

CLUSTERIZAÇÃO DE ALVARÁS NA DEFINIÇÃO DE PONTOS ÓTIMOS PARA INSTALAÇÃO DE PARQUÍMETROS DE ESTACIONAMENTO ROTATIVO

Fagner Sutel de Moura

Marcos Feder

Empresa Pública de Trânsito e Circulação de Porto Alegre

RESUMO

O uso intenso do automóvel gera uma demanda crescente por espaços de estacionamento em vias públicas urbanas. A fim de racionalizar o uso de estacionamentos em vias públicas muitas cidades adotaram a política de Estacionamentos Rotativos Pagos - ERPs. Um dos desafios para garantir a viabilidade na prestação do serviço prestado em ERPs diz respeito à obtenção de índices ideais da taxa da ocupação de vagas. O presente trabalho busca prover por meio de algoritmos de aprendizagem de máquina mecanismos de predição de taxas de ocupação a fim de definir locais ótimos para implantação de ERPs. Por fim, buscou-se demonstrar o desempenho de cada algoritmo na previsibilidade das taxas de ocupação dos ERPs, apresentando modelos com elevado grau de erros de generalização e outros com níveis de acurácia superiores a 75%.

Palavras-chave: estacionamento rotativo pago, desempenho, aprendizado de máquina, acurácia.

ABSTRACT

The intensive use of vehicles generates high demand for parking spaces on urban public roads. In order to arrange the use of parking lots on public roads, many municipalities have adopted on-street Metered Parking Policy - MPP. One of the challenges to ensure viability in the provision of the service provided in MPP is to ensure the occupancy rate. This work seeks to provide, through machine learning algorithms, mechanisms of prediction of occupancy rates in order to define optimal locations for the implementation of MPP. Lastly, we try to present the performance of each algorithm in the predictability of occupancy rates of MPP, presenting models with a high degree of generalization errors and others with levels of accuracy higher than 75%.

Keywords: Metered Parking Policy, performance, machine learning, accuracy.

1. INTRODUÇÃO

As questões relacionadas à mobilidade urbana são diversas e exigem soluções criativas para novos desafios, bem como soluções alternativas para demandas históricas do modelo de transporte e circulação nas grandes cidades (LUZ; BASTOS, 1997). O veículo de transporte individual representa um papel preponderante em nossa cultura e enquanto modo de transporte é determinante na dinâmica dos deslocamentos nas cidades brasileiras (RIBEIRO, 2016; SILVA, 2013).

A massificação do uso do transporte individual gera uma demanda crescente pelo uso do espaço viário urbano, seja para satisfazer a necessidade de deslocamentos, seja para estacionamentos. Essa demanda acarreta a saturação da capacidade viária dos centros urbanos, gerando constantes desafios para a gestão da mobilidade (ÁLVAREZ, 2017; PEREIRA; MOREIS; FERREIRA, 2012).

Dentre os desafios históricos relacionados a gestão da mobilidade, um tema pouco abordado refere-se à gestão de estacionamentos em vias públicas (HAIFUCH et al., 2007; MIRANDA; MACIEL; FEDER, 2005). Frente a demanda crescente por espaços de estacionamento em vias urbanas, a solução adotada por muitos municípios foi a implementação de políticas de estacionamentos rotativos pagos - ERPs (CAPRI, 2002). Enquanto atividade de gestão de estacionamentos em vias públicas, a adoção de políticas de ERPs exige uma receita mínima suficiente para remunerar a operação do sistema e sustentar a qualidade do serviço.

O presente estudo visa desenvolver uma metodologia de classificação e predição por meio de

técnicas de aprendizado de máquina para identificação de locais ótimos para implantação de parquímetros em ERPs, resultando em taxas de ocupação capazes de viabilizar sua operação. Por fim será realizada a avaliação dos algoritmos utilizados por meio de validação cruzada. Para que este objetivo seja atingido serão abordados os seguintes objetivos específicos:

1. Mapear e georreferenciar o uso do solo no município de Porto Alegre para fins de atividade econômica.
2. Identificar, clusterizar e classificar as regiões de atividade econômica mapeadas.
3. Identificar os parquímetros relacionando-os às regiões econômicas em que estão inseridos.
4. Criar uma matriz de atributos dos parquímetros nas diferentes regiões econômicas, contendo dados de ocupação, número de vagas de ERPs, índices de atividade econômica no entorno, medidas de distância entre parquímetros e pontos de centralidade econômica que atuem como atributos preditivos da taxa de ocupação.
5. Uso de algoritmos de aprendizado de máquina para identificar a influência de variáveis preditivas sobre o comportamento da variável objetivo - taxa de ocupação.
6. Aplicação de técnicas de aprendizado de máquina para predição de taxas de ocupação em novas áreas de ERPs com base nos dados obtidos nos objetivos de 1 a 5.
7. Avaliação das técnicas de aprendizagem de máquina por meio de validação cruzada e identificação das técnicas mais adequadas para determinar regiões ótimas para implantação de parquímetros nos ERPs.

