

Análise de Modelos Baseados em WiSARD para Classificação de Trajetórias de Ônibus no Contexto da Mobilidade Urbana

Bruno O. Barbosa¹, Lucas A. B. Marinho¹, Marcelo D. Santos¹,
Fernando Alexandrino^{2,1}, Rafaelli Coutinho¹, Ubiratam de Paula³,
Diego Carvalho¹, Eduardo Ogasawara¹

¹ Centro Federal de Educação Tecnológica Celso Suckow da Fonseca - CEFET/RJ

²Instituto Federal de Educação, Ciência e Tecnologia de São Paulo - IFSP

³Universidade Federal Rural do Rio de Janeiro - UFRRJ

bruno.barbosa.1@aluno.cefet-rj.br, lucas.marinho@aluno.cefet-rj.br,

marcelo.santos@aluno.cefet-rj.br, fernando.alexandrino@ifsp.edu.br,

rafaelli.coutinho@cefet-rj.br, upaula@ufrrj.br,

d.carvalho@ieee.org, eogasawara@ieee.org

Abstract. *Road infrastructure is essential in the urban context, and the increase in automobile use negatively impacts the quality of life due to heavy traffic congestion. Analyzing vehicle trajectories is crucial for the efficient management of cities. By monitoring the GPS of these vehicles, it is possible to classify trajectories and detect deviations, among other analyses. Weightless neural networks (WiSARD) have recently been used for these tasks. However, the performance of these networks is influenced by the encodings adopted in their inputs. This work evaluates the task of trajectory classification for the road transport system of the municipality of Rio de Janeiro to study this influence. The results show significant efficiency in the analyses, with subtle differences in the applicability of each representation, determining the efficiency of each based on classification quality and execution time.*

Resumo. *A infraestrutura viária é essencial no contexto urbano, e o aumento do uso de automóveis impacta negativamente a qualidade de vida devido a grandes congestionamentos. Analisar as trajetórias dos veículos é crucial para a gestão eficiente das cidades. A partir do monitoramento do GPS desses veículos, é possível classificar trajetórias, verificar desvios, entre outras análises. Recentemente, redes neurais sem peso (WiSARD) têm sido utilizadas para essas tarefas. Entretanto, o desempenho dessas redes é influenciado pelas codificações adotadas em suas entradas. Este trabalho avalia a tarefa de classificação de trajetórias do sistema de transporte rodoviário do município do Rio de Janeiro para estudar essa influência. Os resultados mostram uma expressiva eficiência nas análises, com diferenças sutis na aplicabilidade de cada representação, determinando a eficiência de cada uma com base na qualidade da classificação e no tempo de execução.*

1. Introdução

A mobilidade urbana é essencial nas cidades modernas, desempenhando um papel vital na qualidade de vida dos habitantes e no desenvolvimento sustentável. Ela envolve a capacidade da população de se deslocar de maneira eficiente e acessível no ambiente urbano, utilizando diversos meios de transporte, como carros, ônibus, bicicletas e caminhadas. A gestão adequada das vias, a otimização das rotas de ônibus e a manutenção das infraestruturas viárias são cruciais para garantir uma mobilidade fluida e eficaz, tornando a cidade mais funcional e habitável [Chen et al., 2015]. Como em toda grande cidade brasileira, o crescente uso de automóveis no Brasil gera um aumento significativo no congestionamento de veículos e nas emissões de gases poluentes, comprometendo a qualidade de vida dos cidadãos. Como resposta a esses desafios, foi instituída a Lei Federal 12.587/2012, que estabelece a Política Nacional de Mobilidade Urbana [Valença and Santos, 2020], cujo objetivo é melhorar as condições urbanas para a população, promovendo uma circulação mais eficiente, eficaz e sustentável.

