



De 11 a 14 - NOVEMBRO DE 2024

**Inteligência Artificial
na Gestão de Operações:**
Limitações e possibilidades



APLICAÇÃO DE APRENDIZADO DE MÁQUINA NA PROPOSIÇÃO DE ESCALA DE CRITICIDADE DE OCORRÊNCIAS DE TRÂNSITO

JAQUELINE BERBONE - berbone.alves@unesp.br

UNIVERSIDADE ESTADUAL PAULISTA - UNESP - BAURU-FEB

MARCELO FURLAN - marcelofurlan@ita.br

INSTITUTO TECNOLÓGICO DE AERONÁUTICA - ITA

BÁRBARA STOLTE BEZERRA - barbara.bezerra@unesp.br

UNIVERSIDADE ESTADUAL PAULISTA - UNESP - BAURU-FEB

ÁREA: 2. LOGÍSTICA

SUBÁREA: 2.3 - PROJETO E ANÁLISE DE SISTEMAS LOGÍSTICOS

RESUMO: O OBJETIVO DESTE ESTUDO FOI ANALISAR A CLASSIFICAÇÃO DE OCORRÊNCIAS DE TRÂNSITO UTILIZADA ATUALMENTE PELA ARTESP EM RODOVIAS CONCEDIDAS DO ESTADO DE SÃO PAULO E PROPOR UMA ESCALA DE CRITICIDADE UTILIZANDO TÉCNICA DE APRENDIZADO DE MÁQUINA. PARA ALCANÇAR TAL OBJETIVO, FORAM ANALISADAS 4.975 OCORRÊNCIAS DE TRÂNSITO REGISTRADAS NA BASE DE DADOS DA AGÊNCIA EM 87 DIFERENTES VIAS CONCEDIDAS DO ESTADO. A PARTIR DA APLICAÇÃO DE MATRIZ DE CONFUSÃO, TESTES NÃO-PARAMÉTRICOS E TÉCNICA DE REDE NEURAL ARTIFICIAL, OBSERVOU-SE OS SEGUINTE RESULTADOS: A) QUASE METADE DAS OCORRÊNCIAS POSSUEM ALGUM TIPO DE CLASSIFICAÇÃO ENVIESADA; B) OCORRÊNCIAS LEVES POSSUEM SEMELHANÇA COM OCORRÊNCIAS MODERADAS QUANTO AO TEMPO DE INTERDIÇÃO DE VIA; C) AS REDES NEURAI CLASSIFICARAM AS 4.975 OCORRÊNCIAS EM 4 GRUPOS DISTINTOS; D) OCORRÊNCIAS COM FATALIDADE ESTÃO ASSOCIADAS A UM DOS GRUPOS DE CRITICIDADE. OS RESULTADOS DESTE ESTUDO PODEM CONTRIBUIR PARA NOVAS REVISÕES DE BASE DE DADOS, PERMITINDO MELHOR ALOCAÇÃO DE RECURSOS E TEMPO DE RESPOSTA PARA FUTURAS OCORRÊNCIAS DE TRÂNSITOS NAS RODOVIAS DO ESTADO.

PALAVRAS-CHAVES: GESTÃO DE TRÁFEGO; CONGESTIONAMENTO NÃO-RECORRENTE; REDES NEURAI ARTIFICIAIS; ESCALA DE CRITICIDADE; TESTE NÃO PARAMÉTRICO.

1. INTRODUÇÃO

O número de veículos circulando nas rodovias brasileiras tem aumentado nos últimos anos. Comparando os dados disponíveis do Ministério dos Transportes, foram contabilizados mais de 32 milhões de veículos em abril de 2023, enquanto em 2024, já houve um aumento de mais de 1 milhão de veículos nas vias, representando um crescimento de 3,2% a.a. (SENATRAN, 2024). Um dos fatores apontados para o crescente número de veículos nas vias é o aumento populacional (MODI *et al.*, 2022). Só no Estado de São Paulo, em 2024, estima-se que a população seja de cerca de 38 milhões de cidadãos com idade entre 18 a 80 anos, com uma projeção de crescimento de 4,5% até 2030 e 9,1% até 2050 (IBGE, 2020). Neste contexto, ao se considerar que veículos de pequeno porte tendem a oferecer mais conforto e praticidade, eles passam a ser uma opção de escolha para uma população crescente (DE SOUZA *et al.*, 2017; SADOLLAH *et al.*, 2019).

Se há mais veículos nas rodovias, aumenta-se a probabilidade de novas ocorrências de trânsito, sendo este um importante problema de segurança no tráfego rodoviário (XU; LIU; YANG, 2024). Os congestionamentos gerados por incidentes de trânsito podem gerar impactos econômicos, sociais e ambientais, principalmente em áreas densamente habitadas (MFINANGA; FUNGO, 2013). No Brasil, estima-se que o custo do congestionamento ultrapasse R\$ 80 bilhões por ano (ROCHA FILHO *et al.*, 2020).

Por definição, os incidentes de trânsito são compreendidos por quaisquer eventos que gerem prejuízos à segurança e/ou reduza a velocidade do trânsito. Estes eventos podem ser compreendidos por veículos que sofrem panes, acidentes, destroços acumulados na via ou até derramamentos de materiais (MFINANGA; FUNGO, 2013). Por sua vez, os congestionamentos de tráfego podem ser divididos em dois tipos: congestionamento recorrente (CR) e congestionamento não-recorrente (CNR). Segundo Zarindast, Poddar e Sharma (2022), o CR apresenta um padrão diário em relação à localização e durabilidade do evento, ocorre normalmente durante os períodos de pico e está relacionado à demanda de viagens e a capacidade insuficiente de infraestrutura. Já os eventos de CNR podem ocorrer a qualquer momento do dia, com imprevisibilidade nos locais e durabilidade de evento, dependendo também de condições da rede viária e da capacidade das vias.

