

Radar Institucional: uma arquitetura de referência com BERTimbau, QA Macro e MCDA para governança de dados sociais

Mayza Umbelina Fidelis da Silva ¹, Léo Walker da Silva ¹, Marlon Vinicius da Silva ¹

¹Faculdade de Ciências Exatas e Tecnológicas (FACET) – Universidade do Estado do Mato Grosso (UNEMAT). Campus de Cáceres Av. São João, n. 563 – Cavallhada I – CEP: 78.216-060 – Cáceres – MT – Brasil

mayza.silva@unemat.br, walker.leo@unemat.br, marlon.silva@unemat.br

Abstract. Higher Education Institutions use social networks as repositories of unstructured data. This paper proposes a conceptual reference architecture for converting unstructured social media data into actionable intelligence for multicampi universities. The Radar Institucional integrates BERTimbau-based NLP with the QA Macro audit protocol—defined as $QA-Macro(d) = f_3(f_2(f_1(d)))$ —enforcing sequenced anomaly filtering, syntactic deduplication, and human validation. Outputs are structured as KPIs for Multi-Criteria Decision Analysis (MCDA) using the AHP method. A controlled simulation demonstrates the framework's potential in a hypothetical scenario involving 500 posts about a cafeteria. The study discusses scalability, fine-tuning strategy, and architectural questions.

Resumo. Instituições de Ensino Superior utilizam redes sociais como repositórios de dados não estruturados. Este artigo propõe uma arquitetura de referência conceitual para converter dados não estruturados de redes sociais em inteligência para universidades multicampi. O Radar Institucional integra PLN via BERTimbau e o protocolo QA Macro—definido formalmente como $QA-Macro(d) = f_3(f_2(f_1(d)))$ —impondo filtragem de anomalias, deduplicação sintática e validação humana. As saídas são estruturadas como KPIs para Análise de Decisão Multicritério (MCDA) com método AHP. Uma simulação controlada demonstra o potencial do framework em cenário hipotético com 500 postagens sobre o restaurante universitário. O trabalho discute escalabilidade, estratégia de fine-tuning e questões em aberto.

1. Introdução

A expansão multicampi em universidades públicas gerou um volume de *feedback* nas redes sociais que ultrapassa a capacidade analítica humana, especialmente durante períodos de crise ou de alta demanda (como picos de matrícula ou greves) [Belli et al., 2024]. Embora modelos Transformer otimizem a Análise de Sentimentos, sua aplicação direta em decisões governamentais viola princípios de responsabilidade pública devido a riscos de *bots* e alucinações da IA [BRASIL, 2024]. Para possuir valor estratégico, os sentimentos extraídos precisam ser convertidos em KPIs confiáveis [Grande-Ramírez et al., 2022]. Para viabilizar essa integração, este trabalho propõe o “Radar Institucional”: um *framework* que funde NLP (BERTimbau), auditoria estatística (QA Macro) e Apoio Multicritério à Decisão (MCDA). Essa arquitetura atua como um “funil de confiança”, convertendo dados não estruturados em inteligência auditável para elevar a maturidade da governança universitária [Alves e Pantaleão, 2023].

2. Fundamentação Teórica

A eficácia do tratamento de dados de redes sociais está diretamente ligada à maturidade da governança informacional de uma instituição. Conforme as recentes diretrizes

governamentais [BRASIL, 2023; Belli et al., 2024], evitar que vieses algorítmicos influenciam o desenho de políticas públicas exige a adoção de métodos rigorosos de validação. A governança informacional no setor público deve assegurar integridade e procedência dos dados (Belli et al., 2024).

