

## PREVISÃO DA QUALIDADE DA ÁGUA SUBTERRÂNEA PARA FINS DE IRRIGAÇÃO NA REGIÃO DO SEMI-ÁRIDO MINEIRO

MARIA FERNANDA ANTUNES COLLARES <sup>1</sup>, ANDRÉ PEREIRA ROSA <sup>2</sup>

<sup>1</sup> Doutoranda em Engenharia Agrícola, Universidade Federal de Viçosa, maria.collares@ufv.br

<sup>2</sup> Prof. Doutor, Depto. de Engenharia Agrícola, Universidade Federal de Viçosa, andrerosa@ufv.br

Apresentado no  
LIII Congresso Brasileiro de Engenharia Agrícola - CONBEA 2024  
6 a 8 de agosto de 2024 – Natal – RN, Brasil

**RESUMO:** A salinidade da água de irrigação e conseqüentemente do solo afeta o crescimento e a produtividade das culturas. O objetivo do trabalho foi avaliar a qualidade das águas subterrâneas para fins de irrigação em uma região semiárida, identificar correlações entre parâmetros e aplicar algoritmos de aprendizado de máquina para prever a qualidade da água. Os resultados indicaram que o Carbonato de sódio residual (RSC) obteve 57% das amostras classificadas como inadequadas para uso na irrigação, os parâmetros Razão de adsorção de sódio (RAS) apresentou 36 amostras inadequadas e o índice de qualidade da água (WQI) para irrigação apresentou 21 amostras inadequadas para irrigação. O modelo de aprendizado de máquina, o Random Forest (RF), demonstrou alta precisão na previsão dos parâmetros de qualidade da água tendo um  $R^2$  acima de 0,70 para todos os parâmetros avaliados. Conclui-se que, apesar dos desafios enfrentados na região semiárida mineira, os modelos de aprendizado de máquina são ferramentas promissoras para uma gestão mais eficaz e sustentável dos recursos hídricos, contribuindo para a agricultura irrigada e a segurança alimentar na região.

**PALAVRAS-CHAVE:** aprendizado de máquina, produtividade, salinidade

### PREDICTION OF GROUNDWATER QUALITY FOR IRRIGATION PURPOSES IN THE SEMI-ARID REGION OF MINAS GERAIS

**ABSTRACT:** The salinity of the water, and consequently of the soil, affects the growth and productivity of crops. The objective of the work was to evaluate the quality of groundwater for safety purposes in a semi-arid region, identify correlations between parameters and apply machine learning algorithms to predict water quality. The results indicated that residual sodium carbonate (RSC) obtained 57% of the samples classified as unsuitable for irrigation, the sodium adsorption ratio (SAR) parameter presented 36 unsuitable samples, and the water quality index (WQI) for irrigation showed 21 unsuitable samples for irrigation. The machine learning model, Random Forest (RF), demonstrated high accuracy in predicting water quality parameters with an  $R^2$  above 0.70 for all evaluated parameters. It is concluded that, despite the challenges faced in the semi-arid region of Minas Gerais, machine learning models are promising tools for more effective and sustainable water resource management, contributing to irrigated agriculture and food security in the region.

**KEYWORDS:** machine learning, productivity, salinity

**INTRODUÇÃO:** A demanda pelo uso de água subterrânea vem aumentando nas regiões do semiárido devido à falta de chuva, com isso tem pressionado o uso dos recursos hídricos e

vem trazendo a necessidade de uma gestão bem-sucedida das águas (ARABAMERI, *et al.*, 2021). A agricultura irrigada na região do semiárido tem grande importância social e econômica, no entanto, o crescimento populacional, econômico e da agricultura irrigada têm causado consequências na mudança do uso da terra e da qualidade da água. Diante deste contexto, o monitoramento da salinidade pode ser realizado por meio de métodos diretos e indiretos. Embora a análise laboratorial convencional seja mais precisa e confiável, sendo considerada a mais usual, é dispendiosa, demorada e alto custo, o que impossibilita medições *in loco* por longos períodos, especialmente em grande escala. Por isso, muitos estudos têm proposto métodos de previsão da qualidade do solo baseados em modelos de aprendizado de máquina, os quais não demandam o conhecimento de variáveis complexas e podem fornecer soluções simples para funções não lineares e multivariáveis (Wu *et al.*, 2021).

