

Previsão do tempo de evacuação e recomendação de estratégias de resgate em cenários de evacuação horizontal com evacuadores enfraquecidos

Raimundo Juracy Campos Ferro Junior¹, Gustavo Augusto Lima de Campos¹

¹Universidade Estadual do Ceará, Fortaleza, Brasil

junior.ferro@aluno.uece.br, gustavo.campos@uece.br

Abstract. *One of the challenges in the context of studying evacuation processes and rescue situations is the lack of studies and tools that address dependent evacuees or the possibility of simulating different rescue strategies. This work aims to fill this gap. Proposing an agent-based architecture that can produce data, train regression algorithms to make predictions about horizontal evacuation scenarios with dependent evacuees, and propose rescue strategies. The decision tree and multilayer perceptron network algorithms presented the best result for the regression of the evacuation time and the random-forest model was able to reach an accuracy of 92% when classifying the scenarios based on the most appropriate strategy for the rescue team.*

Resumo. *Um dos desafios no contexto do estudo de processos de evacuação e situações de resgate é a falta de estudos e ferramentas que contemplem evacuantes dependentes ou a possibilidade de simular diferentes estratégias de resgate. Este trabalho visa preencher essa lacuna. Propondo uma arquitetura baseada em agentes que pode produzir dados, treinar algoritmos de regressão para fazer previsões sobre cenários de evacuação horizontal com evacuantes dependentes e propor estratégias de resgate. Os algoritmos de árvore de decisão e rede perceptron multicamadas apresentaram o melhor resultado para a regressão do tempo de evacuação e o modelo de floresta-aleatória conseguiu atingir uma acurácia de 92% ao classificar os cenários com base na estratégia mais adequada para a equipe de resgate.*

1. Introdução

Este trabalho faz parte do macro domínio do estudo de cenários de evacuação. Segundo a [K. et al. 2011], a evacuação é um processo social em que um conjunto de **agentes se deslocam de uma área ameaçada por algum evento de perturbação social ou estrutural para uma área percebida como menos ameaçadora.**

Cada processo de evacuação possui características únicas que alteram todas as variáveis do processo. Devido à complexidade e número de cenários possíveis quando se fala em evacuação, existem diferentes subproblemas que abordam cenários específicos dentro do campo.

Conforme observado em [Larusdottir et al. 2014, Rahouti et al. 2020, Liu et al. 2016, Chen and Tong 2019] uma porção dos estudos de evacuação subestimam a importância de estudar o impacto de agentes externos à evacuação e também

subestimam o impacto das capacidades e dependências dos evacuantes sobre o processo de evacuação.

Neste estudo, esses dois tópicos comumente subestimados são explorados. Em específico o problema que este trabalho se propõe a explorar é o de **seleção de estratégias de resgate em situações de evacuação horizontal com evacuados enfraquecidos**.

É possível traçar a relevância deste problema analisando o estado da arte e softwares desenvolvidos no contexto de evacuação. Uma das formas de estudo que tem se destacado é o uso de simulações computacionais ou modelagem 3D para recriar cenários desafiadores para reproduzir e permitir que esses cenários complexos sejam estudados de forma acessível. Segundo o [Camillen et al. 2009, TESTA 2018], o uso de simulações ajuda a diminuir o custo e o risco de estudar evacuações, principalmente com o auxílio de softwares como CrowdSim [Cassol 2016] e BioCrowds [Bicho 2009].

No entanto, como apontado por [TESTA 2018], um dos problemas na utilização destes softwares para formular e testar rotas de evacuação é o tempo gasto para desenvolver as simulações. Normalmente, o desenvolvimento dessas simulações requer a modelagem detalhada de todo o ambiente, o que é um processo demorado. Estudos com modelos de aprendizado de máquina como [TESTA 2018] obtiveram sucesso em prever o tempo de evacuação em um tempo de produção menor devido a redução na necessidade de detalhamento do ambiente.

Outro problema observado nessas ferramentas é a incapacidade de personalizar diferentes comportamentos e capacidades para evacuadores e equipes de resgate. Normalmente, essas ferramentas usam apenas algoritmos de roteamento como A^* para calcular a rota de fuga para uma saída. No trabalho de [Larusdottir and Dederichs 2012] explora-se como os agentes dependentes, como crianças, pessoas com deficiência ou lesões, **não são representados em vários estudos no contexto da evacuação**.

