terapeuta. Este atributo é fundamental para o processamento de linguagem natural, permitindo a extração de *embeddings* semânticos via Sentence-BERT para enriquecer a representação vetorial do indivíduo.
- **Plano de Intervenção (PlanoIntervencao):** Constitui a variável-alvo (rótulo) do modelo, representando a estratégia pedagógica recomendada com base na avaliação.
- **Plano Guia (PlanoGuia):** Atributo de natureza estratégica que fornece diretrizes clínicas de nível superior, utilizado no *framework* para a calibração probabilística da decisão final, assegurando coerência entre o perfil predito e a conduta sugerida.

A Tabela 2 sintetiza a estrutura da base MARSOCH, correlacionando os atributos técnicos aos eixos da Matriz de Comunicação.

Tabela 2. Estrutura da base de dados MARSOCH e correspondência com os eixos da Matriz de Comunicação

Campo da Base MARSOCH	Correspondência Clínica	Natureza do Dado
NivelComunicacao	Níveis de desenvolvimento	Categórico

FuncaoComunicativa	Funções pragmáticas	Categórico
FormaPreferida	Meios de comunicação	Categórico
SuporteNecessario	Nível de apoio e mediação	Categórico
ParceiroComunicacional	Interlocutor envolvido	Categórico
Ambiente	Local de observação	Categórico
DescricaoComportamento	Evidências empíricas	Textual (NLP)
PlanoIntervencao	Estratégia recomendada	Rótulo (<i>Target</i>)
PlanoGuia	Diretriz hierárquica	Auxiliar

Fonte: Autor

4.2. Extração de características

Esta etapa descreve o processo de preparação e transformação dos registros da base MARSOCH em uma representação vetorial híbrida (x_i), adequada ao treinamento do pipeline de aprendizado de máquina. O PROTEA-M integra dois blocos distintos de informação: atributos estruturados, oriundos das categorias da avaliação comunicativa, e atributos não estruturados, provenientes das descrições textuais do comportamento.

4.2.1. Codificação de atributos estruturados por frequência

Os atributos categóricos fundamentados na Matriz de Comunicação são transformados via codificação por frequência (*frequency encoding*). Esta técnica mitiga a alta dimensionalidade e a esparsidade inerentes ao processo, favorecendo a estabilidade estatística de classificadores em bases de dados de tamanho moderado. A frequência relativa de cada categoria é estimada exclusivamente no conjunto de treinamento (D_{tr}) para evitar o vazamento de informação (*data leakage*), conforme a Equação (1).

$$freq(v) = \frac{1}{N_{tr}} \sum_{j \in D_{tr}} \mathbb{I}(v_j = v) \quad (1)$$

Onde $freq(v)$ representa a frequência relativa da categoria v , N_{tr} corresponde ao número total de instâncias do conjunto de treinamento D_{tr} , j indexa essas instâncias, v_j indica o valor da variável categórica na instância j , $\mathbb{I}(v_j = v)$ é a função indicadora que assume valor 1 quando a condição é satisfeita e 0 caso contrário, e o somatório $\sum_{j \in D_{tr}}$ contabiliza o número de ocorrências da categoria v no conjunto de treinamento.

4.2.2. Representação Semântica via *Sentence-BERT*

As evidências textuais do campo **DescricaoComportamento** são convertidas em representações vetoriais densas utilizando o modelo *Sentence-BERT* (SBERT). O modelo define uma função de mapeamento $\Phi: S \rightarrow \mathbb{R}^{768}$ extraíndo nuances contextuais de sentenças clínicas curtas que superam limitações de abordagens léxicas tradicionais. O *embedding* normalizado e_i^{SBERT} :

$$e_i^{SBERT} = Norm(\Phi(s_i)) \quad (2)$$

4.2.3. Formalização do Vetor de Características (x_i)

O vetor de entrada final resulta da concatenação entre as frequências dos atributos estruturados e o *embedding* semântico, conforme a Equação (3)

$$x_i = [Atributos_{freq} \parallel e_i^{SBERT}] \quad (3)$$

Nesta arquitetura, os campos de identificação e os rótulos de desfecho (**PlanoIntervencao** e **PlanoGuia**) são omitidos da entrada, sendo reservados para a supervisão e calibração do modelo.

4.3. Mineração de características

Diferentemente da extração, que converte dados brutos em vetores, a etapa de mineração busca identificar interações funcionais e associações estatísticas entre variáveis já estruturadas. No contexto do PROTEA-M, assume-se que a competência comunicativa não emerge de atributos isolados, mas da combinação entre níveis de desenvolvimento e funções pragmáticas.

4.3.1. Mineração baseada em combinações categóricas

A unidade básica de mineração é o vetor de atributos categóricos c_i , que reúne os principais eixos conceituais da Matriz de Comunicação associados à instância i .

$$c_i = [NivelComunicacao_i, FuncaoComunicativa_i, Ambiente_i, ParceiroComunicacional_i, Suporte_i, FormaPreferida_i]$$

A mineração quantifica a relevância clínica de cada perfil através da probabilidade condicional empírica da classe (plano de intervenção) dada uma combinação específica. Esta relação é formalizada pela Equação (4).

$$P_{emp}(y | c) = \frac{\sum_{j \in D_{tr}} \mathbb{I}(c_i = c \wedge y_i = y)}{\sum_{i \in D_{tr}} \mathbb{I}(c_i = c) + \alpha \cdot ||\gamma||} \quad (4)$$

Onde $P_{emp}(y | c)$ representa a probabilidade condicional da classe y dado o perfil comunicativo c ajustada por suavização, D_{tr} corresponde ao conjunto de treinamento, i indexa as instâncias deste conjunto, c_i e y_i indicam, respectivamente, o perfil e a classe observados na instância i , $\mathbb{I}(\cdot)$ é a função indicadora que assume valor 1 quando a condição lógica é satisfeita e 0 caso contrário, α representa um mecanismo de *fallback* baseado em suavização de Laplace, garantindo que o sistema não produza probabilidades degeneradas em cenários de teste inéditos e $||\gamma||$ indica a cardinalidade do espaço de classes (estratégias de intervenção).