2. REFERENCIAL TEÓRICO

Os estacionamentos rotativos pagos costumam apresentar uma ocupação média ao redor de 40% (ARAÚJO; MOREIRA; RODRIGUES, 2008; CAPRI, 2002); além disso, costuma-se considerar como 30% o valor limite entre baixa ocupação e ocupação viável (CAPRI, 2002), entendendo-se como ocupação viável aquela capaz de sustentar a operação do sistema.

A literatura especializada ao abordar questões relacionadas às taxas de ocupação em ERPs busca explicar a variação da ocupação a partir dos índices de infrações cometidas ou o nível de satisfação do usuário (ARAÚJO; MOREIRA; RODRIGUES, 2008; CAPRI, 2002; CASSIANO, 2014; ELIAS, 2001; PARADELA et al., 2015). Durante o desenvolvimento do presente estudo não foram encontrados outros trabalhos que se dediquem em identificar elementos explicativos das taxas de ocupação nas diferentes áreas de ERP a partir de modelos preditivos.

No presente trabalho considera-se como alternativa viável para predição das taxas de ocupação, a abordagem logística de problemas de localização, ou *Facility Location* (LIAO; GUO, 2008; LORENA et al., 2001), a qual se ocupa da determinação da localização de instalações que atendam as demandas dos usuários do sistema (DUECK, 2009; VARUGHESE; RAJ S, 2017).

A partir da problemática dos problemas de localização, a disposição espacial dos parquímetros e vagas de ERPs relativamente ao destino dos usuários pode ser considerada para determinar a função custo da localização e assim determinar a utilidade do sistema de ERPs. A abordagem de problemas de localização permite modelar o problema de ocupação dos ERPs de forma a estimar quando; dado um conjunto de possíveis locais para instalação de parquímetros, qual subconjunto satisfaz as necessidades dos usuários, minimizando as distâncias em relação ao

destino final e maximizando a ocupação (DUECK, 2009). Este processo de otimização combinatória visa modelar o uso de instalações de forma a atingir o maior número de usuários dentro de uma área específica de atuação, tornando efetivo o sistema quando minimiza o custo percebido pelo usuário e maximiza o resultado do sistema em termos de ocupação (VARUGHESE; RAJ S, 2017).

Considerando o uso de modelos preditivos nas análises, faz-se necessária a determinação da capacidade dos algoritmos aplicados em avaliar novos conjuntos de informações sem viés. Em se tratando de algoritmos de avaliação e classificação, medidas de desempenho recomendáveis são acurácia, sensibilidade e especificidade, mensurados na escala de 0 a 1, onde os valores de referência próximos a zero indicam fraco desempenho e forte desempenho à medida que se aproximam de 1 (PAARSCH; GOLYAEV, 2016).

3. ASPECTOS METODOLÓGICOS

Os estudos apontados refletem a preocupação em estimar taxas de desrespeito, a satisfação dos usuários, bem como as taxas mínimas para sustentar os custos operacionais de ERPs, sem discutir a viabilidade dos locais definidos como ERPs para obtenção da ocupação desejada.

Amparado na teoria dos problemas de localização, este estudo considera como hipótese explicativa para a taxa de ocupação dos ERPs a localização dos parquímetros em relação aos destinos dos usuários, bem como o número e densidade de pontos de destino no entorno dos mesmos parquímetros.

Enquanto medidas de localização e centralidade serão utilizados atributos denominados centróide e exemplar, que representam a cada cluster o local de maior concentração de alvarás, caracterizando-se como um ponto de centralidade gravitacional capaz de gerar maior atratividade entre os usuários do sistema. Em relação à distribuição dos alvarás, serão utilizadas medidas de densidade de alvarás num raio de 100 metros de cada parquímetro, sua distribuição enquanto atividades de comércio e serviços, bem como sua quantidade e densidade por km² a cada região em que os parquímetros operam.

As etapas do trabalho se dividem em coleta de dados, georreferenciamento, clusterização, classificação, construção de matrizes de dados, e aplicação de métodos de aprendizado de máquina por meio de treino, validação e teste de algoritmos.

