

Redes de Kolmogorov-Arnold para Mapeamento de Suscetibilidade a Deslizamentos: Extração de Equação Simbólica a partir do Desastre de São Sebastião

Cândido Alfredo Carvalho de Lucena Filho¹, Felipe Valencia de Almeida¹

¹ Escola Politécnica da Universidade de São Paulo – São Paulo, SP – Brasil

{candidoalfredo, fvalencia}@usp.br

Abstract. *This work applies Kolmogorov-Arnold Networks to landslide susceptibility mapping, extracting an interpretable symbolic equation from the 2023 São Sebastião disaster dataset. Using 1067 crown points and nine topographic variables, we compare frequency ratio, weight of evidence, logistic regression, random forest, support vector machine, and Kolmogorov-Arnold Networks through 5-fold cross-validation. Random forest achieved the highest AUC-ROC (0.884), followed by support vector machine (0.873), logistic regression (0.854), and Kolmogorov-Arnold Networks (0.847). The five-variable symbolic equation achieves AUC-ROC of 0.828, enabling spreadsheet implementation by civil defense teams.*

Resumo. *Este trabalho aplica Redes de Kolmogorov-Arnold ao mapeamento de suscetibilidade a deslizamentos, extraindo uma equação simbólica interpretável a partir de dados do desastre de São Sebastião de 2023. Utilizando 1067 pontos de coroa e nove variáveis topográficas, compara-se razão de frequência, peso de evidência, regressão logística, floresta aleatória, máquinas de vetores de suporte e Redes de Kolmogorov-Arnold via validação cruzada 5-fold. Floresta aleatória alcançou maior AUC-ROC (0,884), seguida por máquinas de vetores de suporte (0,873), regressão logística (0,854) e Redes de Kolmogorov-Arnold (0,847). A equação simbólica com cinco variáveis alcança AUC-ROC de 0,828, permitindo implementação em planilha por equipes de defesa civil.*

1. Introdução

A ocorrência de deslizamentos de terra representa um dos principais riscos geológicos em território brasileiro, especialmente nas regiões serranas do sudeste onde a Serra do Mar concentra elevada densidade populacional em encostas montanhosas. Em fevereiro de 2023, a região de São Sebastião, litoral norte de São Paulo, foi atingida por um evento extremo de precipitação que superou 680 mm em poucas horas, deflagrando uma cascata de deslizamentos que resultou em mais de 60 óbitos e destruição de infraestrutura residencial [Coelho et al. 2024]. Este evento evidenciou a urgência de instrumentos de avaliação de suscetibilidade que sejam simultaneamente precisos e acessíveis para equipes de proteção civil municipal [IBGE and CEMADEN 2018].

Tradicionalmente, o mapeamento de suscetibilidade tem se baseado em métodos estatísticos como razão de frequência (FR) e peso de evidência (WoE), amplamente documentados em agências como o Centro Nacional de Monitoramento e Alertas de Desastres Naturais (CEMADEN) e a Companhia de Pesquisa de Recursos Minerais (CPRM).

Estes métodos são simples, computacionalmente eficientes e interpretáveis, mas repou-sam sobre hipóteses restritivas: independência entre variáveis e incapacidade de capturar relações não-lineares [Van Westen et al. 2006]. A Regressão Logística, método estatístico e de aprendizado de máquina, embora produza equações interpretáveis, compartilha desta última limitação.

A emergência de modelos de aprendizado de máquina como florestas aleatórias e máquinas de vetores de suporte (SVM) tem demonstrado acurácia preditiva sistematicamente superior [Dias et al. 2021, Alcântara et al. 2024]. O custo desta superioridade, porém, é opaco: as decisões não podem ser explicadas em termos de equações, constituindo caixas-pretas que impedem adoção por equipes de defesa civil que demandam instrumentos transparentes e validáveis. Técnicas de IA explicável (xAI) como *SHapley Additive exPlanations* (SHAP) oferecem certo nível de interpretação, mas não substituem uma equação transparente e implementável.