Os modelos de aprendizado de máquina são caracterizados pela capacidade de lidar com as relações não lineares entre variáveis independentes e variáveis dependentes e melhorar significativamente a precisão da previsão (Taghizadeh-Mehrjardi *et al.*, 2021). Atualmente, os métodos de sensoriamento remoto são amplamente empregados para avaliar a salinidade do solo e a concentração iônica em diversas regiões do mundo de maneira rápida, eficiente e não invasiva (Omrani *et al.*, 2021). Entretanto, tais métodos também apresentam limitações, como a precisão limitada na determinação dos íons (Wang *et al.*, 2019) e a incapacidade de avaliar profundidades maiores do solo, o que é essencial para compreender a salinidade nas camadas radiculares durante o crescimento de culturas de raízes profundas (Wang *et al.*, 2021).

Além disso, os métodos de sensoriamento remoto são frequentemente utilizados para monitoramento em larga escala. Recentemente, diversos estudos têm se dedicado à previsão dos íons no solo. Estévez *et al.* (2022) investigaram o desempenho de modelos de floresta aleatória, aumento de gradiente e máquina de vetores de suporte na previsão de sulfato e compararam-nos com métodos tradicionais. Taghizadeh-Mehrjardi *et al.* (2021) investigaram o uso de *super-ensembles* e técnicas de importância de características de permutação para prever propriedades físicas e químicas do solo no Lago Urmia, no Irã, constatando que os *super-ensembles* superaram a regressão linear, reduzindo o RMSE médio em 46%. Nabiollahi *et al.* (2021) utilizaram o modelo RF para prever a distribuição espacial do pH, CE e SAR do solo, a fim de estabelecer relações entre os dados e as variáveis do solo. No entanto, a capacidade dos métodos de aprendizado de máquina em prever com precisão os parâmetros de salinidade do solo ainda requer investigação adicional, especialmente na identificação das combinações mais eficazes e práticas de parâmetros de entrada (citação).

A agricultura irrigada na região do semiárido tem grande importância social e econômica, no entanto, o crescimento populacional, econômico e da agricultura irrigada tem causado consequências na mudança do uso da terra e da qualidade da água. A região Norte e do Vale do Jequitinhonha do estado de Minas Gerais apresenta um clima semiárido caracterizado por baixos regimes de chuvas e longos períodos de estiagem, o que muitas vezes tem levado ao abandono das áreas de cultivo, o que afeta negativamente as atividades agrícolas e subsistência da população, visto que a produção de carne e leite se reduzem em consequência da baixa oferta de forragem (GUERRA, *et al.*, 2022).

O presente estudo concentra-se em uma região semiárida altamente cultivada, onde os agricultores têm recorrido ao uso de águas subterrâneas de poços para mitigar os desafios impostos pela escassez de chuvas. Entre os diversos problemas ambientais que afetam esse sistema e resultam em sérios prejuízos à produção agrícola, destaca-se o processo de salinização. O uso excessivo de água levanta preocupações futuras, incluindo a possibilidade de redução do lençol freático e a contaminação das águas subterrâneas devido a práticas hídricas não sustentáveis. Portanto, o objetivo geral deste estudo é avaliar a qualidade das águas subterrâneas para fins de irrigação nessa região semiárida. Especificamente, o estudo tem como objetivos: 1) avaliar os parâmetros de qualidade das águas subterrâneas para fins de

irrigação; 2) determinar associações entre esses parâmetros usando técnicas de estatística integrada; 3) aplicar algoritmos de aprendizado de máquina para a previsão dos parâmetros de qualidade da água de irrigação.

**MATERIAL E MÉTODOS: Área de estudo:** A área de estudo do projeto está localizada na região do semiárido mineiro que abrange as regiões norte do estado de Minas Gerais. Estas regiões são caracterizadas pelo baixos índices pluviométricos, altas temperaturas, alta quantidade de luz solar e baixa umidade relativa durante a maior parte do ano (SENA *et al.*, 2019).