Por mais que o tema vem sendo pesquisado há décadas, ele continua presente nas rodovias, requerendo abordagens capazes de permitir respostas rápidas de gestão de tráfego (GAL-TZUR; BEKHOR; BARSKY, 2022). Por exemplo, a mineração de dados tem o potencial de descobrir e extrair padrões e relacionamentos inicialmente desconhecidos em grandes bases de dados (CALEFFI *et al.*, 2016). Essa grande quantidade de dados enriquece a

aplicação de técnicas de *machine learning* para a previsão e classificação de congestionamentos, tais como: redes neurais artificiais, aprendizado profundo, árvore de decisão, máquina de vetores de suporte entre outras (TU *et al.*, 2021; XU; LIU; YANG, 2024). Assim, a inteligência artificial e o aprendizado de máquina podem oferecer soluções mais otimizadas, tornando-se ferramentas com papel importante na gestão de tráfego e na proposição de soluções inovadoras para o tema (MODI *et al.*, 2022).

A compreensão dos incidentes de trânsito e a busca de técnicas para análise de tais ocorrências têm sido objeto de estudos relevantes. Sadollah *et al.* (2019) analisaram o congestionamento recorrente (CR) de rodovias classificando o grau de congestionamento via técnica de *machine learning*. Rocha Filho *et al.* (2020) propuseram uma solução de comunicação entre veículos a fim de permitir o máximo de fluxo de veículo em uma rodovia. Song *et al.* (2020) propuseram um índice de congestionamento e, a partir de um valor de corte, os autores classificaram os acidentes em 3 condições distintas: (1) acidente não durante condições de congestionamento, (2) acidente durante congestionamento não recorrente e (3) acidente durante congestionamento recorrente. Por fim, Gore *et al.* (2023) propuseram um índice de congestionamento para tráfego em tempo real e agruparam via *k-means* as regiões da cidade que possuíam similaridade.

Em relação aos estudos que utilizaram dados de congestionamento não recorrente, observa-se que eles procuram compreender como os congestionamentos diminuem ao longo do tempo e sob quais condições. Caleffi *et al.* (2016) aplicou técnicas de clusterização (*k-means* e *fuzzy clustering*) para analisar dados meteorológicos e identificar padrões de comportamento do tráfego na rodovia BR-290/RS. Krishnakumari *et al.* (2017) propôs o uso de um modelo estatístico para processamento de imagens a fim de identificar e classificar regiões de congestionamento.

Entretanto, tais estudos priorizam análises de tráfego real de rodovias e não observam questões de congestionamentos não recorrentes (CNR). Ainda, não analisam classificações baseadas em critérios, mas apenas propõem novas maneiras de gerenciar o tráfego. E quando analisam a criticidade de eventos, os autores verificam a gravidade de lesões ocorridas (ALI; HUSSAIN; HAQUE, 2024), não focando o quanto um incidente causou de congestionamento e interdição de via. Por isso, a análise de maiores bases de dados e a testagem de classificações existentes podem apontar novos caminhos para a melhoria na gestão de tráfego em rodovias, principalmente, quando ocorrem incidentes de trânsito que geram interdição de pista e longas filas de congestionamento.

Portanto, o objetivo deste estudo é analisar a classificação de ocorrências de trânsito

utilizada atualmente pela ARTESP em rodovias concedidas do Estado de São Paulo e propor uma escala de criticidade utilizando técnica de aprendizado de máquina. Para isso, aplicou-se testes não-paramétricos (LIMA *et al.*, 2022) a fim de avaliar se a classificação atual apresenta o mesmo padrão de tempo de interdição de via e tamanho do congestionamento durante as ocorrências atendidas. Em sequência, aplicou-se a técnica *Self-Organizing Map* (SOM) que é um tipo de rede neural artificial em *machine learning* (KOHONEN, 2013). Os dados analisados se referem a 4.975 ocorrências do tipo não recorrente presentes na base da agência. Justifica-se a Artesp como objeto de estudo, pois a instituição foi criada em 2002 e tem como objetivo implementar políticas estaduais de transportes, gerenciar concessões e autorizações, além de garantir a prestação de serviços adequados aos usuários das rodovias.

Este estudo se justifica pois possui análises e proposição que visam a melhoria de gestão de tráfego. Primeiro, quanto à atualidade do tema, pois, como Rocha Filho *et al.* (2020) afirmam, o congestionamento de trânsito é um dos principais desafios no desenvolvimento urbano das grandes cidades. Segundo, a proposição de escala de criticidade usando aprendizado de máquina pode contribuir para a definição de novas estratégias de mitigação de congestionamento como sugere Gore *et al.* (2023). Terceiro, ao considerar que congestionamento não recorrente (CNR) é muitas vezes causado por incidentes de trânsito com fatalidade, a nova escala de criticidade pode contribuir para rápida resposta dos tomadores de decisão e dos agentes de trânsito quanto à segurança e à manutenção da vida de envolvidos (ALI; HUSSAIN; HAQUE, 2024).

2. MÉTODO DE PESQUISA

Tendo em vista o objetivo deste estudo que foi analisar a classificação de ocorrências de trânsito utilizada atualmente pela ARTESP em rodovias concedidas do Estado de São Paulo e propor uma escala de criticidade utilizando técnica de aprendizado de máquina, foram aplicadas as seguintes técnicas: testes não-paramétricos; tese de teste *post-hoc* para avaliar par a par os grupos de classificação; e técnica de *machine learning* para proposição de nova escala de criticidade.