A classificação de trajetórias é essencial para a mobilidade urbana, especialmente quando os dados disponíveis, como os de linhas de ônibus, possuem informações ausentes. Desvios de rota, que podem ocorrer por motivos variados, como enchentes ou grandes eventos, impactam significativamente essa questão. Ao classificar trajetórias, mesmo sem a informação da linha, é possível identificar desvios de rota e evitar problemas. Conceitualmente, a classificação de trajetória envolve prever a classe de rótulo de um objeto (por exemplo, a linha de um ônibus) com base em sua trajetória e outras características [Lee et al., 2008].

Para solucionar esses desafios, é fundamental estudar suas fontes. Agregando as questões de mobilidade, congestionamento e deslocamento de veículos, a maneira mais eficaz é realizar análises e reconhecimento de trajetórias, abordando o contexto de séries temporais. O desafio surge ao analisar ambientes dinâmicos, onde os dados não são constantes, visto que novas amostras são continuamente apresentadas. Nessa situação, poucas estratégias se adaptam devido ao tempo excessivo consumido durante a fase de treinamento ou classificação, dificuldades para incrementar o conhecimento do modelo, arquiteturas extremamente complexas, entre outros fatores. Entre os vários estudos realizados, destacam-se os métodos *K-Nearest Neighbors*, *Dynamic Time Warping*, *Hidden Markov Models* e *Deep Learning* [De Souza et al., 2014].

Recentemente, vem sendo adotada a *Wilkie, Stoneham and Aleksander's Recognition Device* (WiSARD) [Aleksander et al., 1984], uma rede neural sem peso, para a análise de reconhecimento e classificação de trajetórias. Diferentes trabalhos têm explorado essa abordagem [Pontes Cotta et al., 2018]. Esse modelo utiliza um padrão de binarização de reconhecimento de imagens, que pode ser usado para converter dados de *Global Positioning System* (GPS) para análises de rotas e trajetórias. Ela é capaz de apoiar outras tarefas, como a verificação de desvios de padrões. A WiSARD é adequada para aplicações *online* devido à sua rápida velocidade de processamento, permitindo monitorar rotas em tempo real e detectar desvios. Sua eficácia já foi demonstrada em trabalhos semelhantes, inclusive com o uso de imagens das trajetórias dos ônibus, como visto em [Barbosa et al., 2018].

Entretanto, essa rede é influenciada pelas diferentes formas de representação adotadas em sua entrada. Existem várias representações disponíveis na literatura que alcan-

çam taxas de reconhecimento satisfatórias em outros cenários, mas que ainda não foram estudadas no contexto de classificação de mobilidade urbana. Neste sentido, fica em aberto uma avaliação mais completa entre as diferentes formas de codificação das informações de entrada para a rede WiSARD. Este estudo avalia técnicas de codificação para classificar dados de GPS dos ônibus municipais do Rio de Janeiro em suas respectivas linhas, utilizando a WiSARD.

Além desta introdução, este trabalho está dividido em mais quatro seções. Na Seção 2 estão presentes os conceitos necessários para o entendimento do estudo abordado. A Seção 3 detalha os métodos aplicados. Na Seção 4, encontra-se uma avaliação preliminar realizada neste estudo. Por fim, a Seção 5 apresenta as conclusões do trabalho.

2. Fundamentos

A WiSARD é uma rede neural sem peso, criada por Wilkie, Stoneham e Aleksander, usada para reconhecimento e classificação de imagens. Ela utiliza memória de acesso aleatório (RAM) para armazenar informações e funciona com entradas binárias, exigindo que as séries temporais sejam codificadas em listas de 0s e 1s. A arquitetura da WiSARD é composta por discriminadores, cada um formado por um vetor de RAMs e um somador, conforme descrito na Figura 1. Esses discriminadores, que representam diferentes rótulos, são endereçados por n-tuplas de bits mapeadas aleatoriamente. Cada RAM processa um conjunto específico de bits da entrada, e a WiSARD aprende atualizando as posições de memória de 0 para 1 conforme necessário, com base nos padrões apresentados durante o treinamento. O discriminador com maior valor somado é o escolhido.

