
ANÁLISE DO *PAVEMENT CONDITION INDEX* AEROPORTUÁRIO COM USO DE ESTATÍSTICA ESPACIAL

Antonia Fabiana Marques Almeida*, Francisco Heber Lacerda de Oliveira
Universidade Federal do Ceará, Programa de Pós-Graduação em Engenharia de Transportes

* E-mail do autor de correspondência: fabiana@det.ufc.br

PAPER ID: SIT138

RESUMO

O *Pavement Condition Index* (PCI) determina a condição funcional de um pavimento aeroportuário. Esse parâmetro é obtido por meio do levantamento de defeitos existentes na superfície das seções analisadas. A área total de análise é dividida em seções considerando o uso, o material e a condição. Assim, a hipótese é que esse índice apresente alguma estrutura espacial, uma vez que as seções têm informações agregadas com base em critérios bem definidos. Com base no exposto, este trabalho tem como objetivo verificar a autocorrelação espacial da variável PCI de pavimentos aeroportuários em caráter exploratório, determinando um padrão espacial de distribuição dos defeitos e fornecendo subsídios para previsão de valores. Para tanto, foram consideradas as informações de defeitos e do PCI calculado na pista de pouso e decolagem de um aeroporto brasileiro coletados em 2018. Foram testadas matrizes de ponderação de contiguidade e de distâncias, buscando identificar a que melhor se adequou aos dados analisados. Foi analisada a existência de autocorrelação espacial, por meio dos valores do I de Moran e utilizada a densidade do defeito mais recorrente nas seções avaliadas, o afundamento de trilha de roda com baixa severidade como variável explicativa do PCI. A regressão linear entre esses dois parâmetros resultou num coeficiente de determinação de 0,71. Também foram verificados os modelos espaciais autorregressivo e de erro, porém, nenhum foi significativo. Como indicadores de desempenho foram adotados o I de Moran, o critério de informação de Akaike e o log da máxima verossimilhança. Concluiu-se que, para o caso do conjunto de dados analisado, a regressão linear é mais eficiente na estimativa do PCI, porém, a estatística espacial pode ser utilizada para compreensão espacial das informações por parte do operador do aeródromo.

Palavras-chave: Pista de pouso e decolagem, Infraestrutura aeroportuária, *Pavement Condition Index*, Estatística espacial, I de Moran.

1. INTRODUÇÃO

A segurança das operações aéreas é de fundamental importância para a aviação civil. A infraestrutura aeroportuária, mais especificamente da área pavimentada, deve ser avaliada periodicamente. Essa sistemática permite que as atividades de manutenção e reabilitação (M&R) dos pavimentos sejam adequadamente planejadas e executadas com a melhor relação benefício-custo.

FAA (2014) prevê, como forma de avaliação da superfície de pavimentos aeroportuários, o uso do *Pavement Condition Index* (PCI), um importante índice para determinação de condição funcional. ANAC (2017) indica que o PCI é o método principal de determinação da condição funcional de um pavimento aeroportuário quanto à presença de defeitos, fornecendo uma base racional e objetiva para determinação das necessidades e das prioridades de M&R.

Para obtenção do PCI em pistas de pouso e decolagem (PPD), a área total a ser avaliada é dividida em seções, de acordo com idade, estado da superfície e defeitos existentes. É, então, realizado um levantamento de defeitos em cada região para o cálculo do PCI.

Como a PPD é dividida em seções que são vizinhas entre si, uma possibilidade de análise das informações obtidas é por meio da estatística espacial. Esse método permite verificar se existe autocorrelação espacial de uma variável numérica distribuída geograficamente. É possível identificar se as regiões vizinhas influenciam nos valores da região analisada e, em caso positivo, realizar estimativas e previsões dos valores de regiões próximas.

Nesse sentido, Kırbaş & Karaşahin (2017) analisaram o uso da vibração para determinar o PCI em rodovias, e obtiveram um modelo de regressão linear com um coeficiente de determinação (R^2) de 0,85. Adeli *et al.* (2021) buscaram correlações entre o PCI e o Índice de Irregularidade Internacional (IRI), e identificaram que o modelo mais adequado foi o exponencial, com R^2 de 0,76 em rodovias rurais de qualidade considerada regular. Issa *et al.* (2022), por sua vez, utilizaram redes neurais artificiais para determinar o PCI de pavimentos rodoviários de forma mais rápida e objetiva.

Em pavimentos aeroportuários, Shahin & Becker (1984) utilizaram regressão não-linear com múltiplas variáveis independentes e obtiveram, para revestimento asfáltico, um R^2 de 0,83. Cereceda *et al.* (2022) estimaram IRI e PCI de aeroportos chilenos com base em processamento de imagens e encontraram correlações entre os dois parâmetros, com R^2 de 0,90 em uma regressão logarítmica.