Este trabalho visa quebrar essas barreiras e **conceber um sistema** que possa receber rapidamente informações sobre um processo de evacuação horizontal, fazer previsões sobre o tempo de evacuação e identificar como uma equipe de resgate pode conduzir melhor o processo de resgate.

2. Abordagem metodológica

2.1. Definição do problema: Seleção de Planos de Evacuação e Resgate

O problema da formulação de planos de evacuação é a identificação de quais comportamentos, técnicas e condutas, executadas pelos evacuantes, que minimizem o tempo necessário para retirar todos os evacuados do ambiente.

Este problema é amplo e complexo e dá origem a outros subproblemas de evacuação. Por exemplo, no trabalho [Wang et al. 2016], o ambiente de evacuação é uma cidade, e os evacuados são cidadãos, que se locomovem a pé ou de carro e que tentam atravessar as ruas para sair da cidade. Este tipo de cenário de evacuação possui propriedades únicas que irão diferir até mesmo de estudos que também ocorrem em grande escala, como o estudo de [Cimellaro et al. 2017].

O problema estudado neste trabalho é o de **seleção de estratégias de resgate em situações de evacuação horizontal com evacuados enfraquecidos**. Neste tipo de

problema, a equipe de resgate é composta por um grupo de agentes, inicialmente externos à evacuação, que entram voluntariamente no ambiente para acelerar o processo.

Nesse tipo de problema, o foco é encontrar as técnicas e comportamentos que uma equipe de resgate irá realizar para minimizar o tempo necessário para que os evacuantes saiam do ambiente ou cheguem em um local seguro.

Nos experimentos desenvolvidos neste trabalho, a equipe de resgate era composta por uma coleção de um a cinco agentes que guiam suas ações baseadas numa estratégia de resgate previamente implementada. O objetivo final da arquitetura proposta é: **dado um cenário específico, prever o tempo de evacuação de cada estratégia e combinar essas previsões definindo a estratégia mais adequada.**

2.2. Abordagem Proposta

Para resolver o problema apresentado na seção anterior o primeiro passo da abordagem foi a criação de um modelo de simulação baseado em agentes que representasse o contexto estudado.

Esse modelo de simulação foi usado no segundo passo da abordagem, criar uma base de dados contendo os resultados da aplicação de três estratégias de resgate em diferentes configurações de ambientes.

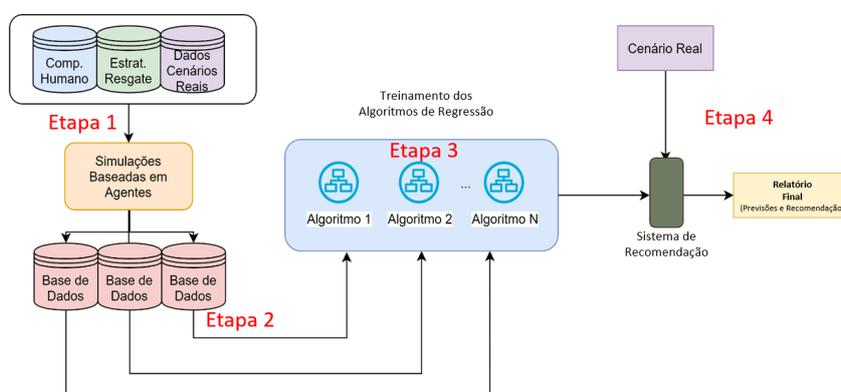


Figura 1. Abordagem Proposta

Com a base de dados de diversos cenários de evacuação pronta, o terceiro passo foi a utilização dessa base de dados para treinar um conjunto de algoritmos de aprendizado de máquina a fim de obter modelos especializados em prever o tempo de evacuação de cada uma das estratégias.

O último passo foi a formulação de um novo modelo que encapsule as previsões de todos os algoritmos de previsão e possa identificar qual a melhor estratégia de resgate.

Ao final dessas etapas o resultado é um sistema que pode receber informações de um cenário novo e retornar um relatório com os tempos de evacuação previsto no caso da aplicação de cada estratégia de resgate e qual é a estratégia mais indicada. As seções abaixo exploram em detalhes cada uma das etapas da abordagem.