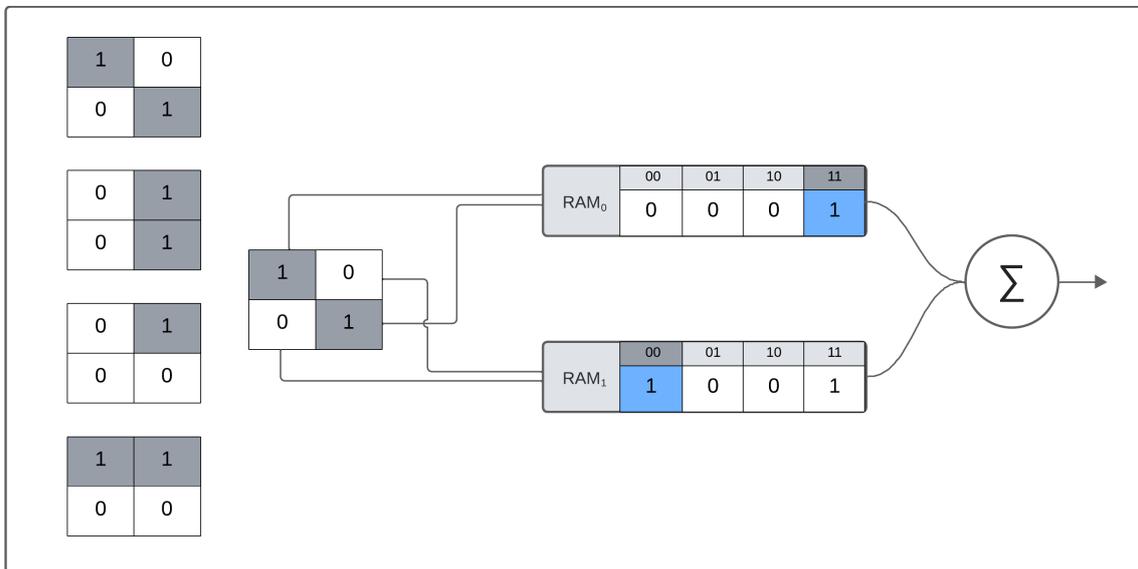


Figura 1. Treinamento de um exemplar na WiSARD (adaptado Carneiro [2012])

A WiSARD requer entradas de tamanho fixo. O método *KernelCanvas* ajusta séries temporais de tamanhos variáveis para um tamanho fixo, conforme a Figura 2, convertendo essas séries de maneira eficiente para análises em tempo real. A abordagem do *KernelCanvas* envolve a criação de uma tela (*canvas*) com um número fixo de regiões, geradas aleatoriamente, cada uma representada por um núcleo (*kernel*). Uma observação

é então colocada sobre esse *canvas* segmentado para análise. O processo de pintura funciona da seguinte maneira: para cada região em que a observação passa perto o suficiente, essa região assume o valor 1; caso contrário, permanece com valor 0 [De Souza et al., 2014].

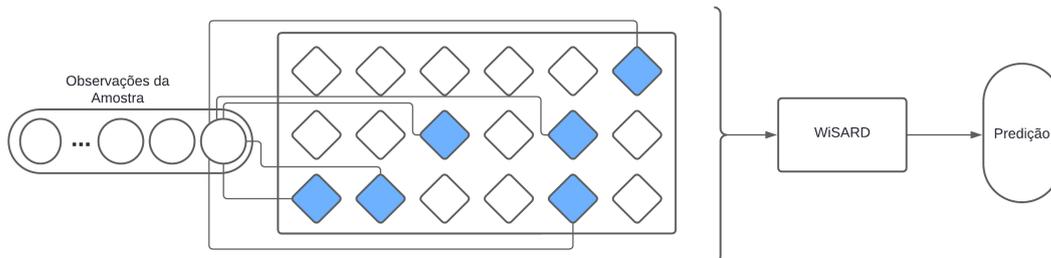


Figura 2. Estrutura *KernelCanvas* combinada com WiSARD (adaptado de De Souza et al. [2014])