Assim, o objetivo deste trabalho é verificar se há autocorrelação espacial da variável PCI na PPD de um aeroporto brasileiro em caráter exploratório. O intuito é definir se é possível determinar um padrão espacial de distribuição dos defeitos, fornecendo subsídios para estimativa de parâmetros como o PCI, por exemplo.

2. REFERENCIAL TEÓRICO

2.1. *Pavement Condition Index*

A avaliação da condição funcional tem como objetivo a verificação da segurança e do conforto ao rolamento (ANAC, 2017). Vale destacar que o índice reflete a realidade do momento dos levantamentos, sendo possível utilizá-lo para previsões de desempenho quando são realizados periodicamente, gerando uma série histórica (Zakaria & Deni, 2020).

No Brasil, a forma de obtenção e o cálculo do PCI são descritos em ASTM (2020). É determinado após a inspeção visual de superfícies de pavimentos flexíveis ou rígidos.

A região a ser analisada é dividida em seções, com área máxima de $450 \pm 180 \text{ m}^2$ em pavimentos em concreto asfáltico, ou 20 ± 8 placas contínuas em pavimentos em concreto de cimento Portland (ASTM, 2020). A quantidade de seções é variável, e deve permitir o cálculo do PCI a um nível de confiança de 95%.

O PCI considera o tipo (T_i), a severidade (S_j) e a densidade (D_{ij}) de defeitos ocorrentes no pavimento, e é amplamente utilizado como referência para manutenção. A severidade é dividida em baixa (B), média (M) e alta (A). D_{ij} , medida adimensional, pode ser calculada conforme a Equação (1).

$$D_{ij} = \frac{\text{Defeitos (m}^2\text{)}}{\text{Área da seção (m}^2\text{)}} \times 100 \quad (1)$$

O PCI é calculado a partir da Equação (2), onde o $max(CDV)$ (*corrected deduct value*) se refere ao valor máximo de dedução corrigido. O CDV é calculado conforme a Equação (3) (Wang *et al.*, 2019).

$$PCI = 100 - (CDV) \quad (2)$$

$$CDV = \left(q, \sum_{i=1}^{m_s} \sum_{j=1}^{n_j} f(T_i, S_j, D_{ij}) \right) \quad (3)$$

Onde,

m_s é o total de defeitos identificados;

n_j é o nível de severidade do defeito j ;

$f(T_i, S_j, D_{ij})$ é a função do valor de dedução determinado pelo tipo de defeito T_i com o nível de severidade S_j e a densidade D_{ij} ;

q é a quantidade de registros com CDV maior que 5; e

$g(q, T_i, S_j, D_{ij})$ é a função do CDV .

Os tipos de defeitos listados no levantamento são: trincas (por fadiga, em bloco, longitudinais, transversais e de reflexão), exsudação, corrugação, depressão, erosão *jet blast*, deterioração por óleo, remendo, agregado polido, desagregação, afundamento de trilha de roda, solevamento, escorregamento, inchamento e desprendimento. O PCI varia de 0 a 100, conforme a escala do Quadro 1.

Quadro 1 Escala de classificação do PCI e tipo de reparo

Classificação	Limites	Reparo
Excelente	86 - 100	Manutenção preventiva
Bom	71 - 85	
Regular	56 - 70	Reabilitação
Ruim	41 - 55	
Muito ruim	26 - 40	Reconstrução
Péssimo	11 - 25	
Ruptura	0 - 10	

Fonte: Adaptado de ANAC (2017) e ASTM (2020).

2.2. Estatística Espacial

Considerando a disponibilidade de bancos de dados de PCI em pavimentos aeroportuários brasileiros, novas ferramentas são necessárias

para a análise dessas informações de forma mais confiável. Quando os dados são georreferenciados, um método exploratório de análise é a estatística espacial (Anselin, 1996).

Nesse método são analisados atributos de regiões que podem apresentar dependência ou heterogeneidade espacial. Espera-se que regiões próximas apresentem correlação maior que regiões mais distantes (Golgher, 2015).

Essa correlação tem o intuito de verificar se o índice de uma região é afetado, ou não, pelo mesmo parâmetro de regiões vizinhas. É denominada autocorrelação espacial, calculado o I de Moran (Equação 4) que varia de -1 (indica dispersão) a +1 (indica agregação), sendo considerados melhores se próximos a esses limites. Essa medida estatística permite verificar se um parâmetro é agrupado, disperso ou aleatório.

$$I = \frac{n}{S_0} \times \frac{\sum_{i=1}^n \sum_{j=1}^n w_{i,j} z_i z_j}{\sum_{i=1}^n z_i^2} \quad (4)$$

Onde,

z_i é o desvio do atributo com relação à média ($x_i - \bar{X}$);

$w_{i,j}$ é o peso espacial entre i e j ;

n é o total de regiões analisadas;

S_0 é a agregação dos pesos (Equação 5).

$$S_0 = \sum_{i=1}^n \sum_{j=1}^n w_{i,j} \quad (5)$$

O cálculo do I de Moran também está associado a uma inferência estatística cuja hipótese nula (H_0) é que o atributo em análise está distribuído aleatoriamente entre as regiões. Para o cálculo do I de Moran é necessário determinar as matrizes de ponderação espacial (W) que mais se adequam aos dados em análise.