A seguir, as etapas resumem o passo a passo executado no estudo:

- Etapa 1: Seleção da amostra de estudo.
- Etapa 2: Pré-processamento de dados.
- Etapa 3: Aplicação de teste estatístico para análise da **atual** classificação.
- Etapa 4: Aplicação da Rede Neural Artificial (*machine learning approach*).
- Etapa 5: Aplicação de teste estatístico para validação da **nova** classificação.

Em relação à Etapa 1, foram coletados os dados de 9.345 ocorrências de trânsito para o período de outubro de 2021 a abril de 2024 a partir da base de dados disponível no site da ARTESP. Desta amostra de dados coletada, 4.975 ocorrências de trânsito geraram congestionamento e interdição de rodovia. Segundo os dados da agência, há o registro de 31 lotes de concessões (ARTESP, 2024), sendo que, na amostra analisada, 87 pistas principais (simples e duplas), pistas marginais e acessos foram observadas.

Na Etapa 2, as ocorrências foram organizadas para que se pudesse analisar seu padrão. Sendo assim, para cada ocorrência havia um valor de tamanho de congestionamento (km), tempo de interdição de via (min) (TARIQ *et al.*, 2020), além de presença/ausência de fatalidade e quantidade de pessoas envolvidas na ocorrência (ALI; HUSSAIN; HAQUE, 2024), além da própria classificação feita pela agência. De acordo com os dados da base, a agência classifica suas ocorrências em 3 níveis de criticidade: leve, moderada e alta. Para essa classificação, a agência utiliza as variáveis listadas anteriormente, exceto quantidade de pessoas envolvidas, para justificar a ordem de criticidade. Vale mencionar que a agência não disponibiliza quais são os critérios de classificação, apenas apontam no registro da ocorrência a justificativa para a criticidade.

Apesar das variáveis estarem presentes nas justificativas de criticidade, os critérios variam de ocorrência para ocorrência. Por isso, este estudo reclassificou inicialmente todas as ocorrências a partir de critérios que mais frequentemente apareceram na amostra estudada. Dessa forma, as ocorrências foram reclassificadas para saber se atendiam ou não ao critério de criticidade moderada, neste caso, se houve congestionamento maior ou igual a 3,0 km. Da mesma maneira, as ocorrências foram reclassificadas para saber se atenderam ou não ao critério de criticidade alta, no caso, se houve interdição de pista por mais de 30 minutos ou se houve fatalidade na ocorrência. Lembrando que a agência define criticidade leve como não atendendo às características de ocorrências do tipo moderada nem alta.

Na Etapa 3, com as reclassificações executadas, uma matriz de confusão foi elaborada a fim de quantificar as ocorrências que atendiam, ao mesmo tempo, os critérios de classificação moderada e alta, além de quantificar as ocorrências que não atendiam a nenhum dos critérios mencionados anteriormente. Isso se justifica, pois, a elaboração de matriz de confusão permite investigar o comportamento de uma determinada classe e, com uma melhor compreensão de dados, propor recomendações futuras para melhorar a precisão de classificação (KRISHNAKUMARI *et al.*, 2017). Os procedimentos seguiram padrões de mineração de dados de acordo com Wu *et al.* (2021).

Posteriormente, dois quadrantes da matriz de confusão foram analisados, sendo: as

ocorrências que atendiam aos critérios moderado e alto ao mesmo tempo e as ocorrências que não atendiam aos critérios de moderado nem alto. Para verificar o padrão destas ocorrências, foram aplicados dois testes: o teste não-paramétrico de Kruskal-Wallis, pois havia mais de um grupo em análise (leve, moderado e alto), tendo em vista que as distribuições das variáveis não seguiram uma distribuição normal; e o teste *post-hoc* de Dunn-Bonferroni para identificar qual dos grupos era diferente (INSTITÓRIS *et al.*, 2022). As ocorrências atípicas foram tratadas para evitar viés na análise. Todos os testes e análises foram executadas no *software* SPSS v.29.

Na Etapa 4, a técnica *Self-Organizing Map* (SOM) foi aplicada a fim de agrupar as ocorrências de trânsito a partir dos padrões das variáveis tamanho de congestionamento, tempo de interdição de via, presença/ausência de fatalidade e quantidade de pessoas envolvidas na ocorrência. Existem várias técnicas de aprendizado de máquina e uma delas é a Rede Neural Artificial, a qual a SOM é uma das tipologias (ZHU *et al.*, 2020). A SOM é indicada para solução de problemas complexos relacionados à classificação e tem sido aplicada em diferentes áreas de estudos como finanças, ciências naturais e gestão de operações (KOHONEN, 2013). A técnica é do tipo não supervisionada e tem como objetivo agrupar uma determinada amostra pelos diversos neurônios da rede por meio da identificação de padrões (MELIN *et al.*, 2020). Por isso, a técnica tem a vantagem sobre a técnica *k-means* pois não necessita de parametrização do número de clusters à priori (HÖFER; MADLENER, 2020).

O primeiro procedimento para aplicação da SOM é a normalização dos dados para variáveis contínuas com métricas diferentes (VLAOVIĆ *et al.*, 2023) e *one-hot encoding* para variável binária (CLARK; SISSON; SHARMA, 2020). Deste modo, foram utilizadas as 3 variáveis que aparecem nas justificativas da agência, adicionando a variável quantidade de pessoas envolvidas que é contabilizada para cada ocorrência e que também está disponível na base da agência. Neste caso, justifica-se a adição desta última variável, pois em regiões mais populosas, o número de veículos envolvidos em incidentes de trânsito é maior (ALSAID; AMBILICHU, 2024) e, como sugerem Park *et al.* (2018), é uma variável relevante para análises no tema.