4.4. Ensemble de *extreme learning machine*

O núcleo de classificação do PROTEA-M fundamenta-se na *Extreme Learning Machine* (ELM). A escolha da ELM justifica-se por seu treinamento em forma fechada via regressão *ridge*, o que dispensa processos iterativos de *backpropagation* e garante alta eficiência computacional e capacidade de generalização em bases de dados clínicas de tamanho moderado. A solução analítica para a matriz de pesos de saída é obtida diretamente por B^* que é obtido pela Equação (5).

$$B^* = (H^T H + \lambda I_L)^{-1} H^T Y \quad (5)$$

Onde B^* representa a matriz ótima de pesos da camada de saída da *Extreme Learning Machine*; H^T corresponde à transposta da matriz de ativações da camada oculta; $H^T H$ define a matriz de correlação das ativações ocultas; λ representa o parâmetro de regularização *ridge* utilizado para reduzir sobreajuste; I_L corresponde à matriz identidade de dimensão $L \times L$; L representa a quantidade de neurônios na camada oculta; $(H^T H + \lambda I_L)^{-1}$ define a inversa regularizada utilizada na solução analítica do modelo; Y corresponde à matriz de rótulos codificados das amostras de treinamento; $H^T Y$ representa a projeção das ativações ocultas sobre os rótulos desejados; e a Equação (5) define a solução em forma fechada para estimação dos pesos de saída da ELM com regularização *ridge*.

Para aumentar a robustez das estimativas, o *framework* adota um aprendizado por *ensemble*, agregando as saídas de múltiplos modelos ELM independentes para gerar uma distribuição de probabilidade calibrada sobre os planos de intervenção.

4.4.1 Fusão e calibração probabilística

A fim de garantir que a recomendação do sistema seja clinicamente coerente, utiliza-se um mecanismo de fusão probabilística. Este mecanismo integra três fontes de informação: a probabilidade do classificador supervisionado (P_{ML}), a evidência empírica das combinações categóricas (P_{emp}) e as diretrizes do Plano Guia (P_{guia}) e pode ser formalizado conforme a Equação (6).

$$P(y | x_i, c_i, g_i) \propto P_{ML}(y | x_i) \cdot P_{emp}(y | c_i)^\beta \cdot P_{guia}(y | g_i)^\gamma \quad (6)$$

Onde $P(y | x_i, c_i, g_i)$ representa a probabilidade final da classe y para a instância i após a fusão multimodal das evidências; x_i corresponde ao vetor híbrido de características extraídas da instância; c_i representa a combinação categórica dos atributos comunicativos; g_i corresponde ao plano guia associado à instância; $P_{ML}(y | x_i)$ define a probabilidade predita pelo modelo de aprendizado de máquina a partir das características vetoriais; $P_{emp}(y | c_i)$ representa a probabilidade empírica obtida das combinações categóricas observadas na base de treinamento; $P_{guia}(y | g_i)$ corresponde à probabilidade condicionada ao plano guia clínico; β controla a influência da evidência empírica no processo de fusão; γ controla o peso da evidência proveniente do plano

guia; e o símbolo \propto indica que a distribuição final é proporcional ao produto ponderado das probabilidades antes do processo de normalização.

Posteriormente, as probabilidades são refinadas via *Temperature Scaling* para alinhar a confiança do modelo às frequências observadas, reduzindo tendências de superconfiança algorítmica, conforme abaixo:

$$z_T(x) = \frac{1}{T}z(x) \quad (7)$$

Onde $z_T(x)$ representa os *logits* escalonados pela temperatura; $z(x)$ corresponde ao vetor original de *logits* produzido pelo modelo antes da calibração; T representa o parâmetro de temperatura utilizado no processo de *temperature scaling*; e $\frac{1}{T}z(x)$ define o reescalonamento dos *logits* para ajuste da confiança preditiva.

$$\hat{p}_{T,c}(x) = \frac{\exp(z_c(x)/T)}{\sum_{k=1}^C \exp(z_k(x)/T)} \quad (8)$$

Onde $\hat{p}_{T,c}(x)$ corresponde à probabilidade calibrada da classe c para a instância x ; $\exp(z_c(x)/T)$ representa a exponenciação do *logit* escalonado da classe c ; $z_k(x)$ corresponde ao *logit* associado à classe k ; C representa o número total de classes do problema; $\sum_{k=1}^C \exp(z_k(x)/T)$ define o termo de normalização da função *softmax*; e a equação descreve o processo de calibração probabilística aplicado aos *logits* do modelo por meio de *temperature scaling*.