O BERTimbau (Souza et al., 2020) é BERT pré-treinado em português brasileiro, superando modelos multilíngues em domínios institucionais. Marreira e Melo (2023) demonstram aplicação prática do BERTimbau em predição de avaliações em português, focando em análise de sentimentos gerais sem camada de auditoria. Campos et al. (no prelo) propõem análise estruturada de sentimentos em português, mas sem integração à decisão multicritério. Silva et al. (2024) apresentam social listening corporativo com detecção parcial de anomalias, mas sem formalização de MCDA. O Radar Institucional diferencia-se ao integrar esses elementos em um fluxo unificado de governança. A auditoria algorítmica é crucial para evitar o "gap de responsabilidade" (Raji et al., 2020), especialmente em educação onde a adoção de IA saltou de 49% (2024) para 66% (2025) (EDUCAUSE, 2025). Detecção de bots em redes sociais usa Z-Score para anomalias comportamentais (Grubbs, 1969) e Levenshtein para conteúdo coordenado (Wang et al., 2010). O método AHP (Saaty, 1980) pondera critérios conflitantes em gestão universitária (Alves e Pantaleão, 2023).

Tabela 1. Comparação com Trabalhos Relacionados:

Trabalho	Técnica PLN	Auditoria?	MCDA?	Foco
Marreira e Melo(2023)	BERTimbau	Não	Não	Sentimentos gerais
Silva et al. (2024)	VADER	Parcial	Não	Social listening
Campos et al. (no prelo)	BERTimbau	Não	Não	Análise estruturada
Radar	BERTimbau	Sim (QA Macro)	Sim (AHP)	Governança univ.

3. Metodologia e Arquitetura

O Radar organiza-se em 4 camadas: Ingestão, Inferência, Governança e Decisão.




Figura 1. Arquitetura em 4 camadas do Radar Institucional.

3.1 Fine-tuning do BERTimbau

Corpus mínimo: 3.000 exemplos (positivo/negativo/neutro), funcional para prototipagem; trabalhos semelhantes utilizam 5.000-15.000 para estabilidade robusta (Marreira e Melo, 2023). Rotulagem com 2 anotadores ($\kappa \geq 0,80$, padrão PLN para publicações de impacto). Ambiente: Google Colab (GPU T4) ou RTX 3090/4090. Função de perda: Cross Entropy Loss. Hiperparâmetros: taxa 2×10^{-5} , batch 16, AdamW, dropout 0,1, divisão 80/10/10 com estratificação.

3.2 Protocolo QA Macro

$$\text{QA-Macro}(d) = f_3(f_2(f_1(d)))$$

- f_1 : Z-Score comportamental ($Z > 3$ isola bots)
- f_2 : Levenshtein normalizado ($< 0,15$ detecta coordenação)
- f_3 : Confiança do modelo ($p < 0,80$ vai para validação humana)

Limiares baseados em literatura: Z-Score (Grubbs, 1969), Levenshtein (Wang et al., 2010), confiança (sistemas de alta confiabilidade).

3.3 Estudo de Caso Simulado: Restaurante Universitário (RU)

Cenário: 500 postagens sobre RU em 7 dias.

Aplicação do QA Macro:

- Filtro 1: Bot com 50 postagens/minuto → $Z = 96 \rightarrow$ Isolado
- Filtro 2: 15 postagens idênticas → Detectadas como coordenadas
- Filtro 3: 30 postagens com confiança $< 0,80 \rightarrow$ Validação humana

Resultado: 410 postagens validadas (82% retenção)

Classificação: Negativas 43,9%, Neutras 36,6%, Positivas 19,5%

Tabela 2. Matriz AHP:

Critério	Peso	Qualidade	Preço	Higiene
		Score: 2,3	Score: 2,1	Score: 3,5
Gravidade	50%	1,15	1,05	1,75
Urgência	30%	0,69	0,63	1,05
Alinhamento	20%	0,46	0,42	0,70
Score Final	100%	2,30	2,10	3,50

RC = 0,08 ($< 0,10 \checkmark$). Recomendação: Priorizar qualidade e preço.

