

## XXVI SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS

# EFEITO DA INICIALIZAÇÃO DE PESOS NO DESEMPENHO DE MAPAS AUTO-ORGANIZÁVEIS PARA SETORIZAÇÃO DE REDES DE DISTRIBUIÇÃO DE ÁGUA: UMA COMPARAÇÃO ENTRE ABORDAGENS ALEATÓRIA E PCA

*Lorena Lemos Dias Lara<sup>1</sup> ; Fernando das Graças Braga da Silva<sup>2</sup>, Sara Maria Marques<sup>3</sup>,*

*Alex Takeo Yasumura Lima Silva<sup>4</sup> & Cláudio Abiar Lourenço<sup>5</sup>*

**Abstract:** The use of machine learning techniques has proven effective in the analysis and clustering of demand nodes for the sectorization of water distribution networks (WDNs). Proper calibration of these techniques is essential to ensure operation near their optimal performance point, thereby enabling more consistent and representative sector formation. This study investigates the impact of weight initialization strategies on the performance of Self-Organizing Maps (SOM) applied to the sectorization of WDNs. Two approaches are compared: random initialization and initialization based on Principal Component Analysis (PCA). The input data correspond to the demand nodes of a benchmark network and include spatial coordinates, demand, and elevation, all previously standardized. SOM performance is evaluated in terms of quantization and topographic errors, as well as the neural network's convergence time. The results indicate a convergence time reduction of 4.1% achieved with PCA-based initialization, compared to random initialization.

**Resumo:** O uso de técnicas de machine learning tem se mostrado eficaz na análise e no agrupamento de nós de demanda na setorização de redes de distribuição de água (RDAs), sendo essencial que essas técnicas estejam devidamente calibradas para operar próximas ao seu ponto ótimo de funcionamento, a fim de garantir resultados mais consistentes e representativos na formação dos setores. Este trabalho investiga o efeito da estratégia de inicialização de pesos no desempenho de Mapas Auto-Organizáveis (SOM) aplicados à setorização de RDAs. Duas abordagens são comparadas: a inicialização aleatória e a baseada em Análise de Componentes Principais (PCA). Os dados utilizados correspondem aos nós de demanda de uma rede *benchmark* com atributos de coordenadas espaciais, demanda e elevação, previamente padronizados. A avaliação de desempenho do SOM considera os erros de quantização e topográfico e o tempo de convergência da rede neural. Os resultados apontam um tempo de convergência 4,1% menor alcançado pela inicialização baseada a PCA, em relação à inicialização aleatória.

**Palavras-Chave** MiniSom; Distritos de Medição e Controle; EXNET.

---

1) Instituto de Recursos Naturais. Universidade Federal de Itajubá, Itajubá-MG. E-mail: lorenaldlara@unifei.edu.br

2) Instituto de Recursos Naturais. Universidade Federal de Itajubá, Itajubá-MG. E-mail: fernandobraga@unifei.edu.br

3) Instituto de Recursos Naturais. Universidade Federal de Itajubá, Itajubá-MG. E-mail: saramarques.eng.civil@gmail.com

4) Instituto de Ciências Puras e Aplicadas, Universidade Federal de Itajubá, Campus Itabira, Itabira-MG, Email: alex.takeo@unifei.edu.br

5) Instituto de Recursos Naturais. Universidade Federal de Itajubá, Itajubá-MG. E-mail: claudioabiar@unifei.edu.br

## 1. INTRODUÇÃO

A setorização de redes de distribuição de água (RDAs) consiste na divisão da rede em áreas menores e gerenciáveis, os Distritos de Medição e Controle (DMCs), e representa uma estratégia eficiente para o controle de pressão, de perdas hídricas e identificação de vazamentos (Bui *et al.*, 2020; Denardi *et al.*, 2025). A criação de métodos de setorização geralmente envolve duas etapas: agrupamento e otimização; a fase de agrupamento busca identificar e agrupar os nós de demanda com características similares, enquanto a de otimização visa a locação ótima dos dispositivos hidráulicos, como medidores de fluxo e válvulas de fechamento de fronteira (Di Nardo *et al.*, 2017; Bui *et al.*, 2020; Wei *et al.*, 2023).