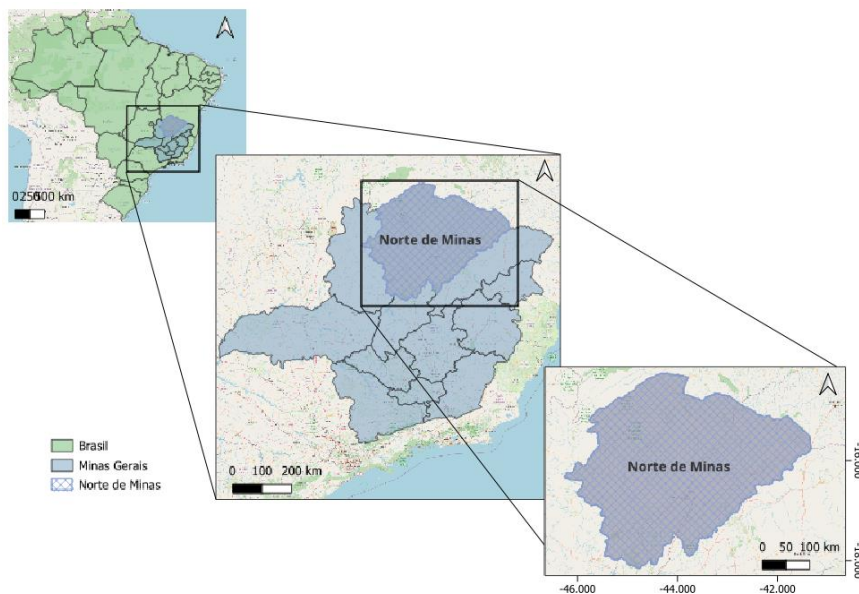


FIGURA 1. Localização da área de estudo

**Análise das amostras:** As amostras foram obtidas junto ao banco de dados do Instituto Mineiro de Gestão das Águas (IGAM) para os anos de 2017 até 2023. A coleta das amostras ocorreu quatro vezes por ano, nos meses de julho, agosto, novembro e dezembro. Os parâmetros considerados foram pH, sulfato, condutividade elétrica, sólidos dissolvidos totais, sódio, magnésio, cálcio, potássio, carbonato, cloreto e bicarbonato. Após a obtenção dos dados, procedeu-se ao tratamento dos mesmos, eliminando valores faltantes.

Ao todo, o banco de dados contou com 672 amostras. Em etapa subsequente, foram realizados cálculos para determinar a razão de adsorção de sódio, o carbonato de sódio residual, o índice de permeabilidade, a porcentagem de sódio e a proporção de Kelly. Os detalhes desses cálculos são apresentados na Tabela 1. A necessidade de calcular essas razões reside na importância de compreender a qualidade e a adequação da água para diversos fins, incluindo irrigação agrícola. As informações derivadas desses cálculos são essenciais para avaliar a viabilidade e os possíveis impactos da utilização da água subterrânea em processos de irrigação, bem como para orientar práticas de manejo e conservação dos recursos hídricos.

TABELA 1. Índices de qualidade da água subterrânea par fins de irrigação.

Índice	Equação	Referência
Razão de adsorção de sódio (SAR)	$SAR = \frac{Na^+}{\sqrt{\frac{(Ca^{2+} + Mg^{2+})}{2}}}$	Ayers and Westcot (1985); Richards (1954)
Carbonato de sódio residual (RSC)	$RSC = (HCO_3^- + CO_3^{2-}) - (Ca^{2+} + Mg^{2+})$	Enaton (1950)

Índice de permeabilidade (PI)	$PI = \frac{Na^+ + \sqrt{HCO_3^-}}{Ca^{2+} + Mg^{2+} + Na^+} * 100$	Doneen (1964)
Porcentagem de sódio (%Na)	$Na\% = \frac{(Na^+ + K^+)}{Ca^{2+} + Mg^{2+} + Na^+ + K^+}$	Wilcox (1955)
Proporção Kelly (KR)	$KR = \frac{Na^+}{Ca^{2+} + Mg^{2+}}$	Kelly (1940)

**Avaliação do índice de qualidade das águas subterrâneas para fins de irrigação :** Para a avaliação da qualidade das águas subterrâneas para fins de irrigação, adotou-se uma metodologia adaptada de SINGH *et al.* (2024), na qual diversos parâmetros, como SAR, RSC, Na%, PI, KR, entre outros, foram calculados utilizando as equações padrão (Tabela 1). Após o cálculo desses parâmetros, foram empregados no cálculo do Índice de Qualidade da Água (IQA) para irrigação, conforme procedimentos e equações (A), (B), (C). O IQA é uma técnica utilizada para avaliar a adequação das águas subterrâneas com base em sua química e nos parâmetros físicos, conforme descrito por Teşan (2023). O padrão estabelecido pela Organização das Nações Unidas para Alimentação e Agricultura (FAO, 1985) foi adotado para o cálculo do IQA, conforme mencionado por Gantait *et al.* (2022), Bahrami e Zarei (2023), Tiwari e Mishra (1985) e Batarseh *et al.* (2021). No cálculo do IQA, foram considerados os seguintes parâmetros da água de irrigação: pH, TDS, TH, CE, Ca<sup>2+</sup>, K<sup>+</sup>, Na<sup>+</sup>, Mg<sup>2+</sup>, HCO<sub>3</sub><sup>-</sup>, CO<sub>3</sub><sup>2-</sup>, Cl<sup>-</sup>, SO<sub>4</sub><sup>2-</sup>, SAR, RSC, PI, Na% e KR. Os pesos relativos dos diversos parâmetros foram determinados de acordo com os padrões da FAO (1985) (Tabela 2).