3.1. Coleta de dados

Os dados foram obtidos de duas fontes, sendo elas, o portal “<http://datapoa.com.br/>” onde foram obtidos os registros dos alvarás do município de Porto Alegre no ano de 2017, classificados segundo o segmento de comércio e serviços. Também foram obtidos os registros de receita média anual dos parquímetros nas diferentes regiões de ERPs no município em 2017, contendo o registro do número de vagas de cada parquímetro, número de horas de operação/ano e a receita anual, permitindo calcular a razão receita/horas de operação que forneceu a taxa de ocupação das vagas de cada parquímetro.

3.2 Processamento de dados

Os dados de alvarás foram georreferenciados através da interface de programação de aplicativos do Google Maps e posteriormente clusterizados através do método de *affinity propagation*. O método *affinity propagation* é um método de clusterização heurística que visa identificar o

número e arranjo natural de clusters por meio de medidas de similaridade e dissimilaridade. Para realizar a clusterização de alvarás, o algoritmo foi implementado utilizando os dados de latitude e longitude de um conjunto amostral de vinte mil alvarás extraídos do conjunto total de 178519 estabelecimentos, onde foram identificados 133 clusters Figura 1.

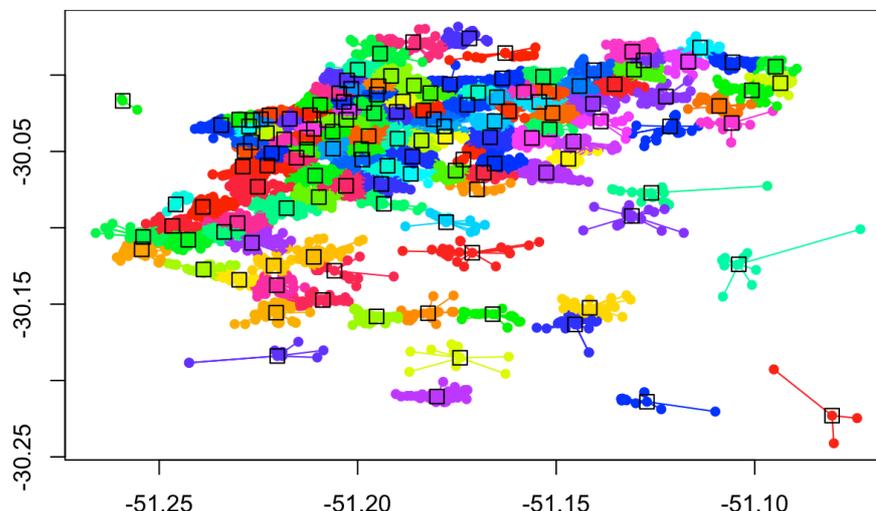


Figura 1: Identificação de 133 clusters e suas medidas de centralidade.

3.3 Classificação dos dados

Após a identificação dos clusters, através de um processo iterativo os 178519 alvarás foram classificados de acordo com o cluster correspondente, formando o mapa de regiões econômicas de Porto Alegre Figura 2.