A definição ótima dos limites dos DMCs apresenta desafios significativos, uma vez que as RDAs são sistemas altamente complexos, com múltiplas variáveis hidráulicas e topológicas em constante interação (Raimundo *et al.*, 2025). Para lidar com essa complexidade, estratégias têm sido propostas com base em algoritmos, redes neurais e outras ferramentas computacionais, integradas a modelos matemáticos e de simulação. Essas abordagens têm se mostrado promissoras, sobretudo na identificação de padrões estruturais e operacionais da rede, destacando-se como alternativas favoráveis ao processo de setorização.

Neste contexto, a rede neural Mapas Auto-Organizáveis (*Self-Organizing Maps* – SOM), desenvolvida por Kohonen (1982), emerge como uma ferramenta conveniente por sua capacidade de redução de dados multidimensionais em uma representação em mapa bidimensional que facilita a identificação de setores, com características similares, na fase de agrupamento do processo de setorização. O aprendizado não supervisionado permite o agrupamento dos nós de demanda da RDA sem a necessidade de rótulos prévios, mantendo as relações espaciais e correspondendo à estrutura física da rede.

O SOM é uma ferramenta versátil e muito poderosa, no entanto o seu desempenho está fortemente condicionado à configuração adequada de seus parâmetros de funcionamento. Um ajuste inadequado pode comprometer a qualidade do mapeamento e a representatividade dos grupos formados. Embora estudos anteriores tenham aplicado o SOM em RDAs *benchmarks* da literatura científica (Brentan *et al.*, 2018; Novarini *et al.*, 2019; Bui *et al.*, 2021; Lara *et al.*, 2024a,b,c; Xie *et al.*, 2024), a sensibilidade da rede neural à inicialização de pesos, especialmente no contexto de setorização das RDAs, ainda deve ser explorada.

Akinduko *et al.* (2016) compararam a inicialização de pesos aleatória com a baseada em Análise de Componentes Principais (*Principal Component Analysis* – PCA) utilizando conjuntos de dados sintéticos e separando-os em classes lineares, quase lineares e não lineares. A avaliação do desempenho de aprendizagem foi feita pela comparação da fração da variância não explicada para cada conjunto de dado. O estudo demonstrou que para dados quase lineares a inicialização por PCA é sistematicamente superior do que a aleatória, enquanto que para dados essencialmente não lineares, a aleatória pode gerar melhor desempenho. Concluindo que não há uma direção absoluta para melhores performances de convergência e qualidade de resultados.

Mancini *et al.* (2020) utilizaram a base de dados *Extended MNIST (EMNIST)*, focada em dígitos e letras manuscritas, para comparar o desempenho, por meio do erro de quantização (EQ) e do tempo de execução, entre diversos tipos de implementações do SOM. Testes preliminares foram feitos comparando as abordagens de inicialização aleatória e por PCA com as bibliotecas *MiniSom* e *XPySom* e, para ambas, a inicialização por PCA não pareceu ajudar a diminuir o EQ em relação à aleatória, a diferença observada no estudo pareceu estar em um tempo de inicialização ligeiramente maior devido a decomposição inicial da PCA.

Este trabalho investiga, portanto, o efeito da inicialização de pesos no desempenho do SOM no contexto da setorização de redes, comparando as abordagens aleatória e baseada em PCA, com o intuito de demonstrar a relevância e importância de métodos computacionais bem estruturados. Avaliou-se como ambas estratégias impactam nas métricas de avaliação: o EQ e o erro topográfico (ET), bem como no tempo de convergência e na qualidade de mapeamento do SOM.


## 2. MATERIAIS E MÉTODOS

Este trabalho foi desenvolvido utilizando a linguagem de programação Python. A implementação do SOM foi aplicada a uma RDA *benchmark* de grande porte, definida intencionalmente por demandar maior esforço computacional, permitindo assim avaliar o desempenho do algoritmo em cenários mais desafiadores.

### 2.1 Dados e Pré-processamento

Os dados que alimentaram a camada de entrada do SOM consistiram nos atributos de coordenadas x e y, demanda e elevação dos nós, extraídos da rede de distribuição EXNET (Farmani *et al.*, 2004), ilustrada na Figura 1. Trata-se de um modelo *benchmark* desenvolvido pelo *Centre for Water Systems da Universidade de Exeter*, amplamente utilizado em estudos de RDAs, como em Giustolisi e Ridolfi (2014), Di Nardo *et al.* (2017), Liu *et al.* (2018), Brentan *et al.* (2022), Sharma *et al.* (2022), Yu *et al.* (2022) e Shekofteh *et al.* (2023).