2.3. Passo 1 - Modelo de simulação baseado em agentes

Normalmente, a primeira opção para criar um projeto de aprendizado de máquina seria encontrar um conjunto de dados que possua dados relativos ao problema a ser trabalhado. No entanto, não foi encontrado nenhuma base de dados que atendesse as necessidades e contemplasse os cenários abordados neste estudo. Assim, como ponto de partida, um modelo de simulação foi desenvolvido.

A linguagem e plataforma Netlogo[Tisue and Wilensky 2004] foi escolhida para ser usada na montagem do modelo de simulação. A plataforma é comumente usada em estudos com simulações que necessitam da modelagem individual ou coletiva dos comportamentos dos agentes devido a capacidade de personalização dos comportamentos.

O modelo de simulação é uma extensão do proposto no estudo de [Junior 2018]. No modelo implementado os ambientes consistiram em salas retangulares, sem obstáculos, com comprimentos e larguras que variam de dois a quarenta metros. Esse tipo de configuração simples é usado em outros estudos como [Chen and Tong 2019], [Camillen et al. 2009], para controle da complexidade e pode ser estendido futuramente para configurações mais complexas.

2.3.1. Formulação dos agentes evacuantes

O ambiente da simulação foi populado por agentes evacuantes e agentes de resgate, os **agentes evacuantes** estão divididos em três categorias que dizem respeito as capacidades físicas e comportamentos deles. A formulação dessas três categorias e os atributos delas foram feitas utilizando as observações e modelagem definidas em [Liu et al. 2016, Rahouti et al. 2020, Larusdottir and Dederichs 2012].

A primeira categoria de agentes evacuantes, denominados como “auto-organizados”, consiste nos agentes que podem se movimentar e evacuar o ambiente sem ajuda do time de resgate. Eles possuem um mecanismo de tomada de decisão personalizável onde cada agente avaliará o entorno e se deslocará para locais mais atrativos.

Um local é considerado mais atraente com base em sua densidade e distância dele para a saída mais próxima. As equações abaixo demonstram o cálculo da atratividade executado por cada evacuante deste grupo ao decidir sua movimentação.

$$A_t = \alpha \times A_e + \beta \times A_i \quad (1)$$

tal que:

- A_t : Atratividade total do local.
- A_e : Atratividade com base na densidade do local.
- A_i : Atratividade com base na distância do local para a saída mais próxima.
- α e β : Pesos de cada atratividade, sendo $\alpha + \beta = 1$.

Como é possível observar na equação os parâmetros alfa e beta regulam a importância da distância e da densidade, cada evacuante recebe um valor de alfa aleatório entre 0.2 e 0.8 e o valor de beta é definido como $\alpha - 1$. As equações abaixo definem o cálculo da atratividade de distância e de densidade.

$$D_{ep} = A_i / (2 + R + 1)^2 \quad (2)$$

$$A_e = (D_{emax} - D_{ep}) / (D_{emax} - D_{emin}) \quad (3)$$

tal que:

- A_e : Atratividade com base na densidade.
- D_{emax} : Densidade máxima entre todos os locais
- D_{ep} : Densidade do local atual
- D_{emin} : Densidade mínima entre todos os locais
- A_i : Número de alunos dentro do raio de alcance
- R : Raio de alcance do agente

$$A_i = (D_{imax} - D_{ip}) / (D_{imax} - D_{imin}) \quad (4)$$

tal que:

- A_i : Atratividade com base na distância para a saída mais próxima.
- D_{imax} : Distância máxima entre todos os locais.
- D_{ip} : Distância do locais atual.
- D_{imin} : Distância mínima entre todos os locais.

O segundo grupo de evacuantes são os agentes "parcialmente assistidos". Eles representam pessoas que precisam de ajuda pontual durante o processo de evacuação. Eles têm menos velocidade do que os agentes auto-organizados, mas têm o mesmo processo de tomada de decisão e utilizam as mesmas equações. No entanto, em intervalos aleatórios o sistema de tomada de decisão dele é temporariamente desligado até receber ajuda de alguém da equipe de resgate. Fazendo com que esse evacuante fique parado até receber assistência.