$$WQI = \sum \frac{W_i * Q_i}{W_i}$$

Q<sub>i</sub> é a classificação de qualidade para o i-ésimo parâmetro de amostra para uma determinada amostra de água.

W<sub>i</sub> é o peso unitário para o i-ésimo parâmetro

$$W_i = \frac{V_a - V_i}{V_s - V_i} \quad (A) \quad W_i = \frac{K}{S_i} \quad (B) \quad K = \frac{1}{\sum_{i=1}^n \frac{1}{S_i}} \quad (C)$$

V<sub>a</sub> = Valor real do i-ésimo parâmetro de uma determinada amostra de água.

V<sub>i</sub> = Valor ideal para o i-ésimo parâmetro (é 0 para todos os parâmetros exceto pH para o qual

é 7,0)

K = Constante relativa.

S<sub>i</sub> = Valor padrão do i-ésimo parâmetro conforme FAO (1985) .

TABELA 2. Padrão de qualidade da água de irrigação pela FAO e peso unitário dos parâmetros para IQA.

Parâmetros	FAO (1985)	Peso unitário (Wi)
CO <sub>3</sub> <sup>2-</sup> (mgL <sup>-1</sup> )	60	0,0062
HCO <sub>3</sub> <sup>-</sup> (mgL <sup>-1</sup> )	610	0,0006
Cl <sup>-</sup> (mgL <sup>-1</sup> )	1065	0,0003
CE (µmhos)	1000	0,0004
TDS (mgL <sup>-1</sup> )	1000	0,0004
Ca <sup>2+</sup> (mgL <sup>-1</sup> )	400	0,0009
pH	8,5	0,0437

$Mg^{2+}(mgL^{-1})$	60	0,0062
$Na^{+}(mgL^{-1})$	920	0,0004
$K^{+}(mgL^{-1})$	2	0,1856
$SO_4^{2-}(mgL^{-1})$	1920	0,0002
Dureza total (como CaCO <sub>3</sub> )	712	0,0005
RSC	1,5	0,2474
SAR	3	0,1237
Na %	30	0,0124
Razão de Kelly (KR)	1	0,3711
$\Sigma Wi$		1,0000

**Previsão da qualidade da água de irrigação:** Os modelos utilizados nesta análise incluem o RF, a Regressão Linear Múltipla e o GBM. O RF é um método que combina múltiplas árvores de decisão para prever a salinidade do solo, sendo eficaz em conjuntos de dados complexos. A Regressão Linear Múltipla busca estabelecer relações lineares entre variáveis independentes e a salinidade do solo, proporcionando uma abordagem interpretável para previsões. O GBM é outra técnica utilizada, construindo estimadores sequencialmente para melhorar a precisão do modelo. Esses modelos foram escolhidos por sua capacidade de lidar com os dados disponíveis e fornecer previsões para os parâmetros de salinidade do solo. As variáveis de entrada do modelo foram todas estudadas até o momento. Para avaliar a eficácia dos modelos, foram utilizados índices estatísticos como o coeficiente de determinação ( $R^2$ ) e a raiz do erro quadrático médio (RMSE).

**RESULTADOS E DISCUSSÃO: Avaliação da água de irrigação utilizando o WQI:** Os resultados indicaram que 48,20% das amostras atenderam aos padrões de irrigação com base na condutividade elétrica (CE). A CE é um parâmetro essencial para avaliar a qualidade da água, sendo influenciada por fatores como taxa de evaporação, precipitação e proporção entre captação de água e recarga. A análise de Wilcox (1955), que considera a CE e o percentual de sódio, classificou a maioria das amostras como excelente a aceitável para irrigação (Tabela 3).