Neste contexto, Redes de Kolmogorov-Arnold (KAN) [Liu et al. 2024b] representam uma alternativa promissora. Diferentemente das redes neurais convencionais que aplicam funções de ativação fixas nos nós, KANs aprendem funções de ativação nas arestas da rede através de B-splines. Esta propriedade, aliada ao procedimento de simbolização automática [Liu et al. 2024a], permite extrair uma equação matemática fechada que reproduz o comportamento preditivo do modelo, combinando a capacidade preditiva de redes neurais com a transparência de modelos estatísticos. Embora KANs já tenham sido aplicadas em diversas áreas das geociências, sua aplicação ao mapeamento de suscetibilidade a deslizamentos permanece pouco explorada.

O presente trabalho tem como objetivos: (i) aplicar KANs ao mapeamento de suscetibilidade a deslizamentos utilizando o desastre de São Sebastião 2023 como estudo de caso; (ii) comparar o desempenho preditivo de KANs com métodos estatísticos clássicos (FR, WoE) e modelos de aprendizado de máquina consagrados (regressão logística, floresta aleatória, SVM); e (iii) extrair uma equação simbólica interpretável a partir da KAN treinada, avaliando sua viabilidade como instrumento prático para equipes de defesa civil.

2. Fundamentação Teórica

2.1. Métodos Estatísticos e de Aprendizado de Máquina

A razão de frequência (FR) baseia-se no cálculo da proporção de eventos em cada classe de uma variável em relação à totalidade de eventos na área de estudo [Lee and Pradhan 2007]. Embora rudimentar, FR é amplamente adotado por agências brasileiras em análises preliminares. O peso de evidência (WoE), fundamentado em *framework* bayesiano [Bonham-Carter 1994], calcula pesos positivos (W^+) e negativos (W^-) para cada classe, com o contraste $C = W^+ - W^-$ quantificando o poder discriminativo.

A Regressão Logística (LR) produz modelo probabilístico da forma $P(y=1|\mathbf{X}) = \sigma(\beta_0 + \sum \beta_i X_i)$, onde os coeficientes β_i são interpretáveis como logaritmo da razão de probabilidades. Porém, assim como FR e WoE, é incapaz de capturar relações não-lineares complexas.

Florestas aleatórias (RF) e máquinas de vetores de suporte (SVM) demonstram consistentemente maior capacidade preditiva em comparação com métodos estatísticos

clássicos. [Dias et al. 2021] confirmam este padrão em revisão sistemática sobre mapeamento de suscetibilidade a deslizamentos no Brasil. No contexto do desastre de São Sebastião, [Alcântara et al. 2024] reportaram área sobre a curva ROC (AUC-ROC) superior a 0,92 com modelos *ensemble*. [Pedreira et al. 2022] investigaram predição de escorregamentos de encostas baseada em aprendizado de máquina no contexto brasileiro, reportando desempenho superior de RF frente a métodos tradicionais. Conforme discutido, a limitação primária dos modelos utilizados nos trabalhos citados é a sua natureza de caixa-preta: não podem ser convertidos em equações compreensíveis.

2.2. Redes de Kolmogorov-Arnold e Extração Simbólica

KANs fundamentam-se no teorema da representação de Kolmogorov-Arnold, que estabelece que qualquer função contínua multivariada pode ser decomposta em composições de funções univariadas. [Liu et al. 2024b] materializaram este conceito em uma arquitetura prática onde, diferentemente de redes *perceptron* multicamadas (MLPs) convencionais com ativações fixas nos nós (ReLU, tanh), KANs aprendem funções de ativação nas arestas via B-splines.

Uma KAN com arquitetura $[n, k, 1]$ recebe n variáveis de entrada, processadas através de k neurônios ocultos e produz uma saída. Cada aresta da rede contém uma função univariada $\phi_{i,j}(x)$, parametrizada por uma combinação linear de funções B-spline. Durante o treinamento, os coeficientes das B-splines são otimizados simultaneamente com regularização de esparsidade (L_1), que incentiva a rede a utilizar o menor número possível de arestas ativas. A saída da rede é computada como $f(\mathbf{x}) = \sum_{j=1}^k \phi_{j,\text{out}}(\sum_{i=1}^n \phi_{i,j}(x_i))$, onde $\phi_{i,j}$ são as funções aprendidas nas arestas.

Esta característica oferece duas vantagens: KANs demonstram capacidade de aproximação com redes menores que MLPs, e as funções aprendidas podem ser convertidas em funções simbólicas explícitas. [Liu et al. 2024a] formalizaram este procedimento através de `auto_symbolic()`, que ajusta funções elementares (exp, log, polinômios) às curvas B-spline aprendidas, produzindo uma equação fechada implementável em planilha. O procedimento completo envolve: treinamento com esparsidade, poda automática de arestas inativas, retreinamento do modelo podado e substituição das B-splines por funções simbólicas.