O *Termômetro Distributivo* é uma técnica de codificação que não requer conhecimento da distribuição dos dados [T. L. Bacellar et al., 2022]. A maioria dos termômetros assume uma distribuição específica no espaço de entrada, como o Termômetro Linear, que pressupõe uma distribuição uniforme e divide as áreas de maneira equidistante. Em contraste, o Termômetro Distributivo ajusta a divisão das regiões conforme os dados de treinamento, de modo que regiões com alta densidade de dados recebem mais bits, enquanto regiões com menor densidade recebem menos bits.

Semelhante aos métodos de termômetro, a técnica de Grade Uniforme e a *Grade KD-Tree* também são usadas para a representação de dados espaciais. A técnica *KD-Tree* (árvore binária multidimensional), onde K representa a dimensionalidade do espaço de busca, serve como uma estrutura de dados para armazenar informações recuperáveis por buscas associativas [Bentley, 1975]. A utilização desse modelo visa proporcionar, assim como o termômetro distributivo, uma maior quantidade de bits onde existe uma maior densidade de informação. A codificação via *KD-Tree* atribui mais píxeis a regiões que exigem maior atenção, ou seja, áreas potencialmente mais movimentadas, e menos píxeis a regiões onde a atenção detalhada não é tão necessária. Em contraste, na Grade Uniforme, os píxeis são distribuídos linearmente [Barbosa et al., 2018].

3. Métodos

Este trabalho avalia técnicas de codificação para aprimorar a classificação de trajetórias a partir das séries espaço-temporais de ônibus públicos, utilizando a rede neural WiSARD. O processo é dividido em quatro atividades principais: (1) pré-processamento; (2) criação de séries temporais; (3) binarização; e (4) classificação com a rede neural.

Os dados utilizados foram obtidos de uma base pública fornecida pela Prefeitura do Município do Rio de Janeiro. Na Atividade 1, pré-processamento, os dados foram tratados para serem adequados como entrada para a WiSARD. Foram identificados e removidos registros de GPS fora dos limites do Rio de Janeiro, informações duplicadas e veículos com velocidades muito altas ou negativas. Na Atividade 2, os dados foram agrupados e transformados em séries temporais.

Na Atividade 3, as técnicas de binarização avaliadas incluem o uso combinado e individual de métodos de binarização de dados (*KernelCanvas* e Termômetro Distributivo) com técnicas de discretização espacial (*Grade Uniforme* e *Grade KD-Tree*). As seguintes combinações foram geradas: Lat/Long + *KernelCanvas*; *Grade Uniforme* + *KernelCanvas*; *Grade KD-Tree* + *KernelCanvas*; e Termômetro Distributivo.

Na abordagem da *Grade Uniforme*, o espaço geográfico é dividido em quadriláteros de tamanho uniforme. Cada ponto de GPS é classificado em um desses quadriláteros com base na sua latitude e longitude. A *Grade KD-Tree*, por sua vez, ajusta o tamanho dos quadriláteros conforme a densidade de dados: quanto maior o número de ônibus em uma região, menor a área do quadrilátero. A divisão é feita iterativamente até que um número limite de nós seja alcançado, priorizando a criação de quadriláteros com maior quantidade de registros.

Além disso, como a WiSARD requer entradas de tamanho fixo, o Termômetro Distributivo necessita de um pré-processamento para satisfazer esse requisito. Na binarização da série temporal, a última localização é repetida até que todas as séries temporais tenham a mesma quantidade de coordenadas espaciais. Ou seja, após os registros reais do GPS, são simulados registros onde os ônibus estão parados no mesmo ponto, para satisfazer os requisitos da WiSARD.