TABELA 3. Adequação de águas subterrâneas para irrigação utilizando diferentes índices.

Faixa	Classe Água	Número de amostras	Percentuais
Condutividade elétrica ( Richards, 1954 )			
<250	Excelente	32	4,80
250 -750	Bom	321	48,20
750-2000	Permitida	286	42,94
2000-3000	Duvidoso	23	3,45
>3000	Inadequado	4	0,60
Carbonato de sódio residual ( $meqL^{-1}$ ) ( Enaton, 1950 ; Richards, 1954 )			
<1,25	Bom	43	6,40
1,25-2,5	Duvidoso	239	35,62
>2,5	Inadequado	389	57,97
Razão de adsorção de sódio (Ayers e Westcot,1985)			
<10	Excelente	562	83,76
10-18	Bom	54	8,05
18-26	Duvidoso	19	2,83
>26	Inadequado	36	5,36
Porcentagem de sódio ( Wilcox, 1955 )			
<20	Excelente	336	50,07

20-40	Bom	124	18,48
40-60	Permitida	60	8,94
60-80	Duvidoso	48	7,15
>80	Inadequado	103	15,35
Razão Kelly (Kelly, 1940)			
<1	Adequado	374	55,74
>1	Inadequado	297	44,26
Índice de qualidade da água (Tiwari e Mishra,1985)			
<150	Excelente	428	63,79
50-300	Bom	171	25,48
300-450	Moderado	51	7,60
>450	Inadequado	21	3,13

Ao considerar o carbonato de sódio residual, observamos que a maioria das amostras (57,97%) está na faixa considerada inadequada, indicando um potencial risco para a qualidade do solo. O mesmo padrão é observado na avaliação da porcentagem de sódio, onde a maioria das amostras (15,35%) é classificada como inadequada de acordo com o critério de Wilcox. Por outro lado, a maioria das amostras apresenta uma razão de adsorção de sódio (SAR) considerada excelente (83,76%), o que sugere que a água analisada possui uma baixa concentração de sódio em relação aos íons cálcio e magnésio, indicando uma boa qualidade para irrigação. Em relação ao Índice de Qualidade da Água, a maioria das amostras (63,79%) é classificada como excelente, com valores abaixo de 150, sugerindo uma boa qualidade geral da água para os usos analisados. No entanto, é importante ressaltar que cerca de 44,26% das amostras são consideradas inadequadas de acordo com o Índice de Kelly, o que indica a presença de riscos para a qualidade da água em uma parcela significativa das amostras analisadas. Esses resultados destacam a importância de uma avaliação abrangente da qualidade da água para garantir seu uso adequado, especialmente em atividades como a irrigação, onde a qualidade da água pode afetar diretamente a produtividade e a saúde do solo. Através do uso do Índice de Qualidade da Água (WQI), a maioria das amostras foi categorizada como excelente (63,19%), com 26,08% como bom e apenas 3,13% como inadequado, indicando uma adequação considerável para fins de irrigação. A distribuição espacial é apresentada da Figura 2 de acordo com a classificação da Tabela 3.

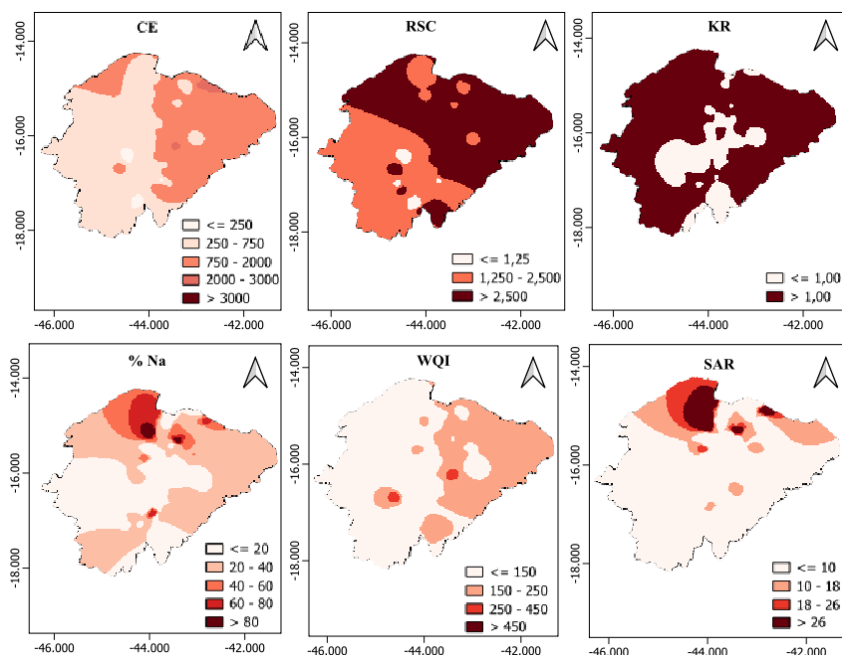


FIGURA 2. Distribuição espacial da classificação dos índices disponíveis na Tabela 3