3. Metodologia

3.1. Área de Estudo e Dados

O município de São Sebastião situa-se no litoral norte de São Paulo, região caracterizada pela Serra do Mar com encostas íngremes cobertas por Mata Atlântica e uso residencial intensivo. Em 18–19 de fevereiro de 2023, precipitação extrema (>680 mm) deflagrou um dos eventos de deslizamento mais catastróficos do país [Coelho et al. 2024].

O inventário de deslizamentos disponibilizado por [Coelho et al. 2024] compreende 1116 pontos de coroa mapeados em alta resolução (EPSG:32723) e 990 polígonos de cicatriz. O Modelo Digital de Terreno (MDT) empregado provém do *Shuttle Radar Topography Mission* (SRTM) com resolução de 30 m. Dos 1116 pontos de coroa, 1067 apresentaram valores válidos e constituíram as amostras positivas. Para amostras negativas, geraram-se 1067 pontos aleatórios respeitando *buffer* de 100 m em torno dos desliza-

mentos, excluindo declividade inferior a 5° e corpos d'água. O *dataset* final compreende 2132 amostras (1067 positivas, 1065 negativas).

Nove variáveis topográficas foram extraídas do MDT para cada amostra: elevação (m), declividade (graus), curvatura em plano (*plan curvature*), curvatura em perfil (*profile curvature*), índice de umidade topográfica ($TWI = \ln(a/\tan \beta)$), componentes $\sin(\text{aspecto})$ e $\cos(\text{aspecto})$ para codificação apropriada da orientação de vertente, distância à drenagem mais próxima (m), e índice de rugosidade do terreno (TRI). A escolha destas variáveis baseou-se em literatura consolidada sobre fatores topográficos de suscetibilidade a deslizamentos translacionais rasos [Van Westen et al. 2006].

3.2. Análise Exploratória dos Dados

A Tabela 1 apresenta as estatísticas descritivas das variáveis topográficas, segmentadas por classe (deslizamento vs. não-deslizamento).

Tabela 1. Estatísticas descritivas das variáveis topográficas por classe.

Variável	Positiva (n=1067)		Negativa (n=1065)	
	Média	DP	Média	DP
Elevação (m)	133,6	79,4	277,0	218,2
Declividade (°)	24,9	7,88	21,4	9,74
Curvatura em plano	0,008	0,033	0,001	0,013
Curvatura em perfil	0,001	0,003	-0,000	0,003
TWI	7,38	0,440	7,61	0,590
$\sin(\text{aspecto})$	-0,055	0,657	-0,038	0,646
$\cos(\text{aspecto})$	-0,087	0,747	-0,264	0,716
Dist. drenagem (m)	231,3	139,7	252,0	199,9
TRI	11,3	3,49	9,82	4,69

As amostras positivas (deslizamento) apresentam declividade média de 24,9° contra 21,4° nas negativas, confirmando a relação direta entre inclinação e instabilidade. A elevação média dos deslizamentos (133,6 m) é inferior à das amostras negativas (277,0 m), indicando concentração dos eventos nas encostas intermediárias da Serra do Mar. O TRI é substancialmente maior nos pontos de deslizamento (11,3 vs. 9,8), evidenciando que terrenos mais rugosos são mais suscetíveis. A distância à drenagem é ligeiramente menor nas amostras positivas (231,3 vs. 252,0 m), sugerindo que a proximidade a canais favorece saturação e ruptura. As componentes de aspecto (\sin e \cos) não apresentam diferenças expressivas entre classes, sugerindo que a orientação da vertente exerce influência limitada neste *dataset*. A variável distância à drenagem apresentou distribuição assimétrica (assimetria= 1,51) e foi transformada via $\log(1+x)$ antes da padronização, uma transformação consolidada na literatura para variáveis com distribuição log-normal.

3.3. Pré-processamento

Todas as variáveis foram padronizadas via `StandardScaler` (média zero, variância unitária), com parâmetros estimados exclusivamente no conjunto de treinamento de cada *fold*, evitando vazamento de informação. A decomposição do aspecto em componentes \sin e \cos é necessária porque o aspecto é uma variável circular ($0^\circ \approx 360^\circ$), e modelos

numéricos interpretariam incorretamente valores próximos como distantes se utilizassem o ângulo bruto. Os parâmetros de escalamento foram posteriormente incorporados na equação simbólica final via substituição algébrica em SymPy.