O fator $1/T$ atua de forma uniforme sobre todas as classes, preservando a ordem relativa dos escores e, conseqüentemente, mantendo inalterada a predição final do modelo ($\arg \max$); assim, o ajuste ocorre apenas no grau de concentração das probabilidades. Quando $T > 1$, há redução da magnitude efetiva dos *logits*, produzindo distribuições probabilísticas mais suaves e menos concentradas, aspecto relevante para reduzir a superconfiança algorítmica comum em modelos complexos; por outro lado, quando $0 < T < 1$, ocorre ampliação da separação entre os escores, tornando a distribuição mais concentrada na classe de maior probabilidade.

4.5. Estratégia de particionamento da base

Para garantir a integridade estatística e a capacidade de generalização do PROTEA-M, a base MARSCH foi organizada por meio de validação cruzada aninhada (*nested cross-validation*) com abordagem *group-aware*. Essa estratégia evita que registros do mesmo indivíduo (PessoalD) apareçam ao mesmo tempo nos conjuntos de treinamento e teste, reduzindo viés na avaliação do modelo.

Em cada dobra (*fold*) do processo experimental, os dados são divididos em subconjuntos destinados ao treinamento do modelo (D_{fit}) e à calibração probabilística (D_{cal}). O parâmetro de temperatura T é estimado em um conjunto de *holdout* composto por indivíduos não utilizados no treinamento do classificador. Portanto, o valor ótimo da temperatura (T^*) é obtido pela minimização

da perda de log-verossimilhança negativa (entropia cruzada), conforme apresentado na Equação (9):

$$T^* = \arg \min_{T>0} \left(- \sum_{(x_i, y_i) \in D_{cal}} \log \hat{p}_{T, y_i}(x_i) \right) \quad (9)$$

Onde T^* representa o valor de temperatura que melhor ajusta a confiabilidade probabilística do modelo; D_{cal} corresponde ao conjunto reservado para calibração; x_i representa o vetor de características da instância i ; y_i indica o rótulo real associado; e $\log \hat{p}_{T, y_i}(x_i)$ corresponde à log-probabilidade calibrada atribuída à classe correta após o reescalonamento dos *logits*.

O uso do subconjunto de *holdout* permite estimar os parâmetros probabilísticos em dados não utilizados no treinamento do classificador, reduzindo efeitos de superconfiança. Dessa forma, as probabilidades calibradas passam a representar com maior fidelidade as frequências observadas nos dados, fornecendo uma base mais confiável para a etapa de fusão de evidências clínicas.

4.6. Integração preditiva-generativa

Esta etapa constitui o estágio final do processamento preditivo, onde ocorre a síntese das diferentes fontes de conhecimento para a definição da estratégia de intervenção. A fusão de evidências assegura que a recomendação do sistema não dependa exclusivamente de correlações estatísticas, mas seja ancorada em diretrizes clínicas estratégicas.

4.6.1 Síntese probabilística e tomada de decisão

A decisão final sobre o plano de intervenção resulta da integração multimodal detalhada na Equação (6). O desfecho deste processo é a identificação da classe recomendada \hat{y}_i , que maximiza a probabilidade posterior condicional, conforme a lógica de inferência do framework. Esta recomendação clínica é o parâmetro central que guiará o conteúdo pedagógico da narrativa a ser gerada.

4.6.2. Formalização da entrada global (I_i)

Para viabilizar a transição entre os módulos, o PROTEA-M consolida as informações individuais, contextuais e preditivas em uma estrutura única denominada Entrada Global (I_i). Esta estrutura funciona como a entrada formal do módulo generativo, garantindo que a História Social sintetizada seja clinicamente coerente com as necessidades do usuário, conforme a Equação (10):

$$I_i = (\pi_i, d, \ell, \tilde{y}_i, \hat{p}_i) \quad (10)$$

Onde I_i representa a entrada formal do módulo generativo para a instância i ; π_i corresponde ao perfil individual estruturado (contendo atributos comunicativos e contextuais); d define o contexto de risco ou tipo de desastre considerado (e.g., inundação); ℓ indica o idioma de geração da narrativa;

\tilde{y}_i representa a recomendação preditiva associada à instância (o plano de intervenção); e \hat{p}_i corresponde à distribuição de probabilidade calibrada sobre o espaço de classes.

4.7. Módulo generativo: síntese de histórias sociais multimodais

O módulo generativo do PROTEA-M é responsável por converter a Entrada Global (I_i) em um artefato comunicacional acessível, traduzindo as recomendações clínicas e o contexto de risco em uma narrativa estruturada. O processo é orientado utilizando modelos de linguagem de grande escala (LLMs) para garantir que o conteúdo seja condicionado ao nível simbólico e às necessidades sensoriais do indivíduo.

4.7.1. Geração do roteiro narrativo

A primeira etapa do módulo consiste na síntese do roteiro textual em formato estruturado (JSON). O sistema utiliza uma função de geração $P_{json}: I \rightarrow H$, que recebe a entrada global e produz uma sequência de painéis narrativos. Cada painel $p_{i,j}$ é formalizado por um conjunto de atributos que definem o título, a descrição narrativa, o apoio comunicativo e o foco de atenção, garantindo a coesão pedagógica da história.

4.7.2. Especificação visual e síntese multimodal

Para reduzir a ambiguidade inerente a cenários de desastre, o *framework* converte o roteiro em uma especificação visual unificada (s_i). Esta especificação resulta da concatenação entre as diretrizes de estilo condicionadas ao idioma e ao risco, e os *prompts* de imagem de cada painel, conforme a Equação (11):

$$s_i = \text{Concat}(\text{Style}(\ell, d), \{\text{prompt_imagem}_{i,j}\}_{j=1}^{N_i}) \quad (11)$$

Onde s_i representa a especificação textual global enviada ao provedor de geração visual; $\text{Style}(\ell, d)$ define as instruções de estilo e restrições visuais baseadas no idioma ℓ e no tipo de desastre d ; N_i indica a cardinalidade de painéis; e $\text{prompt_imagem}_{i,j}$ corresponde à descrição visual do j -ésimo painel. Este processo garante a coerência temática e a adequação estética necessária para evitar gatilhos de sobrecarga sensorial no usuário autista.