O terceiro grupo de evacuados são os agentes "completamente assistidos". Eles representam pessoas que ficaram gravemente feridas e devem ser carregados pela equipe de resgate. Esses agentes não têm nenhum mecanismo de tomada de decisão ou velocidade. Sua única ação é enviar um sinal para a equipe de resgate pedindo ajuda.

Outra observação é que os agentes evacuantes não interagem diretamente uns com os outros.

2.3.2. Formulação dos agentes de resgate

O time de resgate possui um sistema de tomada de decisão diferente do sistema dos agentes evacuantes. Ele é uma evolução do sistema de tomada de decisão apresentado para o agente professor no trabalho de [Junior 2018].

Cada agente tem armazenado qual o tipo de estratégia ele deve executar, assim ao entrar em funcionamento ele observa o ambiente, formula uma lista de prioridades (e atualiza periodicamente essa lista) e, dependendo da prioridade no topo da lista, realiza uma ação diferente. Se a prioridade for um agente específico, todo o seu movimento

será orientado para atingir o objetivo e aplicar a ação necessária. Se a prioridade for um evacuante "parcialmente assistido", a ação será ajudar esse agente, ativando o mecanismo de tomada de decisão dele. No caso de agentes "completamente assistidos", sua ação será levar o evacuante até a saída mais próxima. Quando não há mais evacuantes no ambiente, os socorristas vão em direção à saída e deixam o ambiente.

Três estratégias de resgate foram modeladas para o estudo. O primeiro é chamado de **comportamento aleatório**, no qual cada socorrista resgata um evacuante aleatório que não está sendo resgatado ou como alvo de outro socorrista. O segundo comportamento é chamado de **parcial-completo** (referente à ordem em que os evacuantes são priorizados), em que a equipe de resgate prioriza ajudar os agentes parcialmente assistidos. Por fim, há também o comportamento **por proximidade**, em que cada socorrista resgata a pessoa mais próxima que não está sendo resgatada.

A escolha dessa abordagem foi feita para separar a implementação do comportamento genérico dos agentes, da implementação das estratégias. Assim, caso novas estratégias sejam formuladas só é necessário fornecer uma função que modele uma lista de prioridade sem alterar a formulação do agente em si.

2.3.3. Parâmetros do modelo de simulação

Com os comportamentos implementados o modelo de simulação foi finalizado, cada simulação recebe como parâmetro o número de agentes, o tamanho do ambiente, as proporções de cada categoria de agente evacuante, a quantidade de agentes do time de resgate, tamanho da saída e a estratégia do time de resgate.

2.4. Passo 2 - Construção das bases de dados

Com o modelo de simulação pronto foi possível começar a geração da base de dados para treinar os algoritmos de previsão, na realidade foram criadas três bases de dados, uma para cada estratégia de resgate implementada. A escolha de gerar três bases foi feita para que os algoritmos da próxima etapa fossem especializados em regredir o tempo de evacuação de uma única estratégia.

Foram gerados dez mil cenários de evacuação, ou seja, configurações diferentes de ambiente, variando os parâmetros **dimensões do ambiente, número de evacuantes, proporções das categorias de evacuantes, quantidade de agentes no time de resgate e tamanho da saída**, ou seja esses cenários iniciais independente da estratégia de resgate do time.

A figura 2 esquematiza o processo. Para cada estratégia de evacuação foram executadas simulações de cada um dos dez mil cenários, esse processo foi repetido 10 vezes para que fosse possível extrair a média de tempo de evacuação de cada cenário aplicando cada uma das três estratégias de resgate.

2.5. Passo 3 - Treinamento dos algoritmos de regressão

Com os conjuntos de dados prontos, foi realizado o processo de treinamento e teste dos algoritmos de regressão numérica, com proporção de 70% para treinamento e 30% para teste. Três algoritmos de regressão numérica foram selecionados: uma árvore de decisão,