**Previsão da qualidade da água de irrigação:** Os resultados da análise dos modelos RF, Regressão Linear Múltipla e GBM para diferentes índices revelam sua capacidade de prever a qualidade da água para irrigação, conforme refletido pelos índices de desempenho  $R^2$  e RMSE. Para a CE, todos os modelos exibiram valores de  $R^2$  muito elevados (próximo a 1), indicando uma excelente capacidade de explicação da variabilidade dos dados. O RF registrou o menor RMSE, seguido de perto pelo GBM. Quando consideramos o RAS e a %Na, os modelos RF e GBM novamente se destacaram com valores elevados de  $R^2$ , indicando uma boa capacidade de previsão. A Regressão Linear Múltipla apresentou RMSE mais elevados para a maioria dos parâmetros, sugerindo uma precisão inferior em suas previsões (Tabela 4).

TABELA 4. Resultado dos modelos de aprendizado de máquina

Modelo	Índice	$R^2$	RMSE
Random Forest	CE	0,99	0,03
	RAS	0,96	0,06
	WQI	0,85	0,15
	RSC	0,75	0,12
	%Na	0,70	0,15
	KR	0,73	0,13
Regressão Linear Múltipla	CE	0,98	5,07
	RAS	0,88	1,20
	WQI	0,84	1,58
	RSC	0,73	1,93
	%Na	0,61	9,94
	KR	0,88	1,34
GBM	CE	0,98	4,37
	RAS	0,93	1,84
	WQI	0,83	3,11
	RSC	0,74	2,27
	%Na	0,70	0,70
	KR	0,85	0,26

No que diz respeito ao WQI todos os modelos exibiram  $R^2$  elevados, com valores próximos a 0,99. Tanto o RF quanto o GBM destacaram-se com valores muito baixos de RMSE, indicando uma excelente capacidade de previsão para este índice. No entanto, a Regressão Linear Múltipla novamente demonstrou ser menos precisa em comparação com esses métodos mais avançados de previsão. Esses resultados ressaltam a eficácia dos modelos de aprendizado de máquina, como RF e GBM, na previsão da qualidade da água para irrigação, fornecendo informações valiosas para a gestão agrícola (Figura 3). Por outro lado, a Regressão Linear Múltipla mostrou-se menos precisa em comparação com esses métodos mais avançados de previsão. A interpretação desses índices permite aos agricultores e gestores avaliar os riscos associados ao uso da água para irrigação e implementar medidas adequadas para mitigar esses riscos.

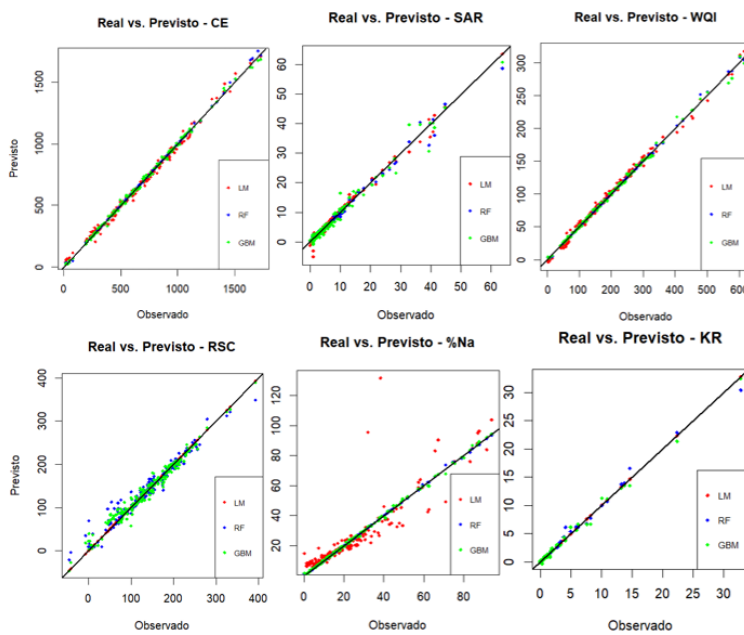


FIGURA 3. Scatterplot dos dados previstos versus dados reais.