4.7.3. Organização de *layout* e persistência

A etapa final compreende a organização espacial da História Social em uma grade retangular configurada de acordo com o número de painéis (N_i), visando maximizar a previsibilidade da leitura. O artefato final é formalizado pelo objeto H_i , que integra metadados de rastreabilidade, o perfil individual, a sequência de painéis e um identificador de persistência (κ_i), conforme a Equação (12):

$$H_i = (\text{meta}_i, \pi_i, P_i, \kappa_i) \quad (12)$$



Onde H_i é o objeto final da História Social multimodal; $meta_i$ contém os metadados da geração; π_i é o perfil individual; P_i representa a sequência ordenada de painéis visuais e textuais; e κ_i é o identificador persistente que permite a recuperação do material nos repositórios do sistema. Com a consolidação deste objeto, o PROTEA-M encerra o ciclo de atendimento à “última milha” da comunicação de risco, entregando um suporte de compreensão personalizado e clinicamente fundamentado.

5. RESULTADOS E DISCUSSÕES

O *framework* PROTEA-M foi submetido a uma avaliação exaustiva contemplando o desempenho preditivo, a qualidade estatística e a adequação funcional da geração multimodal. Os experimentos seguiram um protocolo de validação cruzada aninhada *group-aware*, garantindo que os resultados reflitam a capacidade de generalização para indivíduos não observados durante o treinamento.

5.1. Parâmetros de execução

5.1.1. Configurações do módulo preditivo

O módulo preditivo utilizou a base MARSOCH com 200 registros validados clinicamente. A validação seguiu *nested cross-validation group-aware* por PessoaID, com 5 dobras externas e 3 internas. O particionamento utilizou 20% para teste externo e 80% para treinamento, sendo 64% para ajuste do modelo (Dfit) e 16% para calibração (Dcal). As características combinaram atributos categóricos codificados por frequência e embeddings SBERT de dimensão 768 com normalização ℓ_2 . A busca em grade avaliou ativações ReLU, LeakyReLU, ELU, SELU e Swish, neurônios ocultos $L=\{200,300,400,500,600,700,800,900,1000\}$ e $\lambda=\{10^{-4},10^{-3},10^{-2},10^{-1}\}$. A melhor configuração foi $L^*=600$, Swish e $\lambda^*=10^{-3}$. O treinamento utilizou *label smoothing* ($\epsilon=0,05$), ensemble com 25 ELMs, *temperature scaling* entre 0,50 e 3,00, suavização de Laplace $\alpha=1$ e pesos $\beta=1$ e $\gamma=1$.

5.1.2. Configurações do módulo generativo

Foram gerados 3 indivíduos por dobra externa (n_{sol}), com seleção aleatória e semente fixa $s=42$. Os testes utilizaram cenários de inundação em português brasileiro via OpenAI API.

5.1.3. Ambiente computacional

Os experimentos utilizaram Intel Core i9-10850K, 64 GB DDR4, NVIDIA RTX 3060 12 GB, Windows 11 Pro e Python 3.10.


5.1.4. Testes estatísticos

A comparação com SVM, KNN e Decision Tree utilizou $\alpha=0,05$, testes t pareado, Wilcoxon, McNemar, Shapiro-Wilk, permutação por inversão de sinais e tamanho de efeito dz de Cohen.

5.2. Módulo Preditivo

O núcleo preditivo do PROTEA-M (método FINAL) alcançou uma acurácia mediana de 0,6923 no conjunto de teste, apresentando um intervalo interquartil reduzido (0,0500), o que demonstra alta estabilidade entre as dobras de validação. Em contraste, modelos tradicionais como o KNN e o SVM apresentaram desempenhos significativamente inferiores, com acurácias medianas de 0,0750 e 0,2250, respectivamente. Embora a Árvore de Decisão (DT) tenha atingido uma acurácia central competitiva (0,7000), sua alta dispersão (IQR de 0,1323) revela instabilidade e maior sensibilidade à composição dos dados de treino em comparação ao modelo proposto.

Figura 2. Acurácia por método




Fonte: Autor

5.2.1. Capacidade discriminativa e recuperação de classes

A robustez do sistema é reforçada pelos resultados de ROC-AUC (0,9782) e PR-AUC (0,8557), que indicam uma separação quase perfeita entre classes corretas e incorretas no ranqueamento das probabilidades. O valor elevado da PR-AUC é particularmente relevante, pois confirma a eficácia do PROTEA-M em lidar com o desbalanceamento de classes da base MARSOCH, mantendo alta precisão mesmo em estratégias de intervenção menos frequentes. O teste de McNemar confirmou, com significância estatística ($p < 1 \times 10^{-300}$), que o FINAL realiza um número superior de correções de erro em relação aos modelos de base.