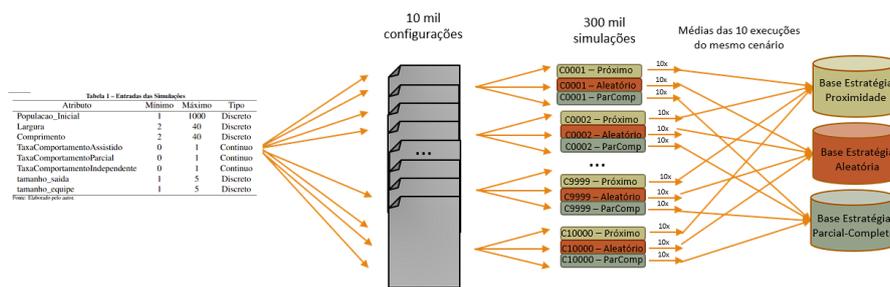


Figura 2. Abordagem Proposta

uma rede Perceptron multicamada e um regressor de mínimos quadrados. Os modelos foram desenvolvidos em python usando as implementações da biblioteca scikit-learn.

Para cada algoritmo foram implementadas três instâncias, uma para cada estratégia da equipe de resgate usando o conjunto de dados da respectiva estratégia. As features utilizadas para treinar os modelos foram **número de Agentes evacuantes, proporção de cada tipo de agente evacuante, tamanho das saídas, tamanho da equipe de resgate, e dimensões do ambiente**. O valor alvo a ser regredido foi o tempo de evacuação.

Ao final, foram geradas nove instâncias de aprendizado de máquina, onde cada uma aplicou um algoritmo diferente especializado em prever o tempo de evacuação caso a equipe de resgate utilizasse uma estratégia específica. A seção de resultados aborda as métricas de desempenho obtidas no processo de regressão.

2.6. Passo 4 - Classificação da melhor estratégia de resgate

Com os nove modelos de aprendizado de máquina treinados foi necessário elaborar uma forma de combinar as saídas desses modelos e definir qual a melhor estratégia de resgate para cada cenário. Para combinar os resultados e prover uma resposta primeiro era necessário retornar aos conjuntos de dados e definir para cada um dos dez mil cenários usados qual a melhor estratégia.

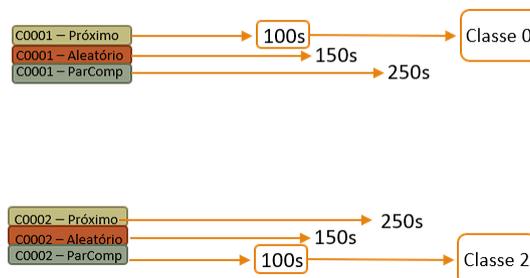


Figura 3. Catalogando Cenários

Para cada cenário foi comparado o tempo de evacuação médio das simulações da aplicação de cada estratégia, a estratégia que fosse mais rápida para aquele cenário era marcada como a “classe” daquele cenário. A imagem 3 exemplifica esse processo.

Por exemplo, supondo que para o cenário “C0001” a média do tempo de evacuação das dez execuções desse cenário com a estratégia de “Proximidade” tenha sido 100s, a média quando aplicamos a estratégia “Aleatória” fosse 150s e a média da estratégia “Parcial-Completo” fosse 250s, esta amostra seria marcada como do tipo 0, ou seja, a melhor estratégia de resgate é a por proximidade. Esse processo foi repetido até que todos os cenários fossem catalogados entre as três classes.

Ao final dessa catalogação foram extraídos dos 10 mil cenários 6 mil cenários de tal forma que o número de elementos de cada classe fosse igual. Isso foi feito para garantir um balanceamento nessas classes.

O objetivo dessa catalogação é para que fosse possível nesta etapa criar um modelo capaz de combinar as nove previsões dos algoritmos e chegar a uma classe que define a melhor estratégia.

Para fazer esse processo de classificação, que define a melhor estratégia foram elaboradas três abordagens. Uma de controle, onde os resultados das previsões seriam ignorados e uma das três estratégias seria escolhida aleatoriamente como a melhor. Uma abordagem gulosa, onde a estratégia com menor tempo de evacuação seria escolhida. Por último foi treinado um modelo de floresta-aleatória que recebe as nove previsões dos tempos de evacuação dos algoritmos e classifica a amostra.

O treinamento e teste do modelo de floresta aleatória foi feito com uma nova base de dados feita a partir dos 6mil cenários mencionado anteriormente nesta seção, os cenários passaram pelos nove modelos de regressão e seus resultados formaram as nove features do novo conjunto de dados e o alvo do modelo eram as classes. A divisão de treinamento e teste foram também de 70% e 30%, respectivamente. Este modelo também foi implementado usando python e a biblioteca scikit-learn.