Figura 1 – Modelo EXNET



A rede EXNET foi inicialmente proposta como um modelo de referência para a otimização de problemas multiobjetivo, tendo sido desenvolvida com o propósito de representar, de forma realista, redes de distribuição de água de grande porte (Farmani *et al.*, 2004). O modelo abastece uma população de cerca de 400.000 consumidores e possui 1891 nós de demanda, 2465 tubulações e 2 reservatórios.

Antes do treinamento do SOM, os dados da EXNET passaram por uma etapa de pré-processamento que envolveu a padronização das variáveis por meio da transformação z-score. A padronização visa evitar que variáveis com escalas distintas tenham influência desproporcional no processo de agrupamento.

## 2.2 Mapas Auto-Organizáveis

A implementação do SOM foi realizada por meio da biblioteca MiniSom (Vettigli, 2018). Os valores adotados para os parâmetros de treinamento da rede neural são explícitos na Tabela 1.

Tabela 1 – Valores adotados para o treinamento do SOM

Parâmetro	Valor adotado
Matriz de neurônios	45 x 45
Número de épocas	1.012.500
Raio de vizinhança	5
Função de distância de ativação	Euclidiana
Função de vizinhança	Gaussiana

Optou-se pela utilização de uma grade com topologia hexagonal disposta em uma matriz 45 x 45, totalizando 2025 neurônios. A sugestão de Vesanto e Alhoniemi (2000), comumente utilizada como auxílio na definição da quantidade de neurônios para treinamento do SOM, quando aplicada a redes de distribuição de água, sugere uma quantidade inferior a necessária para que a rede neural trabalhe com esse tipo de dado (Lara, 2025). Portanto, a definição da quantidade de neurônios foi feita de forma a ser ligeiramente maior do que a quantidade de nós de demanda da EXNET.

Para uma convergência suave e menor instabilidade durante o processo de treinamento, decidiu-se por uma baixa taxa de aprendizado. A taxa de aprendizado foi associada a uma alta quantidade de épocas, ou iterações, a partir da sugestão de Kohonen (1990) e Haykin (2009) da definição deste parâmetro a partir da multiplicação da quantidade de neurônios por 500.

O raio de vizinhança define o alcance da função de vizinhança, ou seja, o alcance da atualização dos pesos dos neurônios, que decresce uniformemente no tempo. Se este parâmetro for muito pequeno, o mapa não será ordenado, logo, recomenda-se a inicialização com um amplo raio para que este encolha ao longo das iterações (Kohonen, 1990; 2001).

A funções de distância de ativação e de vizinhança que medem a dissimilaridade entre os dados de entrada e os neurônios do SOM e determinam a taxa de mudança dos pesos ao redor do neurônio vencedor, respectivamente, foram definidas como Euclidiana e Gaussiana. A associação de ambas é comumente utilizada na literatura e relacionada a resultados satisfatórios (Kohonen, 2001).

## 2.3 Inicialização dos pesos da grade do SOM

Para avaliar o impacto da inicialização dos pesos no desempenho do SOM, foram consideradas duas abordagens: aleatória e baseada em PCA. Na abordagem aleatória, os pesos são inicializados com valores sorteados no intervalo dos dados de entrada já padronizados pela z-score, sem considerar uma estrutura estatística. Na abordagem PCA, os pesos iniciais são distribuídos ao longo das duas componentes principais (CPs) extraídas dos dados de entrada, preservando, dessa forma, a orientação e a variação dominante do conjunto.

## 2.4 Métricas de Avaliação:

Para avaliar o desempenho dos mapas gerados após o treinamento SOM, foram comparados os valores de EQ, ET e tempo de convergência, considerando duas estratégias de inicialização dos pesos: aleatória e baseada em PCA.

O EQ é uma métrica de avaliação tradicional, proposta por Kohonen (1982), expressa na Equação (1), utilizada para mensurar a capacidade do mapa em representar os dados de entrada, consistindo no cálculo da soma das distâncias entre os dados do vetor de entrada e os pesos dos

neurônios vencedores, dividida pela quantidade de nós. Embora não haja um intervalo ótimo para o EQ, valores mais baixos indicam melhor representatividade dos dados pelos neurônios da grade, refletindo maior qualidade na formação de agrupamentos.

$$EQ = \frac{1}{n} \sum_{i=1}^n \sqrt{(x_i - w_{i,j})^2} \quad (1)$$

Sendo  $n$  a quantidade de dados de entrada (nós de demanda),  $x$  o vetor de entrada e  $w_{i,j}$  o vetor de pesos do neurônio vencedor para o dado de entrada  $x_i$ .