20

Figura 3. PR-AUC



Fonte: Autor

Figura 4. ROC-AUC



Fonte: Autor

5.2.2. Confiabilidade probabilística e padrões de erro


Diferentemente de classificadores de “caixa-preta”, o uso de *Temperature Scaling* permitiu que o modelo fornecesse estimativas de incerteza calibradas, com um

21

32

Brier Score de 0,4597. A análise da matriz de confusão revela que os erros do sistema são semanticamente coerentes, ocorrendo majoritariamente entre níveis adjacentes de protocolos clínicos (como as fases do PECS), o que mitiga o impacto pedagógico de uma eventual classificação incorreta. Adicionalmente, a métrica Top-3 Accuracy atingiu o valor unitário (1,0000), assegurando que o plano de intervenção correto esteja invariavelmente entre as três primeiras recomendações.

Figura 3. Matriz de Confusão



Fonte: Autor

5.2.3 Teste t de Student

O teste t pareado avalia se a média das diferenças pareadas entre dois métodos difere de zero, sob a suposição de normalidade dos deltas.

Figura 6. Resultado teste t de Student

Comparação	<i>t</i>	<i>p</i> -valor	<i>n</i>	Δ ACC	IC95%	Decisão
FINAL vs ELM Plain	11.91	2.85×10^{-4}	5	0.4696	[0.3602, 0.5791]	Rejeita H_0
FINAL vs SVM	10.27	5.07×10^{-4}	5	0.4400	[0.3211, 0.5589]	Rejeita H_0
FINAL vs KNN	58.51	5.11×10^{-7}	5	0.6202	[0.5907, 0.6496]	Rejeita H_0
FINAL vs DT	1.22	2.88×10^{-1}	5	0.0696	[-0.0882, 0.2274]	Não rejeita H_0

Fonte: Autor

A comparação entre FINAL e ELM Plain apresentou $t=11,91$ e $p=2,85 \times 10^{-4}$, indicando diferença estatisticamente significativa. O ganho médio de acurácia foi Δ ACC=0,4696, com IC95% [0,3602, 0,5791], evidenciando superioridade consistente do FINAL e impacto positivo da fusão de evidências e calibração. Na comparação com o SVM, o FINAL também apresentou desempenho superior, com $t=10,27$, $p=5,07 \times 10^{-4}$ e Δ ACC=0,4400. O IC95% [0,3211, 0,5589] confirma estabilidade do ganho entre os folds.

Contra o KNN, o FINAL obteve a maior diferença observada, com $t=58,51$, $p=5,11 \times 10^{-7}$ e Δ ACC=0,6202. O IC95% [0,5907, 0,6496] mostra um ganho elevado e estável, reforçando a capacidade do modelo em lidar com representações complexas.

Na comparação com a DT, o resultado foi menos expressivo, com $t=1,22$ e $p=2,88 \times 10^{-1}$. Apesar da diferença média positiva (Δ ACC=0,0696), o IC95% [-0,0882, 0,2274] inclui zero, indicando ausência de significância estatística. Ainda assim, o FINAL manteve vantagem média frente ao método mais competitivo entre os *baselines*.

5.2.4. Teste de normalidade de Shapiro-Wilk

O teste de Shapiro-Wilk avalia a aderência dos deltas de desempenho à distribuição normal, permitindo verificar se a hipótese de normalidade é plausível para os dados analisados.

Comparação	Estatística W	p -valor	n	Interpretação
FINAL vs ELM Plain	0.8935	3.75×10^{-1}	5	Compatível com normalidade
FINAL vs SVM	0.8935	3.75×10^{-1}	5	Compatível com normalidade
FINAL vs KNN	0.8935	3.75×10^{-1}	5	Compatível com normalidade
FINAL vs DT	0.8935	3.75×10^{-1}	5	Compatível com normalidade

O teste de Shapiro-Wilk aplicado aos deltas de acurácia apresentou $W=0,8935$ em todas as comparações, com $p=3,75 \times 10^{-1}$. Como o p -valor permaneceu acima do nível de significância adotado, os resultados indicam compatibilidade dos deltas com a normalidade.

Esse comportamento mostra que os ganhos de acurácia do FINAL se distribuíram de forma estável entre os folds, sem forte influência de casos extremos ou distribuições assimétricas. A estabilidade do valor de W entre as comparações reforça a consistência dos resultados obtidos.

Além disso, a compatibilidade com normalidade fornece suporte ao uso do teste t pareado nas análises subsequentes, tornando estatisticamente válidas as comparações paramétricas realizadas.

Em conjunto, os resultados do teste de Shapiro-Wilk fortalecem a robustez das análises estatísticas e sustentam que a superioridade do FINAL decorre de ganhos consistentes ao longo das partições avaliadas.

5.2.5. Teste de McNemar

O teste de McNemar compara dois classificadores em nível de instância por meio das discordâncias observadas entre suas predições, avaliando a existência de diferença estatística nas decisões individuais produzidas pelos modelos.

Comparação	b	c	n	p -valor	Decisão
FINAL vs ELM Plain	6	100	106	$< 1 \times 10^{-300}$	Rejeita H_0
FINAL vs SVM	11	99	110	1.11×10^{-16}	Rejeita H_0
FINAL vs KNN	3	127	130	$< 1 \times 10^{-300}$	Rejeita H_0
FINAL vs DT	12	26	38	3.50×10^{-2}	Rejeita H_0

O teste de McNemar aplicado às previsões em teste mostra que o método FINAL supera todos os métodos de referência no nível de amostra. Os valores de b e c indicam,



respectivamente, os casos em que o método de referência acerta e o FINAL erra, e os casos em que o FINAL acerta e o método de referência erra.