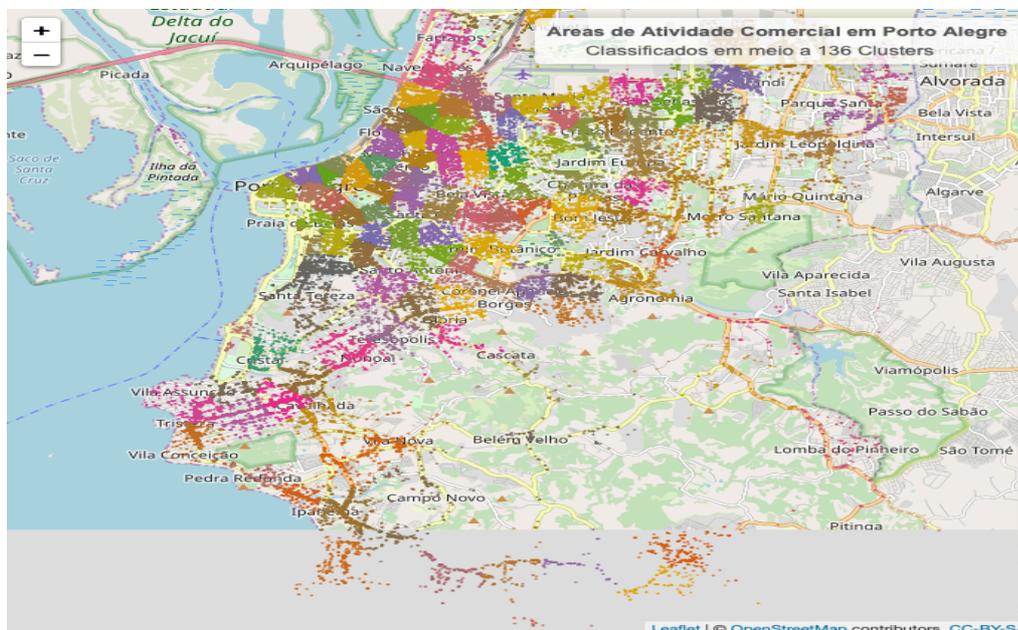


Figura 2: Mapa dos alvarás de Porto Alegre classificados por regiões econômicas.

Uma vez classificados os alvarás, foram extraídas medidas relativas à área, número de alvarás e densidade de alvarás de cada cluster, Figura 3(a). Para identificação dos centróides e exemplares foram recuperados os atributos fornecidos pelo método de *Afinity Propagation* em

que o centróide representa o valor correspondente ao centro de massa do conjunto de elementos do cluster, e onde o exemplar corresponde à localização do alvará mais próximo do centróide, considerado, portanto, elemento mais representativo do centro de equilíbrio Figura 3(b). Após identificação dos clusters, seus atributos e medias de centralidade, foram acrescentadas as localizações dos parquímetros para obtenção de suas distâncias relativas aos centróides e exemplares mais próximos Figura 3(b).

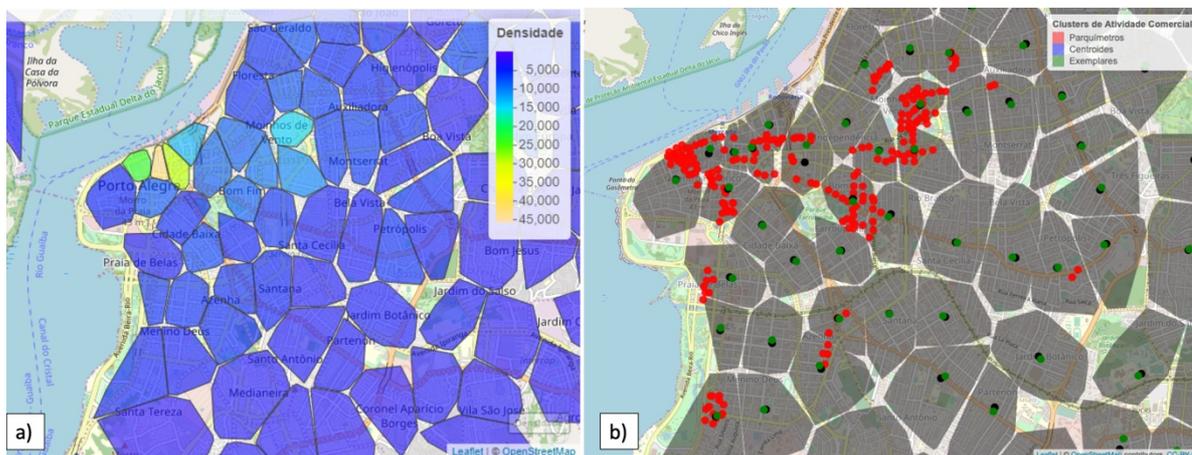


Figura 3: Mapas de clusters com densidade, centralidade e localização de parquímetros.

3.4 Preparação dos conjuntos de treino validação e teste

Uma vez obtidos os clusters e seus atributos foi criada uma matriz com os cruzamentos desses atributos e dados dos parquímetros, ficando identificados na dimensão vertical da matriz os 210 parquímetros existentes no município e na dimensão horizontal os atributos dos parquímetros como vagas, horas de operação, receita média, ocupação média, acrescidos das informações espaciais dos clusters como área, número de alvarás, alvarás por km², os atributos compostos pelas distancias de cada parquímetro em relação ao centróide e exemplar do respectivo cluster, número de alvarás num raio de 100m dos parquímetros e a distribuição percentual dos alvarás entre as atividades de comércio e serviço.

Após gerada a matriz foi adicionada uma variável *dummy*, considerada como variável de desfecho dicotômico, referente os percentuais de ocupação, onde os parquímetros com ocupação superior a 30% receberam o valor 0 (zero) e aqueles com ocupação igual ou inferior a 30% receberam o valor 1 (um), enquanto os demais atributos da matriz foram considerados como variáveis preditoras do modelo.