Em seguida, define-se a quantidade de neurônio da rede pela equação $5\sqrt{n}$ (PAINI *et al.*, 2016), sendo n a quantidade de amostra. Dessa forma, a rede SOM ficou configurada com 18 x 18 (324 neurônios) em formato hexagonal. O número de iterações do algoritmo (ou épocas) foi definido como 50 vezes o número de neurônios, utilizando distância euclidiana e taxa de aprendizagem de 0,35 para os cálculos. Dessa forma, é possível replicar a técnica em

outros estudos conforme sugere Casali, Aydin e Comes (2022). Para avaliar a rede bem como escolher a quantidade de grupos, foram utilizados os seguintes índices: Mean Quantization Error, Topological Error e Davies-Bouldin Index (CLARK; SISSON; SHARMA, 2020; VLAOVIĆ *et al.*, 2023). Os significados dos valores dos índices serão explicados na próxima seção. A rede foi executada no *software* R.

Por fim, após o agrupamento das ocorrências, foi feita a validação da nova escala. Na Etapa 5, foi aplicada a técnica não-paramétrica Jonckheere–Terpstra cujo objetivo é avaliar se os agrupamentos possuem tendência direcionais (crescente ou decrescente) e, uma vez apontada a existência, identificar se os grupos eram ou não diferentes entre si (LIMA *et al.*, 2022). Para a variável binária, presença/ausência de fatalidade na ocorrência, aplicou-se o teste de Qui-quadrado de Pearson a fim de verificar se as classes eram ou não associadas (ALINIZZI; HAIDER; ALRESHEEDI, 2022).

3. RESULTADOS E DISCUSSÕES

3.1. Análise da atual classificação de criticidade de ocorrências

Segundo a classificação de criticidade da ARTESP para ocorrências de trânsito nas rodovias estaduais, há um total de 4.975 ocorrências que geraram congestionamento e interdição de via. Destas ocorrências, 35,4% foram classificadas como leve, 31,2% como moderadas e 33,4% como alta. Essa distribuição balanceada das categorias atendeu aos pressupostos metodológicos descritos por (GAL-TZUR; BEKHOR; BARSKY, 2022). Em seguida, também foi testada se a distribuição amostral se assemelhava com uma distribuição normal (LIMA *et al.*, 2022), porém, os resultados dos testes de hipóteses foram significativos para as variáveis tamanho de congestionamento (km), tempo de interdição da via (min) e quantidade de pessoas envolvidas.

Em seguida, as ocorrências foram reclassificadas a fim de compreender se elas atendiam aos critérios de classificação moderado e alto. Assim, foi possível construir a Tabela 1 com a matriz de confusão entre as categorias. A partir da matriz, foi possível observar que 2.607 ocorrências podem ser, ao mesmo tempo, classificadas como moderadas e altas, seguindo o critério de tamanho de congestionamento maior que 3 km, tempo de interdição de via maior que 30 minutos e se houve presença ou não de fatalidade. Por outro lado, houve 187 ocorrências que não atenderam aos critérios mencionados e, por isso, foram classificadas como nem moderadas nem altas.

Tabela 1: Matriz de confusão com ocorrências reclassificadas

		Críticidade Moderada	
		Sim	Não
Críticidade Alta	Não	138	187
	Sim	2607	2043

Ao se analisar as 2.607 ocorrências quanto ao tamanho de congestionamento e tempo de interdição de via, a amostra apresentou as seguintes frequências: 36,3% leves, 40,4% moderadas e 23,3% altas. Um resultado observado nesta análise de classificação é que a agência classificou como leve 947 ocorrências que poderiam ser classificadas pelo menos como moderada ou alta.

Após a análise da matriz, foram executados testes não-paramétricos a fim de compreender melhor o comportamento das classificações realizadas pela agência. Assim, foram analisadas as 2.607 ocorrências que estão no quadrante sim/sim da matriz de confusão. O teste não-paramétrico de Kruskal-Wallis foi significativo para ambas variáveis observadas: tamanho de congestionamento ($p\text{-value} < 0,0001$) e tempo de interdição via ($p\text{-value} < 0,0001$).

Uma vez observado que houve diferença estatística entre os grupos classificados pela ARTESP, aplicou-se o teste *post-hoc* de Dunn-Bonferroni a fim de identificar qual dos grupos se diferenciaram. Pela análise par a par da variável tamanho de congestionamento (km), todas os grupos se diferenciaram entre si ($p\text{-value} < 0,001$), sendo que o grupo de ocorrências moderadas possui valores medianos maiores do que as ocorrências leves e, estes, maiores do que as ocorrências altas. Esse resultado pode ser explicado pelo fato de que a ausência de critérios claros empregados pela agência não permite separar totalmente as ocorrências moderadas dos demais grupos e ainda gera uma distorção entre os grupos leve e alto, uma vez que o grupo de ocorrências leves possui valor mediano maior que o grupo alto. A Tabela 2 mostra a comparação par a par dos grupos de classificação atual.

Tabela 2: Comparação par a par dos grupos de classificação atual para tamanho de congestionamento

Grupo 1 versus Grupo 2	Estatística de teste	Erro Padrão	Estatística de Teste Padrão	Sig. ^a
Alta versus Leve	138,130	37,496	3,684	0,001
Alta versus Moderado	446,446	36,346	12,283	0,000
Leve versus Moderado	-308,316	29,684	-10,387	0,000

a. Os valores de significância foram ajustados pela correção Bonferroni para vários testes.