O ET, apresentado pela Equação (2), foi proposto por Kiviluoto (1996) com o objetivo de quantificar a frequência com que o segundo neurônio vencedor (*Best Match Unit* – BMU) é vizinho do BMU principal para um dado vetor de entrada. Quando esses neurônios são adjacentes, há indicativo de que o mapeamento mantém a topologia local dos dados, evidenciando continuidade no mapa. Dessa forma, valores baixos de ET refletem maior preservação da estrutura original dos dados no mapa gerado.

$$ET = \frac{1}{n} \sum_{k=1}^n u(x_k) \quad (2)$$

Sendo  $n$  a quantidade de dados de entrada (nós de demanda) e  $u(x_k)$  é igual a 1 caso o primeiro e o segundo neurônios vencedores não sejam adjacentes e igual a 0 caso contrário.

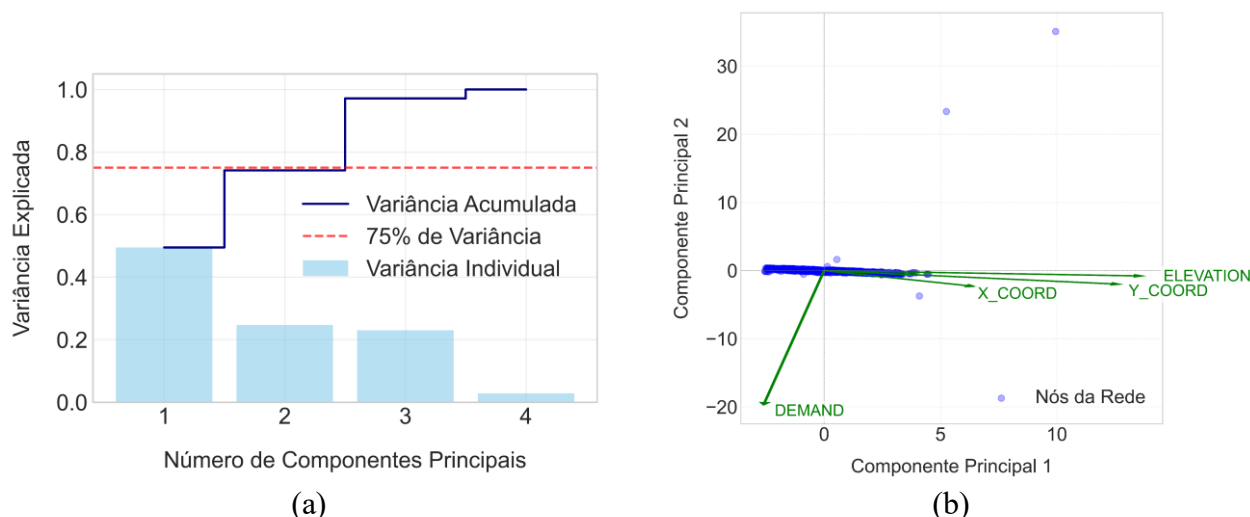
O tempo de convergência do SOM foi determinado monitorando-se a estabilização simultânea do EQ e do ET, considerando-se como critério de convergência a variação relativa à média móvel de ambos os erros inferior a 0,1% ao longo de 50 iterações consecutivas.

### 3. RESULTADOS E DISCUSSÃO

#### 3.1 Análise de Componentes Principais (PCA)

Por meio da PCA, foi possível compreender a estrutura intrínseca dos dados. No gráfico de variância explicada pelas CPs, apresentado na Figura 2a, observa-se que as duas primeiras CPs juntas (CP1 e CP2) explicam cerca de 75% da variância total dos dados, sendo a CP1 responsável por cerca de 50% da variância explicada. A Figura 2b apresenta um *biplot* com a projeção dos dados originais (representados pelos nós da RDA em pontos azuis) no espaço bidimensional das duas primeiras CPs.