Após preparadas e tratadas as variáveis do conjunto de parquímetros, o grupo foi dividido em um conjunto de treino com 180 unidades observacionais e o conjunto de validação com as 30 restantes, sendo cada uma retirada de modo aleatório do conjunto total, permitindo que ambos os conjuntos pudessem conter a mesma estratificação de todas as áreas de ERP de Porto Alegre.

Para montar o conjunto de teste foram utilizados dados de receita e ocupação de oito parquímetros de uma nova área de ERPs no entorno de um centro comercial de Porto Alegre, em um cluster sem ERPs até então. Com o acréscimo de um novo conjunto de dados de teste, buscou-se analisar o quando os algoritmos de aprendizado são aderentes aos parâmetros de

classificação quando aplicados a um novo conjunto de dados.

Uma vez definidos os conjuntos de treino, validação e teste os dados foram submetidos a fase de aprendizado de máquina. Nessa etapa o conjunto de treino foi submetido aos algoritmos de aprendizado de máquina definidos no estudo; gerando os classificadores e então os submetendo ao conjunto de validação e por fim, os avaliando por meio do conjunto de teste (RASHCKA; MIRJALILI, 2017).

3.5 Aprendizado de máquina

Sobre conjunto de treino foram aplicados os algoritmos de *Naive Bayes*, Regras de Decisão, Regressão Logística, Regressão Linear, Árvores de Decisão, Floresta Randômica, Rede Neural Artificial, Máquina de Vetores de Suporte e K-Vizinhos mais próximos (KNN).

No conjunto de treino a variável de desfecho foi mantida para fins de obtenção do modelo de classificação do algoritmo, constituindo um modelo de aprendizado supervisionado. A partir dos treinos realizados com cada algoritmo foram gerados classificadores para cada técnica a serem aplicados sobre os conjuntos de validação e teste.

Gerados os classificadores, estes foram aplicados sobre o conjunto de validação desprovido da variável de desfecho original. Durante a etapa de validação a variável de desfecho foi predita a cada iteração dos classificadores com os parâmetros do conjunto por meio da função de classificação que considera os atributos do conjunto de validação como parâmetros de decisão.

Com as variáveis de desfecho preditas a cada classificador sobre o conjunto de validação, foram criadas matrizes identificando os elementos do conjunto de teste com desfecho predito na validação e seu respectivo valor real, considerado padrão-ouro, permitindo avaliar o desempenho de cada classificador na determinação dos valores esperados por meio de medidas de acurácia, sensibilidade e especificidade.

A última etapa foi aplicar os passos da etapa de validação sobre o conjunto de teste composto por parquímetros recentemente implantados em uma nova região do município de Porto Alegre. A introdução de um novo conjunto de dados permitiu avaliar o desempenho dos algoritmos em estimar a ocupação de parquímetros em novas áreas de ERPs. A avaliação dos algoritmos na etapa de teste se deu reproduzindo os mesmos testes de acurácia, sensibilidade e especificidade aplicados sobre o conjunto de validação.

Considerando a taxa de ocupação superior a 30% como valor de referência para instalação de parquímetros; para fins de avaliação de desempenho de algoritmos no presente estudo, o teste de acurácia apontou o grau de exatidão na identificação de valores referenciais. A sensibilidade indicou o poder de identificar os valores de referência desejados e a especificidade informou quanto o modelo é capaz de apontar elementos que não satisfaçam os valores de referência perseguidos (HULLEY et al., 2015).

3.6 Análise estatística

Uma vez geradas as matrizes de cada classificador, as mesmas foram transformadas matrizes de confusão constituídas de quadro indicadores que são: desfechos verdadeiros positivos (casos

com valor de referência corretamente preditos), falsos positivos (casos sem valor de referência incorretamente preditos), verdadeiros negativos (casos sem valores de referência corretamente preditos) e falsos negativos (casos com valores de referência incorretamente preditos). Para cada matriz de confusão foram obtidos os valores de acurácia, sensibilidade e especificidade de cada algoritmo de forma verificar o desempenho de cada algoritmo Figura 4.