Ao testar a variável tempo de interdição de via (≥ 30 minutos) para a amostra de 2.607 ocorrências, o teste não-paramétrico também indicou diferença entre os grupos. Ao se verificar a comparação par a par dos grupos, observou-se que a classificação alta apresentou diferença entre os grupos de ocorrências moderado e leve ($p\text{-value} < 0,0001$), enquanto os

grupos moderado e leve puderam ser considerados iguais ($p\text{-value} > 0,05$). Esse resultado indica novamente que há falta de critérios claros na classificação da agência, pois o grupo de ocorrência alto possui maior valor entre as três classificações da agência, porém o grupo moderado não se diferencia do grupo leve. A Tabela 3 mostra a comparação par a par dos grupos de classificação atual.

Tabela 3: Comparação par a par dos grupos de classificação atual para tempo de interdição de via

Grupo 1 versus Grupo 2	Estatística de teste	Erro Padrão	Estatística de Teste Padrão	Sig. ^a
Moderado versus Leve	13,563	31,738	0,427	1,000
Moderado versus Alto	-528,990	36,475	-14,503	0,000
Leve versus Alto	-515,427	37,153	-13,873	0,000

a. Os valores de significância foram ajustados pela correção Bonferroni para vários testes.

Por outro lado, ao se observar as 187 ocorrências classificadas na matriz de confusão como nem moderadas nem altas, pode-se observar as seguintes frequências: 51,3% leves, 25,7% moderadas e 23,0% altas. Esse resultado mostra que a classificação feita pela agência de que a criticidade leve é justificada pelo não atendimento dos critérios de classificação moderado e alto não funciona tão bem, pois cerca de metade das ocorrências poderiam ser classificadas como moderadas ou altas. Esses resultados da matriz de confusão permitem identificar que o critério para ocorrências leves possui padrão mal determinado (KRISHNAKUMARI *et al.*, 2017).

Da mesma forma, as variáveis tamanho de congestionamento (km) e tempo de interdição de via (min) foram analisadas neste quadrante a fim de entender o comportamento da classificação feita pela ARTESP. O teste de Kruskal-Wallis indicou que se deve reter a hipótese nula para ambas as variáveis, ou seja, os grupos são iguais. No caso da variável de tamanho de congestionamento o valor de $p\text{-value}$ foi igual a 23,3% e para a variável tempo de interdição de via foi igual a 77,6%. Dessa forma, evidencia-se que o critério utilizado para ocorrências leves não permite diferenciação precisa das outras classificações. A Tabela 4 mostra os valores do teste Kruskal-Wallis para a classificação atual.

Tabela 4: Teste de Kruskal-Wallis para ocorrência que não atendiam aos critérios moderados e alto


Variável	Amostra	Estatística de Teste	g.l.	Sig.
Tamanho de Congestionamento (km)	187	2,915	2	0,233
Tempo de Interdição da Via (min)	187	0,505	2	0,777

3.2. Análise da nova classificação de criticidade de ocorrências

Uma vez analisado que a classificação utilizada pela agência não consegue classificar adequadamente uma grande quantidade de ocorrências devido à complexidade do problema de congestionamento, aplicou-se as redes neurais artificiais do tipo *Self-Organizing Map*

(SOM). Os resultados observados para os índices de ajustes mostram que a rede conseguiu identificar um padrão nas ocorrências, pois seus valores ficaram próximos do valor zero, indicando melhor ajuste. Para o índice *Mean Quantization Error* o valor foi de 1,834 e o *Minimum Quantization Error* foi de 0,197. Esses valores significam que as distâncias entre os dados e o neurônio vencedor da rede diminuíram ao longo das épocas, ajustando melhor aos dados. Já o valor de *Topological Error* foi de 2,641, indicando que os neurônios do mapa neural correspondem bem a uma organização espacial dos dados de entrada. Por fim, *Davies-Bouldin Index* indica se o número de grupos escolhidos é satisfatório ou não. Neste estudo, quatro agrupamentos alcançou o valor de 2,653. Deve-se destacar que não existe valores de referência para estes índices, apenas que quanto mais próximos de zero, melhor. A Figura 1 mostra a composição da rede e a quantidade de ocorrências por grupo.

Figura 1: Mapa neural e quantidade de ocorrências por grupo



Em seguida, aplicou-se o teste de Jonckheere–Terpstra a fim de verificar se os 4 grupos de classificação se diferenciaram quanto às variáveis contínuas do estudo: tamanho de congestionamento, tempo de interdição de via e quantidade de pessoas envolvidas no incidente. Para todas as três variáveis, o teste não-paramétrico foi significativo ($p\text{-value} < 0,001$), indicando tendência de crescimento entre os quatro grupos da nova classificação. Após esse procedimento, verificou-se se os grupos eram diferentes entre si. Novamente, para todas as variáveis, as análises par a par foram menores do que 5%, indicando diferença entre os grupos. A Tabela 5 mostra os valores de média, mediana, intervalo de confiança para mediana e os desvios-padrão. A Tabela 6 mostra os valores de significância estatística para o teste de Jonckheere–Terpstra.