3.4. Métodos Estatísticos: FR e WoE

FR e WoE foram avaliados sobre o *dataset* completo. Cada variável contínua foi discretizada em cinco classes equiprováveis (quintis). Para FR, o índice de suscetibilidade corresponde à soma dos valores FR; para WoE, à soma dos contrastes. O poder discriminativo foi avaliado via AUC-ROC.

3.5. Modelos de Aprendizado de Máquina: LR, RF, SVM

Todos os modelos de aprendizado de máquina foram avaliados com validação cruzada estratificada *5-fold*. Para cada modelo, foi utilizada uma busca em *grid*, visando identificar o conjunto ótimo de hiperparâmetros. Para regressão logística, `GridSearchCV` (3 *folds*) testou $C \in \{0,01; 0,1; 1; 10\}$; o melhor valor foi $C=1$. Para florestas aleatórias, `RandomizedSearchCV` (3 *folds*, 20 iterações) testou `n_estimators` $\in \{100, 200, 500\}$, `max_depth` $\in \{5, 10, 20, \text{None}\}$, `min_samples_split` $\in \{2, 5, 10\}$, `min_samples_leaf` $\in \{1, 2, 4\}$; melhor: 300 árvores sem limite de profundidade. Para SVM (RBF), `GridSearchCV` testou $C \in \{0,1; 1; 10\}$ e $\gamma \in \{\text{scale}, 0,01; 0,1\}$; melhores: $C=1, \gamma=\text{scale}$.

3.6. KAN: Treinamento, Otimização e Extração Simbólica

Para a rede KAN, testaram-se quatro configurações combinando larguras de camada oculta ($K \in \{3, 5\}$), taxas de aprendizado ($\text{lr} \in \{0,005; 0,01\}$), número de passos e regularização, com arquiteturas $[9, K, 1]$ onde 9 é o número de *features*. A largura K define quantas funções univariadas compõem a camada oculta, controlando a capacidade representacional da rede; valores menores favorecem modelos mais esparsos e interpretáveis. A taxa de aprendizado (lr) governa a velocidade de atualização dos coeficientes B-spline a cada passo, e a regularização λ penaliza a magnitude das funções aprendidas, promovendo esparsidade. A função de perda foi `BCEWithLogitsLoss`, com sigmoid na saída para probabilidades. A melhor configuração, selecionada por CV *3-fold* interna, foi $[9, 3, 1]$ com $\text{lr}= 0,005$, 1000 passos e $\lambda = 0,001$. O otimizador Adam com precisão `float64` foi adotado para assegurar determinismo nas execuções.

O *pipeline* de extração simbólica seguiu [Liu et al. 2024b]: (1) treinamento com regularização de esparsidade (800 passos, Adam, $\lambda=0,01$, `grid= 5`, $k=3$, $\text{lr}= 0,01$); (2) *pruning* automático, resultando em $[9, 2, 1]$; (3) retreinamento do modelo podado (500 passos, $\lambda=0,002$); (4) `auto_symbolic()` com biblioteca $\{\text{exp}, \text{log}, x, x^2, x^3, \text{sqrt}, \text{tanh}, \text{abs}\}$; (5) substituição algébrica dos parâmetros do `StandardScaler` via SymPy; e (6) validação numérica comparando predições com o modelo original.

3.7. Métricas de Avaliação

A métrica primária foi a área sobre a curva ROC (AUC-ROC), escolhida por robustez e por ser padrão na literatura. Calcularam-se também acurácia, precisão, *recall* e *F1-score*, definidas em termos de verdadeiros positivos (VP), verdadeiros negativos (VN), falsos positivos (FP) e falsos negativos (FN):

$$\text{Acurácia} = \frac{VP + VN}{VP + VN + FP + FN} \quad (1)$$

$$\text{Precisão} = \frac{VP}{VP + FP}, \quad \text{Recall} = \frac{VP}{VP + FN} \quad (2)$$

$$\text{F1} = 2 \cdot \frac{\text{Precisão} \cdot \text{Recall}}{\text{Precisão} + \text{Recall}} \quad (3)$$

Para LR, RF, SVM e KAN, reportou-se média \pm desvio padrão das 5 *folds*.