Figura 2 – (a) Variância explicada pelas CPs; (b) Projeção de dados e vetores das variáveis





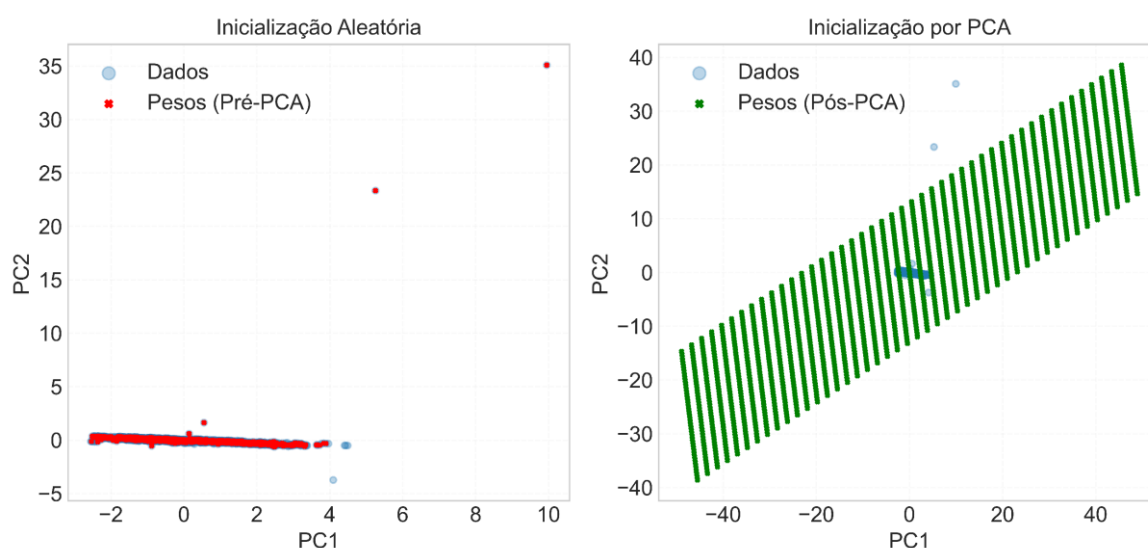
Os vetores na Figura 2b indicam a orientação e magnitude das variáveis originais (atributos dos nós de demanda da RDA considerados neste estudo) no espaço reduzido. A CP 1 demonstra forte correlação com os atributos de elevação e coordenadas, enquanto a CP 2 captura principalmente as variações de demanda da rede. A separação dos vetores manifesta a capacidade da PCA em extrair e segregar informações distintas dos dados de entrada.

### 3.2 Comparação das estratégias de inicialização de pesos

A Figura 3 compara as duas abordagens utilizadas na inicialização dos pesos, para treinamento do SOM, no espaço das CPs. Os pontos azuis representam os dados de entrada projetados nas duas CPs e os marcadores vermelhos/verdes são os pesos iniciais do SOM. O gráfico da esquerda representa a inicialização aleatória que, embora cubra a amplitude dos dados, mostra uma distribuição irregular, não estruturada e com muitos pesos concentrados perto da origem, o que pode resultar na necessidade de mais iterações para que o treinamento alcance a convergência.


O gráfico da direita, que representa a inicialização por PCA, evidencia como essa abordagem incorpora a estatística: os pesos iniciais do SOM (marcadores verdes) são distribuídos por meio de uma malha linear, alinhando-se o eixo de maior variância dos dados. Essa organização indica que o SOM já se inicia com uma estimativa da estrutura dos dados, o que acelera o processo de auto-organização, podendo acelerar a convergência e melhorar a coerência topológica do mapeamento, sendo, portanto, uma técnica de pré-processamento dos dados.

Figura 3 – Comparação de inicialização no espaço PCA



A Figura 4 compara as curvas de convergência para as duas estratégias de inicialização. O aprendizado se decorreu de forma suave para ambas, devido à definição de uma baixa taxa de aprendizado. Pelo critério de convergência adotado, o algoritmo identificou a estabilização dos erros da inicialização aleatória em 938.000 épocas. Na inicialização por PCA, contudo, o sinal de convergência foi antecipado e encontrado em 639.900 épocas, embora, observa-se que o treinamento do SOM continua com sua tendência de declínio na inicialização por PCA para além desse ponto, sugerindo que o algoritmo ainda estaria em processo de aprendizado, com convergência efetiva ocorrendo apenas por volta de 900.000 épocas.

Figura 4 – Convergência do treinamento com inicialização: (a) aleatória; (b) PCA



Essa discrepância ocorre pela organização inicial induzida pela PCA ao inicializar os pesos na direção de maior variância das componentes principais, o treinamento parte de um estado naturalmente mais estruturado e estável, reduzindo a magnitude de flutuações de erro nas fases iniciais. Consequentemente, o critério de convergência adotado se mostrou sensível à volatilidade local identificando precocemente a convergência, o que sinaliza a necessidade de maior rigor na definição deste para inicialização de pesos por PCA.