3. Experimentos e Resultados

É importante a observação de que ao final das 4 etapas, duas análises precisam ser feitas acima dos experimentos. Primeiro é análise dos resultados obtidos pelos modelos de regressão, ou seja avaliar se os tempo de evacuação previstos foram suficientemente próximos do tempo de evacuação observado nas simulações. Em segundo lugar, precisa ser feita a análise da identificação da melhor estratégia ao combinar os resultados das previsões. As seções abaixo discutem os resultados de ambas análises.

Na seção 3.1 é discutido inicialmente os resultados observados e como cada estratégia se comportou, essa análise é importante para traçar o perfil desejado das previsões dos algoritmos de regressão. Após traçar esse perfil nas seções seguintes é feito o comparativo desse perfil com o obtido ao aplicar cada modelo de previsão.

Na seção 3.5 é explorado o resultado do processo de classificação que identifica qual a estratégia mais adequada.

3.1. Resultados - Observando o tempo de evacuação e comparando com as previsões

Foram coletados os dados do conjunto de teste, que são apresentados na tabela 1. Ao analisar os dados, foram levantadas algumas observações para serem utilizadas na comparação com os resultados das técnicas de regressão.

Tabela 1. Resultados - Métricas de Avaliação - Observado nas Simulações de Teste

Métrica	Estratégia: Aleatória	Estratégia: Parcial-Completo	Estratégia: Proximidade
Tempo Médio	752,29	758,22	1171,05
Mediana do Tempo	266	272	377
Desvio Padrão	1232,45	1232,07	1784,73
Tempo de Evacuação Mínimo	1	1	1
Tempo de Evacuação Máximo	9761	9780	9956

Analisando o tempo médio de evacuação das estratégias, observou-se que a diferença entre as estratégias "aleatória" e "parcial-completa" foi inferior a 1% e que a estratégia "por proximidade" teve o pior resultado com uma diferença de 55% em relação à outros.

Ao comparar o tempo médio de evacuação, a estratégia "por proximidade" permaneceu com o pior desempenho, mas neste caso, com valor 27,8% maior que a estratégia "parcial-completa" e 29,4% maior que a "aleatória".

Quando avaliado o desvio padrão do tempo de evacuação, as estratégias "aleatória" e "parcial-completa" novamente apresentaram números menores, com diferença inferior a 1%. Em contrapartida, a estratégia "por proximidade" teve um valor 44% maior que ambas. Não foram observadas diferenças nos tempos mínimos de evacuação, mas observou-se que a estratégia de proximidade apresentou o maior tempo máximo.

3.2. Resultados: Mínimos Quadrados

A técnica dos mínimos quadrados foi a que apresentou os piores resultados em todas as métricas de avaliação. Ao analisar o tempo médio de evacuação, localizado na Tabela 2, percebe-se que esta técnica foi capaz de preservar a ordenação das estratégias. No entanto, não manteve a semelhança observada entre as estratégias "aleatória" e "parcial-completa". Enquanto nos cenários de teste os valores médios das estratégias diferiram em menos de um por cento, aqui uma estratégia teve quase o dobro do tempo médio da outra. A estratégia "por proximidade" apresentou os maiores valores: 9,6% maior que o caso "parcial-completo" e 110% maior que o caso aleatório.

Tabela 2. Resultados - Métricas de Avaliação - Mínimos Quadrados

Métrica	Estratégia: Aleatória	Estratégia: Parcial-Completo	Estratégia: Proximidade
Tempo Médio	652,42	1254,06	1375,29
Mediana do Tempo	521,81	1239,28	886,83
Desvio Padrão	874,33	324,87	1260,63
Tempo de Evacuação Mínimo	3	4	4
Tempo de Evacuação Máximo	5415,08	1981	7862,26
MAPE	5,36	16,81	8,75

Ao avaliar a similaridade do tempo médio observado nas simulações e o equivalente produzido pelo modelo de mínimos quadrados, o tempo médio foi 15% menor que o esperado para o caso aleatório, 65% maior que o caso parcial-completo e 17% maior que por proximidade.