Tabela 5: Valores de média, mediana, intervalo de confiança para mediana e desvio-padrão

		Grupo 1	Grupo 2	Grupo 3	Grupo 4
Tamanho do Congestionamento (km)	Média	2,66	2,89	16,87	4,34
	Mediana	1,50	2,80	15,60	4,00
	Limite Inferior 95,0% para Mediana	1,00	2,50	15,00	3,40
	Limite Superior 95,0% para Mediana	2,00	3,00	18,00	6,00
	Desvio padrão	2,82	1,83	5,31	3,09
Tempo de Interdição de Via (min)	Média	663,74	88,64	318,59	119,56
	Mediana	608,50	79,00	315,00	102,00
	Limite Inferior 95,0% para Mediana	581,00	77,00	300,00	86,00
	Limite Superior 95,0% para Mediana	641,00	81,00	345,00	126,00
	Desvio padrão	199,54	49,94	145,82	73,93
Quantidade de Pessoas Envolvidas na Ocorrência	Média	0,88	1,96	1,52	39,56
	Mediana	0,00	2,00	1,00	39,00
	Limite Inferior 95,0% para Mediana	0,00	2,00	1,00	33,00
	Limite Superior 95,0% para Mediana	0,00	3,00	2,00	43,00
	Desvio padrão	1,34	1,40	0,91	9,51

Tabela 6: Valores do teste de Jonckheere–Terpstra

Variável	Estatística do Teste	Erro Padrão	Estatística de Teste Padronizado	Sig.
Tamanho do Congestionamento (km)	869672,00	20512,25	14,16	0,0000
Tempo de Interdição da Via (min)	498922,00	20561,04	-3,85	0,0001
Quantidade de Pessoas Envolvidas	808603,00	20731,86	10,44	0,0000

A diferença entre os grupos da escala permite avaliar de forma distinta as ocorrências de trânsito a partir das variáveis contínuas. Esse estudo exemplifica que a aplicação de técnicas de aprendizado de máquina permite identificar pequenas semelhanças em grande quantidade de amostra. Isso vai ao encontro de outros exemplos de aplicação identificados na literatura que também observaram bons resultados com a aplicação de técnicas de inteligência artificial (XU; LIU; YANG, 2024).

Diferentemente de outros estudos que utilizaram técnicas de aprendizado supervisionado (ASENCIO-CORTÉS *et al.*, 2016), os resultados observados aqui podem ser considerados um avanço, pois a técnica SOM é do tipo não supervisionada. A SOM fornece assim novas maneiras de classificar ocorrências de trânsito, permitindo maior refinamento de análises e melhor compreensão das condições que ocorrem os incidentes (SONG *et al.*, 2020).

Quanto ao teste Qui-quadrado de Pearson para a variável binária (*dummy*), presença/ausência de fatalidade, o valor foi significativo a 5% ($p\text{-value} < 0,001$), indicando que há uma associação com os quatro grupos da nova escala. A Tabela 7 mostra a análise de associação entre cada grupo da nova escala de criticidade e a variável presença/ausência de fatalidade. Pelos valores de resíduos ajustados, percebe que o Grupo 1 e Grupo 3 possuem tendência menor de presença de fatalidade, pois os valores são maiores que 1,96. Já o Grupo 2 apresentou valor de resíduo padronizado de 2,74, indicando tendência maior de presença de

fatalidade em ocorrências deste grupo. O Grupo 4 possui valor menor que 1,96, portanto, não significativo para fatalidade.

Tabela 7: Análise de associação entre presença de fatalidade e escala de criticidade

			Criticidade			
			Grupo 1	Grupo 2	Grupo 3	Grupo 4
Houve Fatalidade?	Não	Contagem	123	4108	94	34
		Contagem Esperada	112,2	4122,4	86,7	37,7
		% em Houve Fatalidade?	0,0	0,9	0,0	0,0
		% nos Grupos de Criticidade	1,0	0,9	0,9	0,8
		Resíduos ajustados	2,95	-2,74	2,24	-1,71
	Sim	Contagem	5	597	5	9
		Contagem Esperada	15,8	582,6	12,3	5,3
		% em Houve Fatalidade?	0,0	1,0	0,0	0,0
		% nos Grupos de Criticidade	0,0	0,1	0,1	0,2
		Resíduos ajustados	-2,95	2,74	-2,24	1,71

Ao se analisar cada grupo, os resultados apontam que as ocorrências do Grupo 2 possuem maior tendência de fatalidades. Assim, a presença de fatalidade depende do nível de criticidade, porém, com tendência menor de fatalidade nos Grupos 1 e 3. Ressalta-se que independentemente da classificação dos grupos, qualquer presença de fatalidade deve-se garantir total atendimento à ocorrência. Esse resultado pode ser um novo achado para a melhoria na gestão de tráfego, pois há um grupo em que a ocorrência aparece com maior associação com a criticidade, não se excluindo a possibilidade de ocorrência em outros grupos (ALI; HUSSAIN; HAQUE, 2024). Vale destacar que essas tendências em cada grupo quanto à fatalidade difere um pouco da classificação da agência, uma vez que este critério está ligado somente a criticidade alta, enquanto neste estudo é apontado em qual nível de criticidade há maior chances de aparecer fatalidade.

Por serem algoritmos de otimização, as redes podem classificar uma ocorrência em um determinado grupo em vez de classifica-lo em outro. Por isso, há índices de ajuste para avaliar o quanto a rede aderiu aos dados e identificou corretamente seus padrões. Ainda, a Tabela 5 mostra os padrões dos grupos, destacando a mediana, pois ela é a base para os cálculos estatísticos. Nesse sentido, os testes estatísticos mostram que há diferença significativa entre todos os grupos da rede e para todas as variáveis, inclusive a fatalidade. Vale destacar que as redes não associaram as ocorrências em grupos lineares, ou seja, não há uma escala linear ($A > B > C > D$), mas sim em um padrão distinto entre os grupos pelas diversas variáveis do modelo. O Grupo 1 se destaca por ter maior tempo de interdição de via e, talvez, possa ser explicado por desastres naturais, como enchentes e deslizamentos de terra. Da mesma forma, o Grupo 3 que apresentou maior congestionamento pode ser explicado por ocorrências com baixa probabilidade de fatalidade, mas que ocorrem em períodos de pico ou regiões metropolitanas (por exemplo, Campinas e São Paulo).