Por fim, na Atividade 4, as séries temporais binarizadas são classificadas pela rede WiSARD. Forma-se uma imagem do município com as informações das rotas e trajetórias registradas, juntamente com as informações das grades.

4. Avaliação experimental

A metodologia descrita na Seção 3 foi aplicada a dados coletados durante uma semana, de 24 a 30 de junho de 2023, resultando em um total de 57.046.930 registros de GPS, envolvendo 3.966 ônibus operando em 432 linhas diferentes [Instituto Pereira Passos, 2017].

Foram selecionadas as linhas de ônibus que operam na Avenida Maracanã, uma das principais vias do Rio de Janeiro. Após o pré-processamento, foram criadas séries temporais, agrupando registros por linha e veículo, e organizando-os por data e hora. As séries temporais com comprimento superior a cinco quilômetros foram selecionadas, devido à sobreposição de muitos trechos dos itinerários dos ônibus, sendo necessários que as séries temporais sejam minimamente diferentes para cada linha, resultando em 1.420 séries temporais.

Diversas combinações de hiperparâmetros foram testadas para otimizar o desempenho do modelo e a escolha dos melhores valores para esses parâmetros foi baseada em análises exploratórias em uma amostra não usada nas análises finais. No contexto da WiSARD, foi encontrado o *addressSize* igual a 16. No *KernelCanvas*, os hiperparâmetros *numberOfKernels*, *activationDegree* e *bitsByKernel* foram utilizados, respectivamente, como 4.096, 0,03 e 5. No Termômetro Distributivo, o parâmetro *bits* foi definido como 8.

Para verificar se alguma técnica de binarização oferece benefícios adicionais, foram usadas as técnicas *Grade KD-Tree*, *Grade Uniforme* e Termômetro Distributivo. Os resultados obtidos com o conjunto de dados de ônibus do Rio de Janeiro, coletados entre 24 e 30 de junho de 2023, são apresentados a seguir.

Tabela 1. Avaliação das técnicas de binarização utilizadas.

Técnica de Binarização	Acurácia	F1-Score	Precisão	Recall
Grade Uniforme + KernelCanvas	94,71%	94,86%	97,83%	93,09%
Grade KD-Tree + KernelCanvas	92,67%	93,19%	96,74%	93,84%
Lat/Long + KernelCanvas	92,25%	90,90%	93,48%	90,29%
Termômetro Distributivo	86,61%	79,26%	60,12%	79,93%

A Tabela 1 apresenta os resultados para cada abordagem, ordenados pelo F1-Score. O melhor desempenho foi obtido utilizando a abordagem *Grade Uniforme + KernelCanvas*. Com exceção do Termômetro Distributivo, todas as abordagens apresentaram F1-Score e acurácia superiores a 90%, indicando que as binarizações que utilizam o *KernelCanvas* possuem vantagens em termos de precisão.

Tabela 2. Tempo médio de 10 execução das técnicas de binarização utilizadas.

Técnica de Binarização	Binarização (minutos)	Classificação (segundos)
Grade Uniforme + KernelCanvas	13,48	01,11
Grade KD-Tree + KernelCanvas	32,85	01,13
Lat/Long + KernelCanvas	13,30	01,03
Termômetro Distributivo	03,33	21,98

A Tabela 2 mostra que a abordagem utilizando o Termômetro Distributivo possui um tempo de execução para a binarização muito menor que as demais técnicas. Apesar de apresentar F1-Score e acurácia menores, em aplicações críticas, pode ser utilizada como uma aproximação inicial. Além disso, considerando o lado computacional, em aplicações que exigem maior velocidade, essa técnica se destaca.

5. Conclusão

Neste estudo, foram analisadas diversas técnicas de binarização para dados geoespaciais visando aplicá-las na rede neural WiSARD. Os resultados indicam que a melhor abordagem, com base no F1-Score, é a combinação *Grade Uniforme + KernelCanvas*. Esta combinação mostrou-se vantajosa para a classificação das trajetórias dos ônibus em suas respectivas linhas.