Na comparação com o ELM Plain, os valores $b = 6$ e $c = 100$ mostram ampla vantagem do FINAL, com $p\text{-valor} < 1 \times 10^{-300}$. Contra o SVM, $b = 11$ e $c = 99$, também com diferença estatisticamente significativa ($p = 1,11 \times 10^{-16}$). Frente ao KNN, a diferença é ainda maior, com $b = 3$ e $c = 127$ e $p\text{-valor} < 1 \times 10^{-300}$. Na comparação com a DT, o FINAL mantém vantagem, com $b = 12$ e $c = 26$ e $p = 3,50 \times 10^{-2}$.

Em conjunto, os resultados indicam que o FINAL corrige mais erros que todos os métodos avaliados, apresentando superioridade estatisticamente significativa em todas as comparações.

5.3. Módulo generativo

O módulo generativo converteu as predições em Histórias Sociais multimodais que demonstraram alta aderência ao perfil clínico individual e ao contexto de inundação. A análise qualitativa confirmou que a complexidade narrativa e os suportes visuais foram ajustados corretamente: perfis com nível comunicativo emergente receberam histórias focadas em trocas básicas e pedidos de ajuda simples, enquanto perfis simbólicos avançados receberam roteiros com maior detalhamento procedimental. Este encadeamento preditivo-generativo reduz a arbitrariedade na construção de materiais educativos para o TEA.

Os resultados abaixo mostram que cada quadro da história social mantém relação com o perfil comunicativo previsto e com o plano PECS Fase II e III. O primeiro quadro apresenta o conceito de inundação com figuras simples e apoio familiar, compatível com o nível simbólico inicial e suporte moderado. O segundo associa sinais de alerta à discriminação de cartões PECS e ao pedido de ajuda. O terceiro organiza ações funcionais por trocas sucessivas de cartões, explorando distância e combinação simbólica. O quarto apresenta estratégias de regulação emocional com recursos visuais e sensoriais para apoiar a comunicação de necessidades internas. O quinto reforça consolidação e generalização por meio de revisão visual da experiência. Em conjunto, os quadros mostram que o módulo generativo traduz o plano preditivo em cenas estruturadas que favorecem comunicação funcional, previsibilidade e segurança em contexto domiciliar de inundação.

Figura 4. Resultado módulo generativo



Fonte: Autor

6. CONSIDERAÇÕES FINAIS

Diante dos resultados obtidos, conclui-se que o objetivo geral deste trabalho foi alcançado por meio da proposição, desenvolvimento e avaliação do *framework* PROTEA-M. Os experimentos demonstraram que a personalização de conteúdos de emergência, condicionada ao perfil funcional do indivíduo autista, constitui uma estratégia viável para ampliar compreensão, previsibilidade e prontidão em situações críticas, contribuindo para reduzir a lacuna existente na etapa de disseminação dos sistemas de alerta precoce.

A hipótese central da pesquisa também foi confirmada, evidenciando que a integração entre o módulo preditivo e o módulo generativo possibilita a produção de mensagens multimodais mais coerentes, estruturadas e compatíveis com as necessidades de comunicação do usuário. Os resultados indicam que o encadeamento entre estimativa do perfil funcional e geração automatizada de Histórias Sociais reduz a subjetividade na elaboração dos materiais educativos e favorece a construção de narrativas alinhadas ao nível simbólico, às demandas sensoriais e às particularidades de pessoas com Transtorno do Espectro Autista.



No aspecto técnico, o PROTEA-M apresentou desempenho superior aos modelos de referência ao longo das avaliações realizadas. O *framework* alcançou acurácia de 0,6923 e ROC-AUC de 0,9782, demonstrando elevada capacidade discriminativa na recomendação de intervenções. Os testes estatísticos reforçaram a robustez dos resultados e indicaram superioridade significativa em relação aos métodos comparativos. Além disso, o módulo generativo demonstrou capacidade de transformar informações clínicas estruturadas da Matriz de Comunicação em conteúdos multimodais adaptados, produzindo sequências visuais e textuais consistentes com o perfil inferido.

Sob a perspectiva científica, o trabalho contribui para o avanço das pesquisas em comunicação acessível, Inteligência Artificial aplicada ao autismo e sistemas de alerta inclusivos. Destaca-se também a construção da base MARSOCH, que representa um recurso relevante para estudos futuros envolvendo modelagem preditiva e geração adaptativa de conteúdo no contexto do TEA. No âmbito social, o PROTEA-M apresenta potencial para apoiar famílias, cuidadores e profissionais, oferecendo uma alternativa escalável para personalização de conteúdos educativos e emergenciais.

Apesar dos resultados promissores, o estudo possui limitações relacionadas ao recorte linguístico em português brasileiro, ao contexto geográfico analisado e ao foco em cenários de inundação. Como perspectivas futuras, recomenda-se a integração do *framework* a sistemas reais de alerta precoce baseados no protocolo CAP, a ampliação da abordagem para outros tipos de desastres naturais e a incorporação de mecanismos de explicabilidade, visando ampliar transparência, interpretabilidade e confiança clínica nas recomendações produzidas pelo sistema.

REFERÊNCIAS

ABDULLAH, Maria et al. Artificial intelligence-based assistive technologies for autism spectrum disorder: a systematic review. **Journal of Autism and Developmental Disorders**, v. 52, n. 9, p. 4029-4050, 2022.

AHMED, S. et al. An optimized Kernel Extreme Learning Machine for the classification of the autism spectrum disorder by using gaze tracking images. **Applied Soft Computing**, v. 120, p. 108654, 2022. DOI: <https://doi.org/10.1016/j.asoc.2022.108654>.