4. Resultados e Discussão

4.1. Comparação de Desempenho entre Métodos

A Tabela 2 sintetiza as métricas de desempenho para todos os métodos avaliados.

Tabela 2. Métricas de desempenho. Valores com * computados sobre o *dataset* completo (AUC simbólica). Demais valores: média \pm desvio padrão da CV 5-fold.

Modelo	AUC-ROC	Acurácia	Precisão	Recall	F1
FR	0,840 \pm 0,010	0,753 \pm 0,018	0,754 \pm 0,015	0,752 \pm 0,037	0,752 \pm 0,022
WoE	0,838 \pm 0,011	0,753 \pm 0,014	0,754 \pm 0,017	0,752 \pm 0,032	0,752 \pm 0,017
LR	0,854 \pm 0,010	0,784 \pm 0,012	0,765 \pm 0,017	0,821 \pm 0,033	0,791 \pm 0,013
RF	0,884 \pm 0,010	0,817 \pm 0,010	0,791 \pm 0,018	0,863 \pm 0,031	0,825 \pm 0,011
SVM	0,873 \pm 0,009	0,811 \pm 0,018	0,767 \pm 0,020	0,896 \pm 0,031	0,826 \pm 0,017
KAN [†]	0,847 \pm 0,016	0,769 \pm 0,014	0,755 \pm 0,017	0,798 \pm 0,036	0,775 \pm 0,017
Eq. KAN	0,828*	—	—	—	—

[†]AUC-ROC determinístico a 3 casas decimais entre execuções; métricas secundárias podem variar em $\pm 0,003$.

*A equação simbólica produz valores contínuos de logit, permitindo o cálculo de AUC-ROC, mas não define um limiar de decisão único, razão pela qual acurácia, precisão, *recall* e F1 não são reportados.

Conforme esperado pela literatura, todos os modelos de aprendizado de máquina superaram os métodos estatísticos clássicos. Florestas aleatórias alcançaram o melhor desempenho absoluto com AUC-ROC de 0,884 \pm 0,010. SVM com *kernel* RBF apresentou o segundo melhor desempenho (0,873 \pm 0,009), seguido pela regressão logística (0,854 \pm 0,010) e pela rede KAN (0,847 \pm 0,016). FR e WoE apresentaram desempenho similar entre si (0,840 e 0,838 respectivamente), abaixo de todos os modelos de ML. É relevante observar que os valores de AUC-ROC obtidos neste estudo são inferiores aos reportados por [Alcântara et al. 2024] para a mesma região (AUC > 0,92), o que se explica por duas diferenças metodológicas: aquele trabalho incluiu variáveis adicionais como precipitação e uso do solo, e empregou resolução espacial de 12,5 m frente aos 30 m do SRTM utilizado aqui. Apesar dessa diferença, os resultados são consistentes com a revisão de [Dias et al. 2021], que reporta AUC típico entre 0,80 e 0,90 para modelos baseados exclusivamente em variáveis topográficas.

A diferença entre RF e KAN (0,884 vs. 0,847) deve ser contextualizada: RF dispõe de centenas de árvores com profundidade irrestrita, enquanto a KAN utilizada emprega apenas três neurônios ocultos com funções B-spline de ordem 3. A arquitetura compacta da KAN foi deliberadamente escolhida para facilitar a extração simbólica, o que impõe um *trade-off* entre capacidade preditiva e interpretabilidade. Arquiteturas mais profundas (e.g., [9, 5, 3, 1]) poderiam elevar o AUC da KAN, porém inviabilizariam a simbolização.

A baixa variabilidade entre *folds* para todos os modelos (desvio padrão $\leq 0,016$ em AUC) indica estabilidade na partição dos dados e sugere que o *dataset* de 2132 amostras é suficiente para o problema em questão. SVM destacou-se pelo maior *recall* (0,896), indicando sensibilidade superior na detecção de deslizamentos, embora com menor precisão (0,767) em comparação com RF (0,791).

A Figura 1 apresenta as curvas ROC comparativas e a Figura 2 sintetiza a comparação de AUC-ROC entre todos os modelos.