4. CONCLUSÃO

Este estudo teve como o objetivo deste estudo é analisar a classificação de ocorrências de trânsito utilizada atualmente pela ARTESP em rodovias concedidas do Estado de São Paulo e propor uma escala de criticidade utilizando técnica de aprendizado de máquina. Pela análise de dados executada em 4.975 ocorrências de trânsito, foi possível observar que a classificação vigente da agência não é capaz de atender às características das ocorrências. Esse problema tende a se perpetuar na base de dados se não corrigido, podendo gerar vieses em futuras tomadas de decisão.

A proposição de nova escala via aprendizado de máquina, isto é, aplicação de técnica de rede neural artificial se mostrou eficiente para a complexidade do problema estudado. A classificação em grupos distintos permite melhor gerenciamento das ocorrências, com priorização e alocação de recursos necessários de acordo com a gravidade do problema. O destaque foi para a semelhança entre os quatro grupos quanto à presença de fatalidade nas ocorrências, sugerindo que ocorrências com esta característica sejam tratadas independentemente do tamanho de congestionamento ou tempo de interdição de via.

As técnicas aplicadas permitem à agência uma classificação mais coerente, implicando em melhor alocação de recursos (viaturas, guinchos, ambulâncias *etc.*) no atendimento de ocorrências futuras. Essa alocação de recursos pode contribuir com a gestão eficaz de ocorrências, reduzindo os tempos de interdição de vias e tamanho de congestionamento. A tomada de decisão quanto às bases de operações também pode se beneficiar da análise deste estudo, uma vez que a determinação da localização de bases pode ser definida se uma quantificação correta das ocorrências for feita quanto a sua criticidade.

Por fim, este estudo apresenta limitações. A primeira limitação diz respeito à ausência de critérios bem definidos pela agência. Com critérios mais bem definidos seria possível refinar as análises da matriz de confusão. A segunda limitação diz respeito à ausência de outras rodovias concedidas no estado, mas que são de responsabilidade do governo federal. Essas rodovias possuem também ocorrências com diversas causas, mas não possuem as mesmas variáveis utilizadas neste estudo.

REFERÊNCIAS BIBLIOGRÁFICAS

ALI, Y.; HUSSAIN, F.; HAQUE, M. M. Advances, challenges, and future research needs in machine learning-based crash prediction models: A systematic review. **Accident Analysis & Prevention**, v. 194, n. June 2023, p. 107378, jan. 2024. Disponível em: <<https://doi.org/10.1016/j.aap.2023.107378>>.

ALINIZZI, M.; HAIDER, H.; ALRESHEEDI, M. Assessing Traffic Congestion Hazard Period due to Commuters' Home-to-Shopping Center Departures after COVID-19 Curfew Timings. **Computation**,

v. 10, n. 8, p. 132, 2 ago. 2022. Disponível em: <<https://www.mdpi.com/2079-3197/10/8/132>>.

ALSAID, L. A. Z. A.; AMBILICHU, C. A. Performance measurement in urban development: unfolding a case of sustainability KPIs reporting. **Journal of Accounting in Emerging Economies**, v. 14, n. 1, p. 48–74, 9 fev. 2024. Disponível em: <<https://www.emerald.com/insight/content/doi/10.1108/JAEE-09-2021-0299/full/html>>.

ARTESP. **Rodovias e Concessionárias**. Disponível em: <<http://www.artesp.sp.gov.br/StyleLibrary/extranet/rodovias/rodovias-e-concessionarias.aspx>>. Acesso em: 21 jun. 2024.

ASENCIO-CORTÉS, G. *et al.* A novel methodology to predict urban traffic congestion with ensemble learning. **Soft Computing**, v. 20, n. 11, p. 4205–4216, 2016.

CALEFFI, F. *et al.* Influência das condições climáticas e de acidentes na caracterização do comportamento do tráfego em rodovias. **Transportes**, v. 24, n. 4, p. 57, 2016.

CASALI, Y.; AYDIN, N. Y.; COMES, T. Machine learning for spatial analyses in urban areas: a scoping review. **Sustainable Cities and Society**, v. 85, n. April, p. 104050, 2022. Disponível em: <<https://doi.org/10.1016/j.scs.2022.104050>>.

CLARK, S.; SISSON, S. A.; SHARMA, A. Tools for enhancing the application of self-organizing maps in water resources research and engineering. **Advances in Water Resources**, v. 143, n. November 2019, p. 103676, set. 2020. Disponível em: <<https://doi.org/10.1016/j.advwatres.2020.103676>>.

DE SOUZA, A. M. *et al.* Traffic management systems: A classification, review, challenges, and future perspectives. **International Journal of Distributed Sensor Networks**, v. 13, n. 4, 2017. Disponível em: <<https://doi.org/10.1177/1550147716683612>>.

GAL-TZUR, A.; BEKHOR, S.; BARSKY, Y. Feature engineering methodology for congestion forecasting. **Journal of Traffic and Transportation Engineering (English Edition)**, v. 9, n. 6, p. 1055–1068, 2022.

GORE, N. *et al.* Developing modified congestion index and congestion-based level of service. **Transport Policy**, v. 131, n. May 2022, p. 97–119, 2023. Disponível em: <<https://doi.org/10.1016/j.tranpol.2022.12.008>>.