BALOG-WAY, Dominic H. P.; MCCOMAS, Katherine A.; BESLEY, John C. The evolving field of risk communication. **Risk Analysis**, v. 40, n. S1, p. 2240-2262, 2020. DOI: <https://doi.org/10.1111/risa.13615>



BASHER, Reid. Global early warning systems for natural hazards: systematic and people-centred. **Philosophical Transactions of the Royal Society A**, v. 364, n. 1845, p. 2167-2182, 2006. DOI: <https://doi.org/10.1098/rsta.2006.1819>.

BEUKELMAN, David R.; MIRENDA, Pat. **Augmentative and alternative communication: supporting children and adults with complex communication needs**. 4. ed. Baltimore: Paul H. Brookes Publishing, 2013.

BOGDASHINA, Olga. **Sensory perceptual issues in autism and Asperger syndrome: different sensory experiences, different perceptual worlds**. 2. ed. London: Jessica Kingsley Publishers, 2016.

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

BRIER, Glenn W. Verification of forecasts expressed in terms of probability. **Monthly Weather Review**, v. 78, n. 1, p. 1-3, 1950. DOI: [https://doi.org/10.1175/1520-0493\(1950\)078<0001:VOFEIT>2.0.CO;2](https://doi.org/10.1175/1520-0493(1950)078<0001:VOFEIT>2.0.CO;2).

BROWN, Tom et al. Language models are few-shot learners. **Advances in Neural Information Processing Systems**, v. 33, p. 1877-1901, 2020.

CENTERS FOR DISEASE CONTROL AND PREVENTION (CDC). **Data and statistics on autism spectrum disorder**. Atlanta: CDC, 2023. Disponível em: <https://www.cdc.gov/autism/data-research/index.html>. Acesso em: 25 maio 2026.

CERDA, Patricio; VAROQUAUX, Gaël; KÉGL, Balázs. Similarity encoding for learning with dirty categorical variables. **Machine Learning**, v. 107, p. 1477-1494, 2018. DOI: <https://doi.org/10.1007/s10994-018-5724-2>.

COHEN, Jacob. A coefficient of agreement for nominal scales. **Educational and Psychological Measurement**, v. 20, n. 1, p. 37-46, 1960. DOI: <https://doi.org/10.1177/001316446002000104>.

CORTES, Corinna; VAPNIK, Vladimir. Support-vector networks. **Machine Learning**, v. 20, p. 273-297, 1995. DOI: <https://doi.org/10.1007/BF00994018>.

COVER, Thomas; HART, Peter. Nearest neighbor pattern classification. **IEEE Transactions on Information Theory**, v. 13, n. 1, p. 21-27, 1967. DOI: <https://doi.org/10.1109/TIT.1967.1053964>.

DIETTERICH, Thomas G. Ensemble methods in machine learning. In: **MULTIPLE CLASSIFIER SYSTEMS**. Berlin: Springer, 2000. p. 1-15. DOI: https://doi.org/10.1007/3-540-45014-9_1.

ELDAWLATLY, Abdelazeem. Writing the methods section. **Saudi Journal of Anaesthesia**, v. 13, supl. 1, p. S10-S11, 2019. DOI: https://doi.org/10.4103/sja.SJA_685_18.

FAWCETT, Tom. 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>.

FAYYAD, Usama; PIATETSKY-SHAPIRO, Gregory; SMYTH, Padhraic. From data mining to knowledge discovery in databases. **AI Magazine**, v. 17, n. 3, p. 37-54, 1996. DOI: <https://doi.org/10.1609/aimag.v17i3.1230>.



FENG, Yi et al. SS-GEN: a social story generation framework with large language models. In: **Proceedings of the AAAI Conference on Artificial Intelligence**. v. 39, n. 2, p. 1300-1308, 2025.

FRITH, Uta. **Autism: explaining the enigma**. Oxford: Blackwell, 2003.

GRAY, Carol. **The new social story book**. 10. ed. Arlington: Future Horizons, 2010.

GUO, Chuan et al. On calibration of modern neural networks. In: **International Conference on Machine Learning**. [S.l.]: PMLR, 2017. p. 1321-1330.

HASTIE, Trevor; TIBSHIRANI, Robert; FRIEDMAN, Jerome. **The elements of statistical learning**. 2. ed. New York: Springer, 2009.

HOERL, Arthur E.; KENNARD, Robert W. Ridge regression: biased estimation for nonorthogonal problems. **Technometrics**, v. 12, n. 1, p. 55-67, 1970. DOI: <https://doi.org/10.1080/00401706.1970.10488634>.

HUANG, Guang-Bin; ZHU, Qin-Yu; SIEW, Chee-Kheong. Extreme learning machine: theory and applications. **Neurocomputing**, v. 70, n. 1-3, p. 489-501, 2006. DOI: <https://doi.org/10.1016/j.neucom.2005.12.126>.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Censo Demográfico 2022**. Rio de Janeiro: IBGE, 2022. Disponível em: <https://www.ibge.gov.br>. Acesso em: 25 maio 2026.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC). **Climate change 2023: synthesis report**. Geneva: IPCC, 2023. Disponível em: <https://www.ipcc.ch/report/ar6/syr/>. Acesso em: 25 maio 2026.

KENT, Rachel et al. Preparing for emergencies among families of children with autism spectrum disorder. **Journal of Autism and Developmental Disorders**, v. 43, n. 3, p. 666-675, 2013. DOI: <https://doi.org/10.1007/s10803-012-1618-0>.