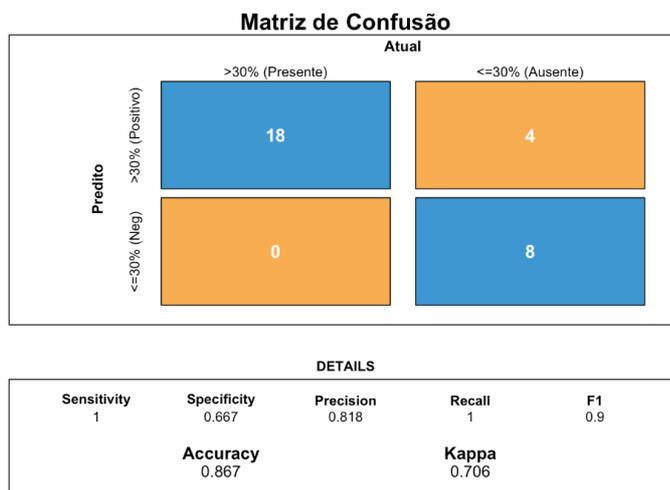


Figura 4: Exemplo de Matriz de Confusão e valores de Acurácia, Sensibilidade e Precisão

3.6.1. Análise da etapa de validação

Durante a validação, os nove algoritmos testados geraram as previsões de desfecho sobre conjunto de 30 parquímetros, sendo estes valores comparados com os valores reais. Dentre os modelos validados o melhor desempenho foi do modelo de K-vizinhos mais próximos, com 83% de acurácia e sensibilidade de 100%; enquanto que os modelos *Naive Bayes* e Rede Neural Artificial apresentaram especificidade de 67% Tabela 1.

Tabela 1: Resultados do conjunto de validação

Modelo	Acurácia	Sensibilidade	Especificidade
Naive Bayes	0.70	0.72	0.67
Regras de Decisão	0.60	0.72	0.42
Regressão Logística	0.67	0.83	0.42
Regressão Linear	0.63	0.78	0.42
Arvore de Decisão	0.53	0.72	0.25
Floresta Randômica	0.73	0.89	0.50
Rede Neural Artificial	0.77	0.83	0.67
Máquina Suporte de Vetores	0.70	0.83	0.50
K Vizinhos mais próximos (KNN)	0.83	1.00	0.58

3.6.2. Análise da etapa de teste

Durante a etapa de teste foram utilizados dados da nova área de operação de ERPs, com intuito de avaliar a aderência dos modelos a novos conjuntos de dados. Esta abordagem permitiu atestar a utilidade dos modelos na predição das taxas de ocupação em novas áreas de operação.

A aplicação dos modelos treinados e validados sobre o conjunto de teste gerou flutuações nos valores das métricas de acurácia, sensibilidade e especificidade em alguns dos modelos, enquanto outros mantiveram os valores da fase de validação. Enquanto o modelo de KNN apresentou melhoria de desempenho no conjunto de teste, o modelo de *Naive Bayes* apresentou significativa queda de performance para as três medidas de desempenho, ao passo que o modelo de Rede Neural Artificial manteve o mesmo índice de acurácia com uma redução na sensibilidade e aumento de especificidade *Tabela 2*.

Tabela 2: Resultados do conjunto de teste

Modelo	Acurácia	Sensibilidade	Especificidade
Naive Bayes	0.38	0.67	0.20
Regras de Decisão	0.60	0.72	0.42
Regressão Logística	0.67	0.83	0.42
Regressão Linear	0.63	0.78	0.42
Arvore de Decisão	0.53	0.72	0.25
Floresta Randômica	0.77	0.94	0.50
Rede Neural Artificial	0.77	0.78	0.75
Máquina Suporte de Vetores	0.70	0.83	0.50
K Vizinhos mais próximos (KNN)	0.87	1.00	0.67

A análise comparativa da variação dos resultados durante as fases de validação e teste demonstrou que os algoritmos de Regras de Decisão, Regressão Logística, Regressão Linear, Árvore de Decisão e Máquina de Suporte de Vetores mantiveram o mesmo desempenho, enquanto o algoritmo de *Naive Bayes* apresentou queda significativa no desempenho, com uma redução de 46% na acurácia, redução de 7% na sensibilidade e queda de 70% na especificidade, reduzindo a capacidade preditiva do mesmo frente a novos conjuntos de dados; esta redução de desempenho pode ser explicada pela correlação existente entre variáveis preditoras, uma vez que o algoritmo de *Naive Bayes* considera todas variáveis independentes quando calcula as probabilidades associadas entre variáveis preditoras e de desfecho (LANGLEY; SAGE, 1994). O algoritmo de Floresta Randômica apresentou um tímido ganho de desempenho de 5% de acurácia e 6% de sensibilidade. Por fim, o modelo de KNN apresentou ganho de desempenho de 5% de acurácia e 16% de especificidade *Tabela 3*.