HÖFER, T.; MADLENER, R. A participatory stakeholder process for evaluating sustainable energy transition scenarios. **Energy Policy**, v. 139, p. 111277, abr. 2020. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0301421520300355>>.

IBGE. **Projeções da População do Brasil e Unidades da Federação por sexo e idade: 2010-2060**. Disponível em: <<https://www.ibge.gov.br/estatisticas/sociais/populacao/9109-projecao-da-populacao.html>>. Acesso em: 22 jun. 2024.

INSTITÓRIS, L. *et al.* Drug consumption of suspected drug-influenced drivers in Hungary (2016–2018). **Forensic Science International**, v. 336, 2022.

KOHONEN, T. Essentials of the self-organizing map. **Neural Networks**, v. 37, p. 52–65, jan. 2013. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0893608012002596>>.

KRISHNAKUMARI, P. *et al.* Traffic congestion pattern classification using multiclass active shape models. **Transportation Research Record**, v. 2645, n. 1, p. 94–103, 2017. Disponível em: <<https://doi.org/10.3141/2645-11>>.

LIMA, P. A. B. *et al.* Sustainable Human Development at the Municipal Level: A Data Envelopment Analysis Index. **Infrastructures**, v. 7, n. 2, p. 12, 21 jan. 2022. Disponível em: <<https://www.mdpi.com/2412-3811/7/2/12>>.

MELIN, P. *et al.* Chaos , Solitons and Fractals Analysis of Spatial Spread Relationships of Coronavirus (COVID-19) Pandemic in the World using Self Organizing Maps. v. 138, 2020.

MFINANGA, D.; FUNGO, E. Impact of Incidents on Traffic Congestion in Dar es Salaam City. **International Journal of Transportation Science and Technology**, v. 2, n. 2, p. 95–108, 2013.

Disponível em: <<http://dx.doi.org/10.1260/2046-0430.2.2.95>>.

MODI, Y. *et al.* A comprehensive review on intelligent traffic management using machine learning algorithms. **Innovative Infrastructure Solutions**, v. 7, n. 1, p. 1–14, 2022. Disponível em: <<https://doi.org/10.1007/s41062-021-00718-3>>.

PAINI, D. R. *et al.* Global threat to agriculture from invasive species. **Proceedings of the National Academy of Sciences**, v. 113, n. 27, p. 7575–7579, 5 jul. 2016. Disponível em: <<https://pnas.org/doi/full/10.1073/pnas.1602205113>>.

PARK, H. *et al.* Real-time prediction and avoidance of secondary crashes under unexpected traffic congestion. **Accident Analysis and Prevention**, v. 112, n. October 2017, p. 39–49, 2018. Disponível em: <<https://doi.org/10.1016/j.aap.2017.11.025>>.

ROCHA FILHO, G. P. *et al.* Enhancing intelligence in traffic management systems to aid in vehicle traffic congestion problems in smart cities. **Ad Hoc Networks**, v. 107, p. 102265, 2020. Disponível em: <<https://doi.org/10.1016/j.adhoc.2020.102265>>.

SADOLLAH, A. *et al.* Management of traffic congestion in adaptive traffic signals using a novel classification-based approach. **Engineering Optimization**, v. 51, n. 9, p. 1509–1528, 2019. Disponível em: <<https://doi.org/10.1080/0305215X.2018.1525708>>.

SENATRAN. **Frota Veículos Nac.** Disponível em: <<https://www.gov.br/transportes/pt-br/assuntos/transito/conteudo-Senatran/frota-de-veiculos-2024>>. Acesso em: 21 jun. 2024.

SONG, T. J. *et al.* Crash classification by congestion type for highways. **Applied Sciences (Switzerland)**, v. 10, n. 7, p. 1–15, 2020.

TARIQ, M. T. *et al.* Combining Machine Learning and Fuzzy Rule-Based System in Automating Signal Timing Experts' Decisions during Non-Recurrent Congestion. **Transportation Research Record**, v. 2674, n. 6, p. 163–176, 2020.

TU, Y. *et al.* Deep traffic congestion prediction model based on road segment grouping. **Applied Intelligence**, v. 51, n. 11, p. 8519–8541, 2021.

VLAOVIĆ, Ž. D. *et al.* Mapping energy sustainability using the Kohonen self-organizing maps - Case study. **Journal of Cleaner Production**, v. 412, n. April, 2023.

WU, W.-T. *et al.* Data mining in clinical big data: the frequently used databases, steps, and methodological models. **Military Medical Research**, v. 8, n. 1, p. 44, 11 ago. 2021. Disponível em: <<https://mmrjournal.biomedcentral.com/articles/10.1186/s40779-021-00338-z>>.

XU, M.; LIU, H.; YANG, H. Ensemble learning based approach for traffic incident detection and multi-category classification. **Engineering Applications of Artificial Intelligence**, v. 132, n. October 2023, p. 107933, 2024. Disponível em: <<https://doi.org/10.1016/j.engappai.2024.107933>>.

ZARINDAST, A.; PODDAR, S.; SHARMA, A. A Data-Driven Method for Congestion Identification and Classification. **Journal of Transportation Engineering, Part A: Systems**, v. 148, n. 4, p. 1–10, 2022.

ZHU, G. *et al.* Influence of mining activities on groundwater hydrochemistry and heavy metal migration using a self-organizing map (SOM). **Journal of Cleaner Production**, v. 257, p. 120664, 2020. Disponível em: <<https://doi.org/10.1016/j.jclepro.2020.120664>>.