A inicialização por PCA proporcionou uma redução de aproximadamente 4,1% no número de épocas necessárias para a convergência, quando comparada com a inicialização aleatória, evidenciando menor esforço computacional para alcançar a estabilidade dos erros. A avaliação do desempenho do mapeamento do SOM foi realizada monitorando a evolução do EQ e do ET ao longo do treinamento. A Tabela 2 quantifica os erros finais para cada abordagem.

Tabela 2 – Comparação de erros entre abordagens

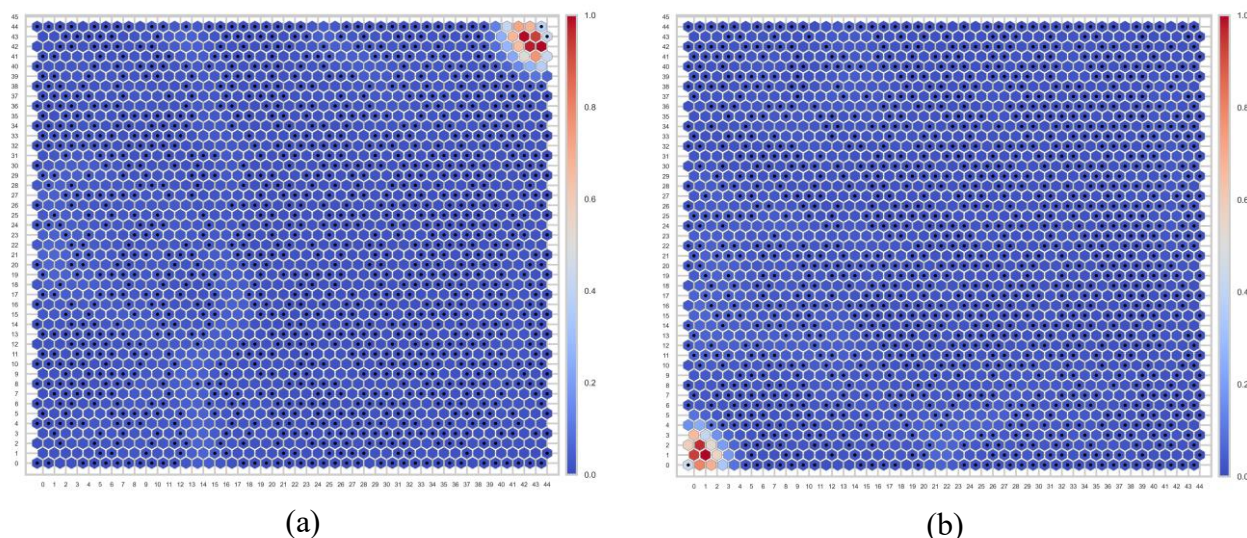
	Inicialização aleatória	Inicialização com base PCA
<b>EQ</b>	0,1330	0,1292
<b>ET</b>	0,0307	0,0122

A Tabela 2 demonstra que a inicialização por PCA proporcionou uma redução de aproximadamente 2,9% do EQ e uma expressiva redução de 60,3% no ET, em relação à inicialização aleatória. O desempenho superior da inicialização por PCA é um indicativo de que a organização inicial dos pesos não apenas acelerou a convergência, mas também favoreceu a capacidade de representação e a preservação da topologia dos dados de entrada no mapa final.

### 3.3 Mapas resultantes

A Figura 5 apresenta as U-Matrizes resultantes do treinamento do SOM para as duas abordagens de inicialização dos pesos. Visualmente os dois mapeamentos foram bem semelhantes, ambos dominados por tons de azul que indicam semelhanças entre neurônios e com apenas uma pequena área no mapa (ambas em cantos) com poucos neurônios avermelhados, que indicam maior dissimilaridade entre os neurônios posicionados nas respectivas regiões em que isso ocorre. BMUs em vermelho não foram observados em nenhum dos mapas, portanto, não há indícios de dados atípicos (*outliers*).

Figura 5 – U-Matrix com inicialização: (a) aleatória; (b) PCA



A similaridade entre as U-Matrices sugere que, independentemente da estratégia de inicialização, a estrutura de agrupamento preservada pelo SOM é robusta. É importante ressaltar que ambas as U-Matrices se mostram eficazes na identificação de fronteiras entre os clusters, fornecendo uma representação visual clara da estrutura dos dados subjacente.