Tabela 3: variação percentual no desempenho dos algoritmos

Modelo	Acurácia	Sensibilidade	Especificidade
Naive Bayes	-46%	-7%	-70%
Regras de Decisão	0%	0%	0%
Regressão Logística	0%	0%	0%
Regressão Linear	0%	0%	0%
Arvore de Decisão	0%	0%	0%
Floresta Randômica	5%	6%	0%
Rede Neural Artificial	0%	-6%	12%
Máquina de Suporte De Vetores	0%	0%	0%
K-Vizinhos mais próximos (KNN)	5%	0%	16%

4. RESULTADOS

Os dados do conjunto de teste permitiram identificar que o modelo de *Naive Bayes* apresentou sobreajuste ao modelo de treino, pois quando testado pelo conjunto de validação apresentou bom desempenho preditivo, porém, quando submetido ao novo modelo de teste, o algoritmo perdeu significativo desempenho, sendo pouco resiliente à novos conjuntos de dados Figura 5.

Dentre os algoritmos que mantiveram o desempenho durante as etapas de validação e teste; os modelos de Regras de Decisão, Regressão Logística, Regressão Linear, e Árvore de Decisão apresentaram valores de acurácia, sensibilidade e especificidade tímidos; enquanto o modelo de Máquina de Suporte de Vetores apresentou bom desempenho. Os algoritmos que apresentaram ganho de desempenho na etapa de teste foram KNN e Floresta Randômica, com ganhos de acurácia de 5% para ambos, ganho de sensibilidade de 6% e 0% e sensibilidade de 0% e 16% de especificidade para Floresta Randômica e KNN respectivamente.

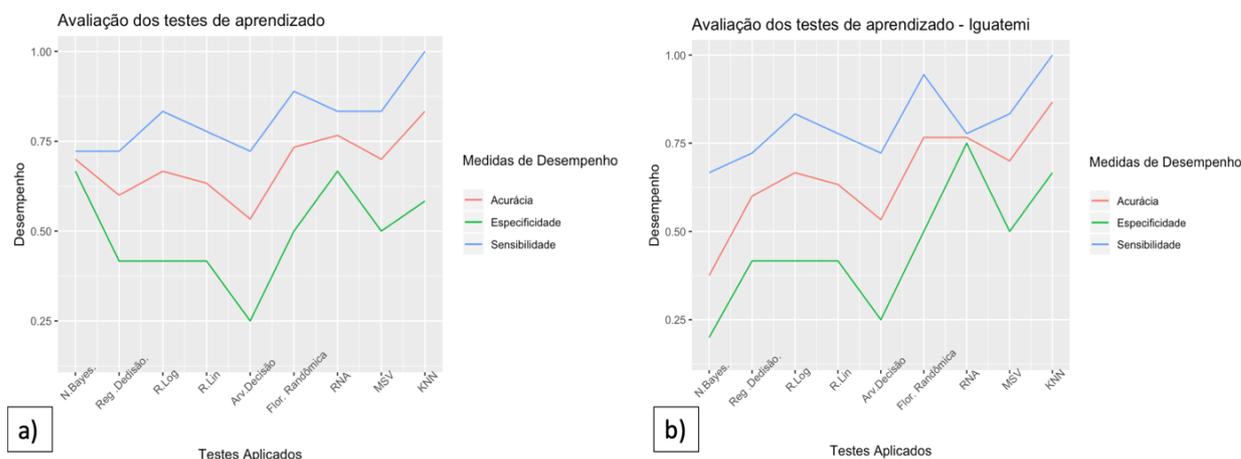


Figura 5: Desempenho dos algoritmos sobre os conjuntos de validação(a) e teste(b)

Os dados apontados demonstram que durante a avaliação do conjunto de teste, o algoritmo de *Naive Bayes* foi o que apresentou significativo erro de generalização, enquanto os algoritmos de Regras de Decisão, Regressão Logística, Regressão Linear, e Árvore de Decisão mantiveram o mesmo desempenho e razoável poder de generalização.

Os algoritmos de Floresta Randômica, Rede Neural Artificial, Máquina de Suporte de Vetores e KNN apresentaram significativa capacidade de generalização, demonstrando boa aderência dos modelos tanto ao conjunto de validação como de teste.

Estes resultados permitiram avaliar os modelos dos algoritmos Floresta Randômica, Rede Neural Artificial, Máquina de Suporte de Vetores e KNN como aqueles que apresentam melhor desempenho preditivo da ocupação dos parquímetros de ERPs, fornecendo subsídios significativos para definição de locais ótimos para instalação de parquímetros.