Observou-se também que as previsões feitas pela técnica apresentaram tempos máximos abaixo do esperado. Enquanto isso, os valores medianos foram maiores para todas as estratégias.

3.3. Resultados: Multi-Layer Perceptron

O modelo MLP apresentou melhores resultados que a técnica dos mínimos quadrados. Analisando os dados da Tabela 3, é possível observar que a rede MLP também foi capaz de preservar a ordem no ranking das estratégias e apresentou valores mais próximos do esperado. Quando avaliada a similaridade esperada entre as estratégias "aleatória" e "parcial-completa", a diferença entre elas foi de 7%. Enquanto isso, como esperado, a estratégia "por proximidade" apresentou os maiores valores, com tempo médio 51% maior que a estratégia "parcial-completa" (esperado em torno de 55%) e 63% maior que a aleatória (valor esperado, neste caso, também foi de 55%). Em resumo, o MLP foi capaz de fazer a média do ranking das estratégias e preservou as diferenças entre as estratégias melhor do que os mínimos quadrados.

Tabela 3. Resultados - Métricas de Avaliação - - MLP

Métrica	Estratégia: Aleatória	Estratégia: Parcial-Completo	Estratégia: Proximidade
Tempo Médio	588,54	633,59	962,39
Mediana do Tempo	220,30	242,98	381,97
Desvio Padrão	968,12	1003,48	1375,29
Tempo de Evacuação Mínimo	2	2	4
Tempo de Evacuação Máximo	8181	8366	8507
MAPE	0,9	0,59	0,87

Em todas as métricas, as redes MLP apresentaram resultados melhores que a técnica anterior, porém, observou-se que a rede MLP tende a resultados abaixo do esperado. Quando comparado ao observado nos casos de teste, quase todos os valores ficaram abaixo do esperado, exceto apenas os tempos mínimos e o tempo mediano de evacuação da estratégia "por proximidade".

3.4. Resultados: Árvore de Decisão para Regressão

A árvore de decisão apresentou os melhores resultados, considerando que manteve a ordenação das estratégias e foi a que melhor reproduziu as semelhanças entre as estratégias. Ao analisar a similaridade esperada entre as estratégias "aleatória" e "parcial-completa", apresentadas na Tabela 4, a diferença foi de apenas 3% (o valor esperado foi de 1%). A estratégia "por proximidade", por sua vez, apresentou o maior tempo de evacuação, sendo 48% maior que a estratégia "parcial-completa" e 51% superior ao caso "aleatório", sendo que a diferença esperada para os dois dados foi de 55%.

Tabela 4. Resultados - Métricas de Avaliação - Árvore de Decisão

Métrica	Estratégia: Aleatória	Estratégia: Parcial-Completo	Estratégia: Proximidade
Tempo Médio	745,96	768,85	1143,27
Mediana do Tempo	256	278	381
Desvio Padrão	1266,88	1226,99	1723,99
Tempo de Evacuação Mínimo	2	2	4
Tempo de Evacuação Máximo	9865	9800	9944
MAPE	0,33	0,34	0,41

Ao comparar os tempos médios, a média produzida pelas previsões e a média observada nas simulações para a estratégia aleatória foi inferior a 1%. Para o caso "parcial-completo", essa diferença foi de 13%, e para a estratégia "por proximidade", a diferença foi de 2,4%.

3.5. Resultados: Identificação da melhor estratégia de resgate

Tabela 5. Resultados - Acurácia na previsão de melhor estratégia

	Aleatório	Guloso	Floresta-Aleatória
Acurácia	0,32	0,42	0,92

Quando avaliamos a classificação dos cenários, definindo a estratégia mais indicada, foi observado que a estratégia "aleatória" teve uma acurácia de apenas 32%, um resultado dentro dos valores esperado visto que as classes eram balanceadas. A estratégia gulosa teve apenas uma acurácia de 40% mostrando que usar apenas o menor valor também não apresentou melhoras suficientes na recomendação. Enquanto isso o modelo de floresta-aleatória treinado com as nove instâncias foi capaz de acertar a estratégia mais adequada com 92% de acurácia. Esse resultado não foi inteiramente inesperado visto que os modelos de árvore apresentaram melhor desempenho na etapa anterior.