#### 4. CONCLUSÕES

Este trabalho investigou o efeito da estratégia de inicialização de pesos no desempenho do SOM aplicados à setorização de RDAs, comparando as abordagens aleatória e baseada em PCA. As diferenças entre as métricas de avaliação do SOM (EQ e ET) foram substanciais, com a inicialização por PCA atingindo menores valores. As distinções entre os mapeamentos finais gerados (U-Matrices) foram sutis, demonstrando que o SOM é suficientemente robusto para superar diferenças iniciais de pesos e entregar um mapa final consistente independentemente do tipo de inicialização adotado.

Contudo, em relação ao tempo de convergência, a inicialização de pesos baseada em PCA se mostrou uma estratégia superior à inicialização aleatória, necessitando de menos iterações (épocas) para estabilizar os erros e alcançar a convergência da rede neural. Quando os pesos iniciais são aleatórios e desorganizados, o SOM precisa realizar mais trabalho durante o treinamento para "ordenar" a si mesmo e formar essa topologia. A ordenação inicial beneficiou principalmente a redução do ET, proporcionando ao SOM uma maior capacidade de preservação da topologia dos dados de entrada.

Dessa forma, a escolha adequada da estratégia de inicialização pode contribuir significativamente para acelerar a aplicação prática do SOM em ambientes reais, onde rapidez e estabilidade no treinamento são essenciais para a tomada de decisão.

Para estudos futuros, é recomendada a ampliação da análise comparativa entre estratégias de inicialização de pesos do SOM, aplicando-as a RDAs *benchmark* com configurações distintas. Além disso, sugere-se a inclusão de atributos hidráulicos adicionais, como a pressão, no conjunto de dados de entrada, a fim de enriquecer a representação dos nós de demanda e avaliar a robustez dos métodos em cenários mais complexos.



## REFERÊNCIAS

- AKINDUKO, A. A.; MIRKES, E. M.; GORBAN, A. N. (2016). SOM: “*Stochastic initialization versus principal components*”. Information Sciences, (364), p. 213-22.
- BRENTAN, B. M.; CARPITELLA, S.; IZQUIERDO, J.; LUVIZZOTO JR, E.; MEIRELLES, G. (2022). “*District metered area design through multicriteria and multiobjective optimization*”. Mathematical methods in the applied sciences, (45-6), p. 3254-3271.
- BRENTAN, B. M.; MEIRELLES, G.; LUVIZOTTO JR., E.; IZQUIERDO, J. (2018). “*Hybrid SOM+k-Means clustering to improve planning, operation and management in water distribution systems*”. Environmental Modelling & Software, (106), p. 77-88.
- BUI, X. K.; MARLIM, M. S.; KANG, D. (2021). “*Optimal design of district metered areas in a water distribution network using coupled self-organizing map and community structure algorithm*”. Water, (13-6), p. 836.
- BUI, X. K.; MARLIM, M. S.; KANG, D. (2020). “*Water Network Partitioning into District Metered Areas: A State-Of-The-Art Review*”. Water, (12-4), p. 1002.
- DI NARDO, A.; DI NATALE, M.; GIUDICIANNI, C.; MUSMARRA, D.; VARELA, J. M. R.; SANTONASTASO, G. F.; SIMONE, A.; TZATCHKOV, V. (2017). “*Redundancy features of water distribution systems*”. Procedia Engineering, (186), p. 412-419.
- DENARDI, M.; BIANCHOTTI, J. D.; CASTRO-GAMA, M.; PUCCINI, G. D. (2025). “*Managing Nighttime Pressure for Background Leakage Control in Water Distribution Networks Using Simulated Annealing*”. Journal of Water Resources Planning and Management, (151-1).
- FARMANI, R.; SAVIC, D. A.; WALTERS, G. A. (2004). “*Exnet benchmark problem for multi-objective optimization of large water systems*”. In: Modelling and control for participatory planning and managing water systems.
- GIUSTOLISI, O.; RIDOLFI, L. (2014). “*A novel infrastructure modularity index for the segmentation of water distribution networks*”. Water Resources Research, (50-10), p. 7648-7661.
- HAYKIN, S. (2009). *Neural networks and learning machines*. 3 ed. Pearson.
- KIVILUOTO, K. (1996). “*Topology preservation in self-organizing maps*” in Proceedings of International Conference on Neural Networks (ICNN'96), IEEE, p. 294-299.
- KOHONEN, T. (1982). “*Self-Organized Formation of Topologically Correct Feature Maps*”. Biological Cybernetics, (43-1), p. 59-69.
- KOHONEN, T. (2001). *Self-organizing maps*. 3 ed. Berlim: Springer.
- KOHONEN, T. (1990). “*The Self-Organizing Map*”. Proceedings of the IEEE, (78-9), p. 1464-1480.
- LARA, L. L. D. (2025). “*Aplicação da rede neural mapas auto-organizáveis e algoritmo genético NSGA - II à setorização de rede de distribuição de água*”. Dissertação de Mestrado, Universidade Federal de Itajubá, 126p.
- LARA, L. L. D.; SILVA, F. G. B.; SILVA, P. M. G.; ALVES, S. C. R.; MARQUES, S. M.; SILVA, A. T. Y. L.; BARBEDO, M. D. G. (2024a). “*Análise comparativa de agrupamento de nós para setorização de rede de distribuição de água utilizando Mapas de Kohonen hexagonais e retangulares*” in Anais do II FluHidros - Simpósio Nacional de Mecânica dos Fluidos e Hidráulica, Curitiba, 2024, 2, 8p.