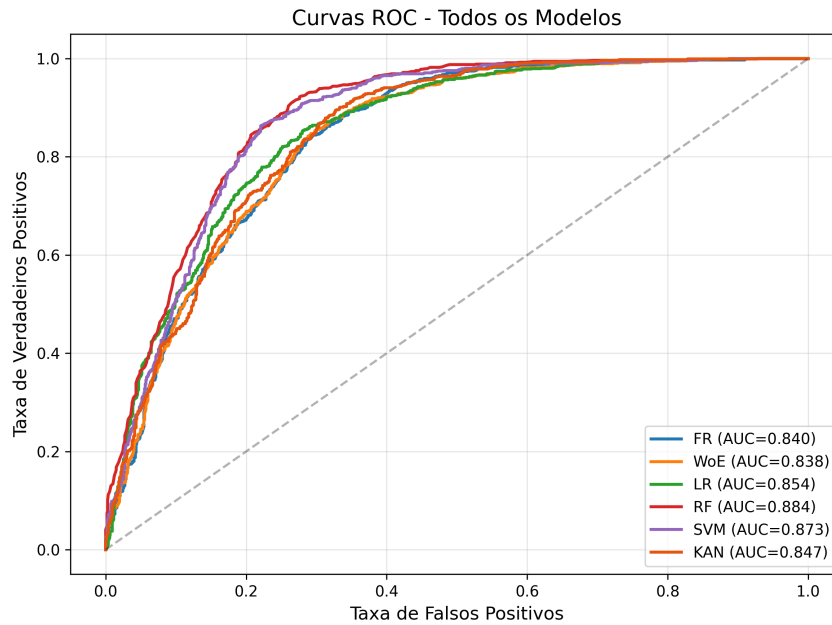


Figura 1. Curvas ROC comparativas. RF alcançou maior AUC (0,884), seguido por SVM (0,873), LR (0,854) e KAN (0,847).

4.2. Equação Simbólica Extraída

A extração simbólica a partir do KAN treinado no *dataset* integral, após poda automática de [9, 3, 1] para [9, 2, 1] (duas unidades ocultas), produziu a seguinte equação em termos das variáveis originais:

$$\begin{aligned} \text{logit}(P) = & 0,472 - 4,89 \times 10^{-4} \cdot h + 3,18 \cdot c_p \\ & + 31,3 \cdot c_f - 0,0402 \cdot \text{TWI} + 0,0286 \cdot \text{TRI} \\ & - 0,0907 \cdot e^{6,56 \times 10^{-3} \cdot h} \end{aligned} \quad (4)$$

onde h é a elevação (m), c_p a curvatura em plano, c_f a curvatura em perfil, TWI o índice de umidade topográfica, TRI o índice de rugosidade do terreno, e $P(\text{deslizamento}) =$

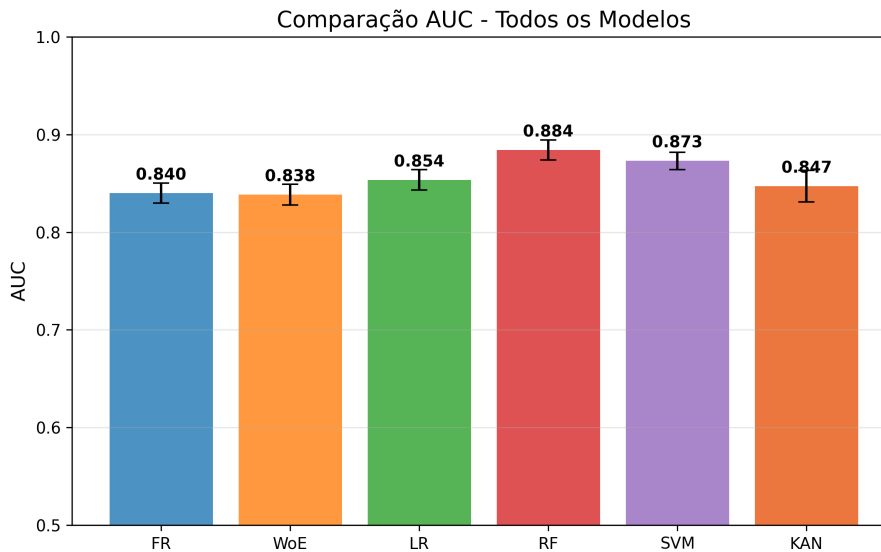


Figura 2. Comparação de AUC-ROC entre todos os modelos. Barras de erro indicam desvio padrão da CV 5-fold.