REFERÊNCIAS BIBLIOGRÁFICAS

- ÁLVAREZ, Diego Armando Céspedes (2017) *O automóvel nas cidades e o planejamento deteriorado*. InterEspaço: Revista de Geografia e Interdisciplinaridade, v. 2, n. 7, p. 45-60.
- ARAÚJO, Pedro Ismael; MOREIRA, Vale; RODRIGUES, Manuel (2008) *Boas Práticas de gestão de estacionamento em cidades de pequena e média dimensão*. Dissertação (Mestrado). Faculdade de Engenharia - Universidade do Porto, Porto.
- CAPRI, Marco Antonio (2002) *Otimização no Serviço de Estacionamento Regulamentado Utilizando Técnicas de Pesquisa Operacional*. Dissertação (Mestrado). Universidade Federal do Paraná, Curitiba.
- CASSIANO, Luciano Vieira (2014) *Estudo de implantação de um sistema de estacionamento rotativo na região central da cidade de Campo Mourão-PR*. Monografia (Graduação). Universidade Tecnológica Federal do Paraná, Campo Mourão.
- DUECK, Delbert (2009) *Affinity propagation: clustering data by passing messages*. Tese (Doutorado). Columbia, 2009.
- ELIAS, Antonio Carlos Cardoso (2001) *Estacionamento rotativo pago em via pública : racionalização do uso da via x disposição do usuário em pagar pelo serviço*. Dissertação (Mestrado). Universidade Federal do Rio Grande do Sul, Porto Alegre.
- HAIFUCH, Isabel Cristina Guimarães et al (2007) *Déficit de Estacionamentos na Cidade de Porto Alegre: Uma Questão de Planejamento Urbano*. In: XXI ANPET - Congresso de Pesquisa e Ensino em Transportes, Rio de Janeiro, RJ, Brasil.
- HULLEY, Stephen B. et al. (2015) *Delineando a Pesquisa Clínica*. 4. ed. Porto Alegre: Artmed.
- LANGLEY, PAT; SAGE, STEPHANIE (1994) Induction of Selective Bayesian Classifiers. *Uncertainty Proceedings*, p. 399–406.
- LIAO, Ke; GUO, Diansheng (2008) *A Clustering-Based Approach to the Capacitated Facility Location Problem*. *Transactions in GIS*, v. 12, p. 323–339.
- LORENA, Luiz Antonio Nogueira et al (2001) *Integração de modelos de localização a sistemas de informações geográficas*. *Gestão & Produção*, v. 8, n. 2, p. 180–195.
- LUZ, Paulo Roberto Pinto Da; BASTOS, Rogério Cid (1997) *Um estudo de caso utilizando técnicas de preferência declarada, para análise do fluxo e permanência de veículos em áreas delimitadas*. Dissertação (Mestrado). Universidade Federal de Santa Catarina, Florianópolis.
- MIRANDA, Julio César; MACIEL, Lucia Borba; FEDER, Marcos (2005) *Estacionamento rotativo pago : critérios de implantação*. In: XIX ANPET - Congresso de Pesquisa e Ensino em Transportes, Recife, PE, Brasil.
- PAARSCH, Harry J.; GOLYAEV, Konstantin (2016) *A Gentle Introduction to Effective Computing in Quantitative Research*. The MIT Press.
- PARADELA, Carolina Soares Matuck et al (2015) *Estacionamento rotativo: uma abordagem ampla a partir do exemplo de belo horizonte*. *Revista Pensar Engenharia*, v. 3, n. 1.
- PEREIRA, Luiz Andrel Gonçalves; MOREIS, Sandra Dalvi Quintaes De; FERREIRA, Willian Rodrigues (2012) *A geografia dos transportes na organização do espaço urbano: mobilidade e acidentes de trânsito*. *Caminhos de Geografia*, v. 13, n. 42, p. 240–252.
- RASHCKA, Sebastian; MIRJALILI, Vahid (2013) *Python Machine Learning*. Birmingham: Packt Publish.
- RIBEIRO, Luiz Cesar de Queiroz (2015) *Estudo da motorização indivisual no Brasil - Relatório*. Rio de Janeiro.
- SILVA, Fernando Nunes (2013) *Mobilidade urbana: os desafios do futuro*. *Cadernos Metrópole*, v. 15, n. 30, p. 377-388.
- VARUGHESE, Shaju; RAJ S, Gladston (2017) *Facility Location in Logistic Network Design Using Soft Computing Opimization Models*. *International Journal of Computer Science and Information Technology*, v. 9, n. 5, p. 51–65.

Fagner Sutel de Moura (fsmoura@eptc.prefpoa.com.br)

Equipe de Simulação e Estudos de Tráfego – Coordenação de Indicadores e Engenharia de Tráfego - EPTC
Rua João Neves da Fontoura, 07 – Porto Alegre, RS, Brasil