- LARA, L. L. D.; SILVA, F. G. B.; SILVA, A. T. Y. L.; BARBEDO, M. D. G.; MARQUES, S. M.; BRITO, G. G. (2024b). “*Agrupamento de nós da rede Hanoi visando a setorização utilizando mapas auto-organizáveis: variações na taxa de aprendizado*” in Anais I Congresso Nacional da Associação Brasileira de Engenharia Hídrica, Itajubá, 2024, 11p.
- LARA, L. L. D.; SILVA, F. G. B.; SILVA, P. M. G.; ALVES, S. C. R.; MARQUES, S. M.; SILVA, A. T. Y. L.; BARBEDO, M. D. G. (2024c). “*Desempenho de mapas auto-organizáveis em agrupamento de nós de diferentes redes de distribuição de água visando a setorização*” in Anais do II FluHidros - Simpósio Nacional de Mecânica dos Fluidos e Hidráulica, Curitiba, 2024, 2, 8p.
- LIU, H.; ZHAO, M.; ZHANG, C.; FU, G. (2018). “*Comparing topological partitioning methods for district metered areas in the water distribution network*”. Water, (10-4), p. 368.
- MANCINI, R.; RITACCO, A.; LANCIANO, G.; CUCINOTTA, T. (2020). “*XPySom: High-performance self-organizing maps*” In 2020 IEEE 32nd International Symposium on Computer Architecture and High Performance Computing (SBAC-PAD), IEEE, p. 209-216.
- NOVARIANI, B.; BRENTAN, B. M.; MEIRELLES, G.; LUVIZOTTO JR., E. (2019). “*Optimal pressure management in water distribution networks through district metered area creation based on machine learning*”. Brazilian Journal of Water Resources, (24-37).
- SHARMA, A. N.; DONGRE, S. R.; GUPTA, R.; ORMSBEE, L. (2022). “*Multiphase procedure for identifying district metered areas in water distribution networks using community detection, NSGA-III optimization, and multiple attribute decision making*”. Journal of Water Resources Planning and Management, (148-8).
- SHEKOFTEH, M. R.; YOUSEFI-KHOSHQALB, E.; PIRATLA, K. R. (2023). “*An efficient approach for partitioning water distribution networks using multi-objective optimization and graph theory*”. Water Resources Management, (37-13), p. 5007-5022.
- VESANTO, J.; ALHONIEMI, E. (2000). *Clustering of the Self-Organizing Map*. IEEE Transactions on Neural Networks, (11-3).
- VETTIGLI, G. (2018). *MiniSom: minimalistic and Numpy-based implementation of the Self Organizing Map*. Disponível em: <<https://github.com/JustGlowing/minisom/>>. Acesso em: 08 jun. 2025.
- WEI, R.; LV, L.; HUANG, X.; WENG, J. (2023). “*DMA Partitioning Method for Water Supply Network Based on Density Peak Optimized Spectral Clustering*”. Journal of Network Intelligence, (8-1), p. 157-167.
- YU, T.; ZHANG, X.; LONG, Z.; ZHOU, H.; LIU, X. (2022). “*Optimal design of district metered areas based on improved particle swarm optimization method for water distribution systems*”. Water Supply, (22-11), p. 7930-7944.

## AGRADECIMENTOS

À Fundação de Amparo à Pesquisa do Estado de Minas Gerais (Fapemig) pelo apoio financeiro.