$\sigma(\text{logit}(P)) = 1/(1 + e^{-\text{logit}(P)})$. Os coeficientes foram arredondados para 3 dígitos significativos; valores com precisão completa encontram-se no *notebook* disponibilizado em repositório público. Entre execuções independentes, os coeficientes podem variar em até $\approx 3\%$ devido à estocasticidade residual do processo de simbolização, embora o AUC-ROC da equação simbólica permaneça estável em $\approx 0,83$.

O modelo KAN com B-splines alcançou AUC de 0,884 no *dataset* completo, e a equação simbólica obteve 0,828. A perda de 0,056 pontos é inerente à aproximação de curvas B-spline por funções elementares, mas a equação resultante é competitiva com regressão logística (AUC 0,854) e oferece transparência total.

A poda automática eliminou quatro variáveis (declividade, aspecto seno e cosseno e distância à drenagem), restando cinco preditores com significado geomorfológico direto. A eliminação da declividade pode parecer contraintuitiva, dado que é o fator mais citado na literatura de suscetibilidade. Contudo, a declividade apresenta correlação com as curvaturas e com o TRI, e a KAN captura indiretamente o efeito da inclinação através do termo exponencial de elevação e da rugosidade do terreno. Este resultado evidencia uma vantagem da extração simbólica: a identificação de representações mais parcimoniosas do fenômeno, onde variáveis redundantes são automaticamente descartadas sem intervenção manual.

A interpretação física dos preditores retidos revela padrões consistentes com a geomorfologia da Serra do Mar. O termo exponencial $-0,0907 \cdot e^{6,56 \times 10^{-3}h}$ captura o efeito não-linear da elevação: para altitudes baixas o termo é próximo de zero, mas cresce exponencialmente acima de ≈ 400 m, reduzindo acentuadamente a probabilidade de deslizamento. Este comportamento é consistente com a concentração dos eventos nas encostas intermediárias (elevação média de 133,6 m nas amostras positivas vs. 277,0 m nas negativas), onde colúvios espessos e regolito intemperizado são mais suscetíveis à ruptura.

A curvatura em perfil (c_f) apresenta o maior coeficiente em valor absoluto

(+31,3), indicando que a forma do perfil longitudinal da encosta é o preditor dominante na equação. Valores positivos de c_f correspondem a perfis convexos, que favorecem aceleração do fluxo subsuperficial e concentração de tensões cisalhantes. A curvatura em plano (c_p , +3,18) reflete convergência topográfica lateral, que canaliza água e material coluvionar. A combinação destes dois preditores é coerente com o modelo conceitual de deslizamentos translacionais rasos em que a geometria da encosta controla tanto a hidrologia subsuperficial quanto a estabilidade mecânica [Van Westen et al. 2006]. O TRI (+0,0286) indica que terrenos mais rugosos são mais suscetíveis. O TWI (-0,0402) apresenta contribuição marginal na equação, possivelmente porque o efeito de umidade é parcialmente capturado pelas curvaturas.

A adoção do otimizador Adam com precisão float64 garante determinismo nas execuções, com variação máxima de $\pm 0,001$ no AUC-ROC entre execuções independentes. Comparada com a regressão logística clássica ($\beta_0 + \sum \beta_i X_i$), a equação KAN captura não-linearidades via o termo exponencial de elevação que o modelo linear não consegue representar. Esta diferença estrutural é uma contribuição central do trabalho: enquanto LR assume linearidade na relação logit-preditores, a KAN descobre autonomamente que a elevação exerce influência exponencial, um resultado que pode orientar futuras modelagens.

A título de exemplo do uso da equação simbólica extraída, são consideradas duas simulações feitas com amostras extraídas do conjunto de dados utilizado. Para uma amostra positiva com $h=105$ m, $c_p=0,005$, $c_f=0,005$, TWI=7,1 e TRI=13,9: a Equação (4) produz $\text{logit}(P) = 0,51$, correspondendo a $P = 63\%$ de suscetibilidade. Para uma amostra negativa típica com $h=403$ m, $c_p=-0,002$, $c_f=-0,002$, TWI=6,8 e TRI=17,5: $\text{logit}(P) = -0,85$, resultando em $P = 30\%$. A implementação prática da Equação (4) em planilha eletrônica requer apenas oito colunas de cálculo, tornando-a diretamente utilizável por qualquer município.