Os resultados dos modelos de previsão são essenciais para a gestão agrícola, especialmente em áreas onde a qualidade da água subterrânea é crucial para a irrigação. Como o modelo RF apresentou a melhor análise das métricas de desempenho, plotou-se os dados reais versus os previstos para os dados de validação (FIGURA 4).

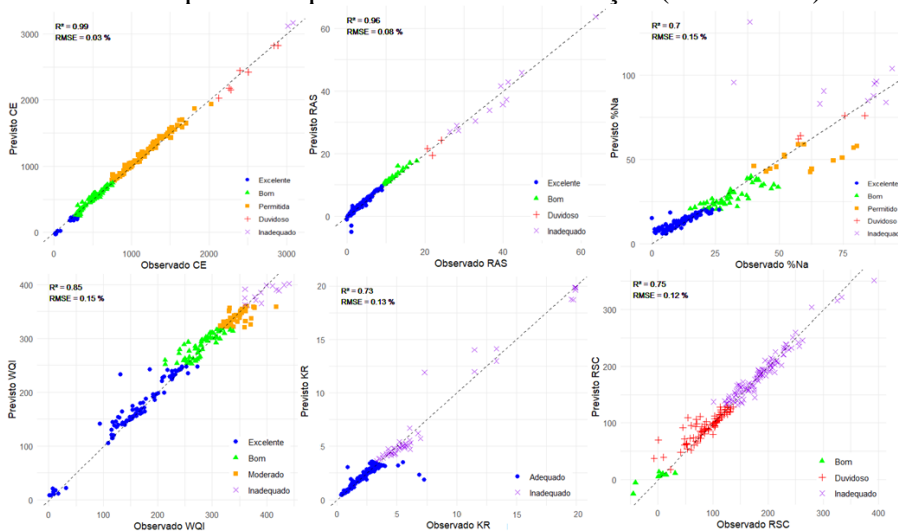


FIGURA 4. Scatterplot dos dados de validação previstos versus dados reais

Como resultado da CE o modelo exibiu valor de  $R^2$  de 0,99, indicando uma excelente capacidade de explicação da variabilidade dos dados. Em seguida, o RAS apresentou um ótimo valor de  $R^2$  e RMSE para o modelo de RF. Os índices de KR e de %Na apresentaram os menores valores de  $R^2$  (0.7 e 0.73 respectivamente) e são indicadores importantes da qualidade da água para irrigação, pois altos níveis de sódio na água podem afetar negativamente a estrutura do solo e a absorção de nutrientes pelas plantas. Em geral, para os índices WQI e RSC o modelo RF apresentou um bom desempenho. O movimento da água, como irrigação, drenagem, evaporação e reposição de águas subterrâneas, afeta o WQI. Além disso, porque a condutividade hidráulica do solo é afetada por diferentes componentes iônicos (Liu *et al.*, 2022), o que acaba se manifestando no WQI. A avaliação razoável da salinidade do solo requer muita análise de parâmetros químicos, que também é uma forma importante de liberar a salinização do solo. No entanto, os métodos tradicionais de análise laboratorial são muitas vezes problemáticos e caros, demorados e trabalhosos.

**CONCLUSÕES:** Neste artigo, modelos de aprendizado de máquina de RF, RLM e GBM foram propostos para prever parâmetros de salinidade do solo como CE, WQI, SAR, %Na, RSC e KR em uma região semiárida do norte de Minas Gerais. O modelo RF foi adequado para prever quase todos os parâmetros de salinidade do solo e apresentou melhor precisão, capacidade de generalização do modelo. O modelo RF apresentou melhor precisão e capacidade de generalização do modelo comparado aos modelos RLM e GBM, sendo o algoritmo de aprendizado de máquina mais recomendado. Além disso, este estudo foi realizado apenas em áreas semiáridas não levando em consideração o período seco e chuvoso, o que pode ser interessante para poder saber qual melhor época do ano precisa ter mais cuidado com a salinidade. Espera-se que algoritmos de previsão de aprendizado de máquina combinados com sensores e outras tecnologias IoT sejam uma tecnologia de monitoramento de solo salino mais eficiente e barata.