KOHAVI, Ron. A study of cross-validation and bootstrap for accuracy estimation and model selection. In: **International Joint Conference on Artificial Intelligence**. San Francisco: Morgan Kaufmann, 1995. p. 1137-1145.

KOHONEN, Teuvo. **Self-organizing maps**. 3. ed. Berlin: Springer, 2001.

KOKINA, Anastasia; KERN, Lee. Social story interventions for students with autism spectrum disorders: a meta-analysis. **Journal of Autism and Developmental Disorders**, v. 40, n. 7, p. 812-826, 2010. DOI: <https://doi.org/10.1007/s10803-009-0931-0>.

LINDELL, Michael K.; PERRY, Ronald W. The protective action decision model: theoretical modifications and additional evidence. **Risk Analysis**, v. 32, n. 4, p. 616-632, 2012. DOI: <https://doi.org/10.1111/j.1539-6924.2011.01647.x>.

LUNDGREN, Regina E.; MCKIN, Andrea H. **Risk communication: a handbook for communicating environmental, safety, and health risks**. 6. ed. Hoboken: Wiley, 2018.



LUNDBERG, Scott M.; LEE, Su-In. A unified approach to interpreting model predictions. In: **Advances in Neural Information Processing Systems**, 2017.

MICCI-BARRECA, Daniele. A preprocessing scheme for high-cardinality categorical attributes in classification and prediction problems. **ACM SIGKDD Explorations Newsletter**, v. 3, n. 1, p. 27-32, 2001. DOI: <https://doi.org/10.1145/507533.507538>.

MILETI, Dennis S.; SORENSEN, John H. **Communication of emergency public warnings**. Oak Ridge: ORNL, 1990.

NAEINI, Mahdi Pakdaman; COOPER, Gregory; HAUSKRECHT, Milos. Obtaining well calibrated probabilities using Bayesian binning. In: **AAAI Conference on Artificial Intelligence**. 2015. p. 2901-2907.

PEEK, Lori; STOUGH, Laura. Children with disabilities in the context of disaster: a social vulnerability perspective. **Child Development**, v. 81, n. 4, p. 1260-1270, 2010. DOI: <https://doi.org/10.1111/j.1467-8624.2010.01466.x>.

QUINLAN, J. Ross. Induction of decision trees. **Machine Learning**, v. 1, p. 81-106, 1986. DOI: <https://doi.org/10.1007/BF00116251>.

REIMERS, Nils; GUREVYCH, Iryna. Sentence-BERT: sentence embeddings using Siamese BERT-networks. In: **Conference on Empirical Methods in Natural Language Processing**. Hong Kong: ACL, 2019. p. 3982-3992. DOI: <https://doi.org/10.18653/v1/D19-1410>.

ROBERTSON, Caroline E.; BARON-COHEN, Simon. Sensory perception in autism. **Nature Reviews Neuroscience**, v. 18, n. 11, p. 671-684, 2017. DOI: <https://doi.org/10.1038/nrn.2017.112>.

ROWLAND, Charity. **Matriz de Comunicação**. Portland: Oregon Health & Science University, 2011.

RUTHERFORD, Marion et al. Visual supports at home and in the community for autistic children: a scoping review. **Autism**, v. 24, n. 7, p. 1737-1752, 2020. DOI: <https://doi.org/10.1177/1362361320901572>.

SAITO, Takaya; REHMSMEIER, Marc. The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets. **PLOS ONE**, v. 10, n. 3, e0118432, 2015. DOI: <https://doi.org/10.1371/journal.pone.0118432>.

SHAH, Ashfaq Ahmad et al. Community social barriers to non-technical aspects of flood early warning systems and NGO-led interventions: the case of Pakistan. **Frontiers in Earth Science**, v. 11, p. 1068721, 2023. DOI: <https://doi.org/10.3389/feart.2023.1068721>.

STOUGH, Laura M.; KELMAN, Ilan. **People with disabilities and disasters**. New York: Palgrave Macmillan, 2018.

SUTTON, Jeannette; TIERNEY, Kathleen. **Disaster preparedness: concepts, guidance, and research**. Boulder: University of Colorado, 2006.



TEST, David W. et al. Evidence-based practices for individuals with autism. **Exceptional Children**, v. 78, n. 2, p. 135-155, 2011. DOI: <https://doi.org/10.1177/001440291107800201>.

UNITED NATIONS CHILDREN'S FUND (UNICEF). **Disability-inclusive disaster risk reduction**. New York: UNICEF, 2023.

UNITED NATIONS OFFICE FOR DISASTER RISK REDUCTION (UNDRR). **Global assessment report on disaster risk reduction 2022**. Geneva: UN, 2022.

UNITED NATIONS OFFICE FOR DISASTER RISK REDUCTION (UNDRR). **Sendai framework for disaster risk reduction 2015-2030**. Geneva: UN, 2015.

VARMA, Sudhir; SIMON, Richard. Bias in error estimation when using cross-validation for model selection. **BMC Bioinformatics**, v. 7, n. 91, 2006. DOI: <https://doi.org/10.1186/1471-2105-7-91>.

VASWANI, Ashish et al. Attention is all you need. **Advances in Neural Information Processing Systems**, v. 30, 2017.

WORLD BANK. **Inclusive early warning systems: a lifeline for all**. Washington: World Bank, 2022.

WORLD METEOROLOGICAL ORGANIZATION (WMO). **State of the global climate 2021**. Geneva: WMO, 2021.