Os resultados evidenciam um *trade-off* entre desempenho preditivo e interpretabilidade. Embora RF tenha obtido maior AUC-ROC, o modelo opera como caixa-preta e não permite representação analítica compacta. A KAN, por outro lado, apresentou desempenho competitivo ao mesmo tempo em que possibilitou a extração de uma equação simbólica implementável e interpretável. Em aplicações operacionais de defesa civil, essa transparência pode representar vantagem relevante frente a ganhos marginais de desempenho obtidos por modelos de maior complexidade.

5. Conclusão

O presente estudo demonstrou a viabilidade de aplicação de Redes de Kolmogorov-Arnold ao mapeamento de suscetibilidade a deslizamentos, com as seguintes conclusões: (i) todos os modelos de ML superaram consistentemente os métodos estatísticos clássicos em AUC-ROC; (ii) RF alcançou desempenho superior (AUC = 0,884); (iii) KAN obteve desempenho competitivo (AUC = 0,847) com estabilidade elevada; (iv) a equação simbólica extraída, envolvendo cinco variáveis topográficas incluindo termo exponencial de elevação, apresentou AUC de 0,828, sendo implementável em planilha eletrônica sem infraestrutura computacional complexa.

As limitações do estudo incluem: concentração em uma única área de estudo e evento específico, o que restringe a generalização dos resultados para outros contextos

geológicos e climáticos; uso exclusivo de variáveis topográficas, omitindo fatores reconhecidamente relevantes como precipitação antecedente, tipo de solo, cobertura vegetal e uso da terra; e a extração da equação simbólica a partir da integralidade do *dataset*, o que pode introduzir viés otimista na avaliação de desempenho da equação.

Perspectivas futuras incluem validação da equação em outras regiões da Serra do Mar para avaliar transferibilidade, integração de variáveis climáticas (notadamente precipitação) ao conjunto de preditores, investigação de arquiteturas KAN mais profundas para captura de interações de ordem superior, e estudo de implementação com equipes de defesa civil para avaliar usabilidade prática da equação em cenários operacionais reais.

O código-fonte e os *notebooks* experimentais estão disponíveis em: https://github.com/candidoalfilho/KAN_Landslide_Susceptibility_WCAMA2026.

6. Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

Referências

- Alcântara, E., de Souza Coelho, R., Grohmann, C. H., and Silva, V. F. (2024). Machine learning approaches for mapping and predicting landslide-prone areas in São Sebastião. *Natural Hazards Research*.
- Bonham-Carter, G. F. (1994). *Geographic Information Systems for Geoscientists: Modelling with GIS*. Pergamon Press.
- Coelho, R. D., Grohmann, C. H., Silva, V. F., and Alcântara, E. (2024). Landslides of the 2023 summer event of São Sebastião, southeastern Brazil: Spatial dataset. *Brazilian Journal of Geology*.
- Dias, H. C., Hölbling, D., and Grohmann, C. H. (2021). Landslide susceptibility mapping in Brazil: A review. *Geosciences*, 11(10):425.
- IBGE and CEMADEN (2018). População em áreas de risco no Brasil. Technical report, Instituto Brasileiro de Geografia e Estatística.
- Lee, S. and Pradhan, B. (2007). Landslide hazard mapping at Selangor, Malaysia using frequency ratio and logistic regression models. *Landslides*, 4(1):33–41.
- Liu, Z., Ma, P., Wang, Y., Matusik, W., and Tegmark, M. (2024a). KAN 2.0: Kolmogorov-Arnold networks meet science. *arXiv preprint arXiv:2408.10205*.
- Liu, Z., Wang, Y., Vaidya, S., Ruehle, F., Halverson, J., Soljačić, M., Hou, T. Y., and Tegmark, M. (2024b). KAN: Kolmogorov-Arnold networks. *arXiv preprint arXiv:2404.19756*.
- Pedreira, L. S., Calumby, R. T., and São Mateus, M. S. C. (2022). Predição de escorregamentos de encostas baseada em aprendizado de máquina. In *Anais do ERBASE/SBC*.
- Van Westen, C. J., Rengers, N., and Soeters, R. (2006). Use of geomorphological information in indirect landslide susceptibility assessment. *Natural Hazards*, 30(3):399–419.