No entanto, o Termômetro Distributivo apresentou vantagens significativas do ponto de vista computacional, sendo aproximadamente quatro vezes mais rápido na etapa de binarização em comparação com a abordagem *Grade Uniforme + KernelCanvas*. Essa rapidez torna o Termômetro Distributivo uma opção viável para aplicações que exigem análises em tempo real e aproximações rápidas. Contudo, seu desempenho em termos de F1-Score é cerca de 15,6% inferior ao da melhor abordagem, o que sugere que seu uso deve ser considerado com cautela, dependendo dos requisitos específicos da aplicação.

A escolha da técnica de binarização, portanto, deve levar em conta o equilíbrio entre a precisão e a eficiência computacional, conforme as necessidades do sistema de

mobilidade urbana em questão. A combinação *Grade Uniforme + KernelCanvas* oferece a melhor precisão, enquanto o Termômetro Distributivo proporciona maior velocidade, sendo uma opção adequada para cenários onde a rapidez é crucial.

Agradecimentos

Os autores agradecem ao CNPq, CAPES e FAPERJ pelo apoio parcial a esta pesquisa.

Referências

- Aleksander, I., Thomas, W., and Bowden, P. (1984). Wisard a radical step forward in image recognition. *Sensor Review*, 4(3):120 – 126.
- Barbosa, R., Cardoso, D. O., Carvalho, D., and França, F. M. (2018). Weightless neuro-symbolic GPS trajectory classification. *Neurocomputing*, 298:100 – 108.
- Bentley, J. L. (1975). Multidimensional Binary Search Trees Used for Associative Searching. *Communications of the ACM*, 18(9):509 – 517.
- Carneiro, C. (2012). *A Função do Índice de Síntese das Linguagens na Classificação Gramatical com Redes Neurais sem Peso*. Mestrado em Engenharia de Sistemas e Computação, Universidade Federal do Rio de Janeiro, Rio de Janeiro.
- Chen, W., Guo, F., and Wang, F.-Y. (2015). A Survey of Traffic Data Visualization. *IEEE Transactions on Intelligent Transportation Systems*, 16(6):2970 – 2984.
- De Souza, D. F. P., França, F. M. G., and Lima, P. M. V. (2014). Spatio-temporal pattern classification with KernelCanvas and WiSARD. In *Proceedings - 2014 Brazilian Conference on Intelligent Systems, BRACIS 2014*, pages 228 – 233.
- Instituto Pereira Passos (2017). Data.Rio - DataLake. Technical report, <https://www.data.rio/search?q=datalake>.
- Lee, J., Han, J., Li, X., and Gonzalez, H. (2008). TraClass: Trajectory classification using hierarchical region based and trajectory based clustering. In *Proceedings of the VLDB Endowment*, volume 1, pages 1081 – 1094.
- Pontes Cotta, K., Sena Ferreira, R., and Franca, F. M. (2018). Weightless neural network WiSARD applied to online recommender systems. In *Proceedings - 2018 Brazilian Conference on Intelligent Systems, BRACIS 2018*, pages 348 – 353.
- T. L. Bacellar, A., Susskind, Z., A. Q. Villon, L., D. S. Miranda, I., Santiago De Araújo, L., Cadette Dutra, D. L., Breternitz Jr., M., John, L., Lima, P., and França, F. (2022). Distributive Thermometer: A New Unary Encoding for Weightless Neural Networks. In *ESANN 2022 proceedings*, pages 31–36, Bruges (Belgium) and online event. Ciaco - i6doc.com.
- Valença, G. and Santos, E. (2020). The relationship between the concept of complete streets and the National Urban Mobility Policy: Application to a road project in Natal-RN, Brazil. *Eure*, 46(139):73 – 89.