4. Análise Crítica e Limitações

Uma limitação conhecida do BERTimbau é a dificuldade em distinguir sarcasmo e ironia, que são frequentes em redes sociais universitárias. Postagens como "Que comida deliciosa!" dita ironicamente sobre o RU podem ser classificadas como positivas quando são na verdade negativas. Estudos indicam que modelos Transformer alcançam acurácia de 85-92% em análise de sentimentos em português (Marreira e Melo, 2023; Junqueira et al., 2023), mas essa taxa cai para 70-75% em contextos com alta densidade de figuras de linguagem. O Filtro 3 do QA Macro (validação humana com limiar 0,80) mitiga esse risco ao encaminhar classificações incertas para revisão, garantindo que sarcasmos não distorcem a análise final.

Tabela 3. Análise e Limitações:

Dimensão	Forças	Vulnerabilidades
Governança	QA Macro reduz ruídos/bots	Dependência de validação humana
Técnica	BERTimbau em português	Requer GPU para tempo real
Decisão	MCDA-AHP objetiva	Viés dos gestores nos pesos
Ética	Transparência e rastreabilidade	Exclui não-usuários de redes sociais
Escalabilidade	Modular e adaptável	Custos crescem com

		volume
--	--	--------

5. LGPD e Ética Algorítmica

O sistema armazena apenas hash da postagem, permitindo auditoria sem expor nomes. Ao receber solicitação de esquecimento (Art. 18, LGPD): (1) identifica postagens via hash, (2) remove dados brutos, (3) mantém agregados anônimos, (4) preserva logs de conformidade. O Radar funciona como "sensor suplementar" cruzado com pesquisas tradicionais, ouvidoria oficial e indicadores administrativos, reduzindo viés de representatividade.

6. Considerações Finais

O Radar Institucional é um blueprint para governança de dados sociais que propõe mecanismos para fortalecer decisões em universidades multicampi. O protocolo QA Macro oferece barreira procedural de segurança. O estudo simulado demonstra viabilidade técnica. Trabalhos futuros: (i) protótipo em campus piloto, (ii) benchmarking com Sabiá-2/PTT5, (iii) validação empírica com dados reais, (iv) refinamento de limiares em produção.

7. Referências

- Alves, L. F. e Pantaleão, C. H. Z. (2023) "Modelo multicritério de apoio à maturidade da ouvidoria", NAVUS, v. 13, p. 1-17.
- Belli, L. et al. (2024) "Governança de dados no setor público", Lumen Juris.
- BRASIL (2023) "Diretrizes para Governança de Dados no Setor Público", Ministério da Gestão.
- BRASIL (2024) "IA Generativa no Serviço Público", Ministério da Gestão.
- Campos, A. B. et al. (no prelo) "Structured Sentiment Analysis in Brazilian Portuguese", ProPOR 2026.
- Costa, H. G. e Mello, C. H. P. (2022) "Aplicações do método AHP em gestão de projetos", Revista Gestão & Produção, v. 29.
- EDUCAUSE (2025) "2025 AI Landscape Study in Higher Education", EDUCAUSE Research.
- Grande-Ramírez, C., Fernández-Montes, A. e González-Gómez, J. (2022) "Sentiment Analysis as a Key Performance Indicator for Institutional Governance", Journal of Information Systems and Technology Management, v. 19, p. 1-18.
- Grubbs, F. E. (1969) "Procedures for Detecting Outlying Observations in Samples", Technometrics, v. 11, n. 1.
- Junqueira, J. R. et al. (2023) "BERTimbau in Action: An Investigation of its Abilities in Sentiment Analysis", FLAIRS, v. 36.
- Marreira, E. e de Melo, T. (2023) "Predição Numérica de Avaliações em Português Usando BERTimbau", SBBD, p. 123-134.
- Raji, I. D. et al. (2020) "Closing the AI accountability gap: Defining an internal

algorithmic auditing framework", ACM FAccT, p. 33-44.

Saaty, T. L. (1980) "The Analytic Hierarchy Process: Planning, Priority Setting, Resource Allocation", McGraw-Hill.

Souza, F. et al. (2020) "BERTimbau: Pretrained BERT Models for Brazilian Portuguese", BRACIS, p. 403-417.

Wang, B. et al. (2010) "Detecting Spam in Online Social Networks", ACM CSCW, p.1-4.