**AGRADECIMENTOS:** À Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) - Projeto nº APQ-01576-22 e à bolsa de doutorado concedida pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (Cnpq).

**REFERÊNCIAS:** ARABAMERI, A. et al. Modeling Groundwater Potential Using Novel Gis-Based Machine-Learning Ensemble Techniques. **Journal Of Hydrology: Regional Studies**, v. 36, 2021.

BATARSEH, M. et al. Assessment of groundwater quality for irrigation in the arid regions using irrigation water quality index (IWQI) and GIS-Zoning maps: case study from Abu Dhabi Emirate, UAE. **Groundwater Sustain Dev**, v. 14, 2021, Artigo 100611.

BAHRAMI, M.; ZAREI, A.R. Assessment And Modeling Of Groundwater Quality For Drinking, Irrigation, And Industrial Purposes Using Water Quality Indices And Gis Technique In Fasarud Aquifer (Iran). **Modeling Earth Systems and Environment**, p. 1–15, 2023.

ESTÉVEZ, V. et al. Machine learning techniques for acid sulfate soil mapping in southeastern Finland. **Geoderma**, v. 406, 2022, Artigo 115446.

GANTAIT, A. et al. Hydrogeochemical evolution and quality assessment of groundwater of Ajmer district, Rajasthan, India. **J. Earth Syst. Sci.**, v. 131, n. 4, 2022, p. 236.

GUERRA, J.V.S. et al. Agronomic Performance Of Irrigated Crop Rotations Under Conventional And No-Tillage Systems In The Semiarid Region Of Minas Gerais, Brazil. **Rev. Caatinga, Mossoró**, v. 35, n. 1, p. 33–43, jan.–mar., 2022.

LIU, X. et al. Effects of sodium adsorption ratio and electrolyte concentration on soil saturated hydraulic conductivity. **Geoderma**, v. 414, 2022, Artigo 115772.

NABIOLLAHI, K. et al. Assessing agricultural salt-affected land using digital soil mapping and hybridized random forests. **Geoderma**, v. 385, 2021, Artigo 114858.

OMRANI, M. et al. Application of remote sensing indices to digital soil salt composition and ionic strength mapping in the east shore of Urmia Lake, Iran. *Remote Sens. Appl.: Soc. Environ.*, v. 22, 2021, Artigo 100498..

SENA, F.H.S. et al. Levantamento Fitossociológico De Plantas Daninhas Em Pomares De Mangueira No Semiárido Mineiro. **Nativa**, Sinop, v. 7, n. 5, p. 500-505, 2019.

SINGH, G. et al. Assessment of Groundwater Suitability For Sustainable Irrigation: A Comprehensive Study Using Indexical, Statistical, and Machine Learning Approaches. **Groundwater For Sustainable Development**, v. 24, 2024.

TAGHIZADEH-MEHRJARDI, R. et al. Enhancing the accuracy of machine learning models using the super learner technique in digital soil mapping. **Geoderma**, v. 399, 2021, Artigo 115108.

TEŞAN, S. Estimation of groundwater quality using an integration of water quality index, artificial intelligence methods and GIS: case study, Central Mediterranean Region of Turkey. *Appl. Water Sci.*, v. 13, n. 1, 2023, p. 15.

TIWARI, T.N.; MISHRA, M.A. A preliminary assignment of water quality index of major Indian rivers. *Indian J. Environ. Protect.*, v. 5, n. 4, 1985, pp. 276-279.

WANG, H. et al. Quantitatively estimating main soil water-soluble salt ions content based on Visible-near infrared wavelength selected using GC. **SR and VIP. PeerJ**, v. 7, 2019, p. e6310.

WANG, F. et al. Characterizing soil salinity at multiple depth using electromagnetic induction and remote sensing data with random forests: A case study in Tarim River Basin of southern Xinjiang, China. **Sci. Total Environ.**, v. 754, 2021, Artigo 142030.

WILCOX, L.V. Classification and Use of Irrigation Waters. **USDA Circular** No. 969, Washington, DC, 1955, 19 p.

WU, Y. et al. A Novel Kernel Extreme Learning Machine Model Coupled With K-Means Clustering And Firefly Algorithm For Estimating Monthly Reference Evapotranspiration In Parallel Computation. **Agric. Water Manag.**, v. 245, 2021, Artigo 106624