4. Conclusões

Ao analisar o desempenho da abordagem proposta, os resultados foram promissores e dentro das expectativas. O algoritmo de mínimos quadrados foi o que apresentou os piores resultados, sendo inviável a sua utilização em contextos autênticos. No entanto, o uso de um algoritmo linear foi uma proposição para fazer a comparação com os demais, portanto não havia expectativa de que ele tivesse um desempenho tão bom quanto os demais. O MLP apresentou resultados promissores, apesar de apresentar desempenho médio inferior ao relatado em estudos semelhantes, demonstrando que o contexto estudado agrega maior complexidade, e a perda de desempenho era esperada. Em contrapartida, a árvore de decisão obteve resultados competitivos com outras abordagens.

Ao avaliar o desempenho do sistema de recomendação, os resultados foram satisfatórios, pois a ordenação das estratégias foi feita corretamente, e a classificação teve um desempenho de 92% de acerto com a floresta aleatória.

Por fim, é possível dizer que o trabalho atingiu seus objetivos de formular e produzir uma arquitetura flexível e extensível para ajudar a lidar com situações de

evacuação. Nenhum outro trabalho encontrado foi capaz de unificar a mesma quantidade de informações e ainda produzir resultados consistentes dentro da complexidade do domínio da aplicação.

Referências

- Bicho, A. (2009). *Da modelagem de plantas à dinâmica de multidões: um modelo de animação comportamental bio-inspirado*. PhD thesis.
- Camillen, F., Capri, S., Garofalo, C., M., et al. (2009). Multi agent simulation of pedestrian behavior in closed spatial environments. In *Proceedings...*, pages 375–380, Toronto. IEEE Toronto International Conference Science and Technology for Humanity (TIC-STH), IEEE.
- Cassol, V. J. (2016). *Crowdsim : a framework to estimate safety of egress performance in real life scenarios*. PhD thesis. Faculdade de Informática.
- Chen, C.-K. and Tong, Y.-H. (2019). Evacuation simulation considering action of guard in artificial attack. *Chinese physics B*, 28(1):10503.
- Cimellaro, G. P., Ozzello, F., Vallero, A., Mahin, S., and Shao, B. (2017). Simulating earthquake evacuation using human behavior models. *Earthquake Engineering & Structural Dynamics*, 46(6):985–1002.
- Junior, F. (2018). An agent-based simulation model for analyzing the impact of teacher behavior in case of evacuation from daycare classrooms. *Anais do Encontro Nacional de Inteligência Artificial e Computacional (ENIAC)*, pages 656–667.
- K., P., Statler, B., and Matthew (2011). *Encyclopedia of disaster relief*. Sage Publications, Thousand Oaks.
- Larusdottir, A., Dederichs, A., and Nilsson, D. (2014). *Evacuation of Children: Focusing on daycare centers and elementary schools*. PhD thesis, Technical University of Denmark, Department of Civil Engineering, Lyngby.
- Larusdottir, A. R. and Dederichs, A. S. (2012). Evacuation of children: Movement on stairs and on horizontal plane. *Fire Technology*, 48(1):43–53.
- Liu, R., Jiang, D., and Shi, L. (2016). Agent-based simulation of alternative classroom evacuation scenarios. *Frontiers of Architectural Research*, 5(1):111 – 125.
- Rahouti, A., Lovreglio, R., Gwynne, S., Jackson, P., Datoussaïd, S., and Hunt, A. (2020). Human behaviour during a healthcare facility evacuation drills: Investigation of pre-evacuation and travel phases. *Safety Science*, 129:104754.
- TESTA, E. S. (2018). *Modelo de estimação de multidões pra cenários de emergência*. Master's thesis. Escola Politécnica.
- Tisue, S. and Wilensky, U. (2004). Netlogo: A simple environment for modeling complexity. In *Proceedings...*, pages 16–21, Boston. International Conference on Complex Systems, New England Complex Systems Institute.
- Wang, H., Mostafizi, A., Cramer, L. A., Cox, D., and Park, H. (2016). An agent-based model of a multimodal near-field tsunami evacuation: Decision-making and life safety. *Transportation Research Part C: Emerging Technologies*, 64:86 – 100.