Uma matriz W é do tipo quadrada, de tamanho $n \times n$, composta pelos pesos espaciais ($w_{i,j}$) que representam o grau de conexão entre as regiões segundo algum critério de proximidade, permitindo identificar a influência da região j sobre a região i . Buscam refletir o arranjo espacial das interações resultantes do fenômeno a ser estudado (Almeida, 2012).

Determinar as matrizes é uma etapa arbitrária, pois não existem testes formais (Plaignin, 2009). As matrizes podem ser definidas

conforme a contiguidade e/ou com a distância geográfica. Nas matrizes de contiguidade duas regiões são vizinhas se partilharem de uma barreira em comum. As mais utilizadas são do tipo rainha (*queen*) ou torre (*rook*). A matriz *queen* considera vizinha a região que divide um vértice com a área a ser estudada. A matriz *rook*, por sua vez, considera vizinha a região que divide um vértice. Na matriz binária de contiguidade W , caso sejam consideradas vizinhas, $w_{i,j} = 1$, se não, $w_{i,j} = 0$.

Uma das matrizes W por distância geográfica mais utilizadas é a dos k vizinhos mais próximos (*k-nearest*), que também é do tipo binária. Aqui, $w_{i,j}(k) = 1$ se $d_{i,j} \leq d_i(k)$, e $w_{i,j}(k) = 0$ se $d_{i,j} > d_i(k)$, em que $d_i(k)$ é a menor distância para a região i a fim de que ela possua k vizinhos (especificados).

Existem outras matrizes W como a que considera a distância entre os centróides das regiões, a de pesos de Cliff e Ord, e outras. Essas matrizes não serão definidas neste trabalho, pois não serão utilizadas. Para definir a matriz W ideal, é selecionada a que gera o maior I de Moran.

Após identificada a matriz W , podem ser realizadas as verificações por regressão espacial, utilizando variáveis independentes de caráter explicativo. São identificados os erros da regressão, se atendem às premissas de normalidade, variância constante e distribuição aleatória. Após identificar as variáveis explicativas ideais, podem ser desenvolvidos modelos espaciais.

Os modelos espaciais mais utilizados são o SAR (*Spatial Autoregression*) e o SEM (*Spatial Error Model*), além da própria regressão (OLS – *Ordinary Least Squares*). Para definir se os modelos são válidos, são considerados o multiplicador de Lagrange (ML) (da distância – *lag*, e do erro – *error*) e o ML robusto (*lag* e *error*). A forma de identificar qual é o melhor modelo é por meio de algum indicador de desempenho, como o próprio I de Moran obtido da modelagem, o critério de Informação de Akaike (*Akaike Information Criteria - AIC*), ou o log da máxima verossimilhança (*Likelihood*).

3. MÉTODO DE PESQUISA

Este trabalho foi desenvolvido em 5 etapas: (i) Coleta e georreferenciamento de informações de PCI da PPD de estudo e análise descritiva dos dados; (ii) Determinação das matrizes de ponderação; (iii) Cálculo do Índice de Moran das variáveis analisadas; (iv) Regressão espacial com verificação das premissas nos erros obtidos referentes à: existência de normalidade, variância constante e independência espacial; e (v) Identificação do modelo espacial mais adequado.

Para a análise, foram utilizados os *softwares*: AutoCAD, versão 2020, para o esboço prévio das seções da PPD conforme informações obtidas do relatório oriundo do levantamento realizado; QGIS, versão 3.16.14, para criação do arquivo do tipo *shapefile* com as informações de análise; Jupyter Notebook (Anaconda), versão 6.3.0, para uso da linguagem Python (3.8.8) na confecção de gráficos; e GeoDa, versão 1.14.0, para a geração das matrizes de ponderação, verificação dos valores de I de Moran, análise da regressão linear e espacial e identificação do modelo espacial mais adequado aos dados pelos indicadores de desempenho (I de Moran, AIC e *Log Likelihood*).

Além do fator disponibilidade dos dados, o aeroporto de estudo foi selecionado pela homogeneidade no revestimento ao longo da PPD, que é em concreto asfáltico. Os levantamentos que resultaram nos dados analisados foram realizados conforme ASTM (2012) nos meses de agosto e setembro de 2018.

A avaliação do pavimento foi realizada de maneira contínua com a utilização do *Pavement Scanner* (Figura 1), que detecta e classifica automaticamente os defeitos. Para tanto, a PPD foi dividida em 27 seções. Os levantamentos foram executados com o tempo limpo e ventoso, com temperaturas médias de 25°C e a umidade relativa do ar média de 70%, de acordo com o relatório da empresa executora do serviço.

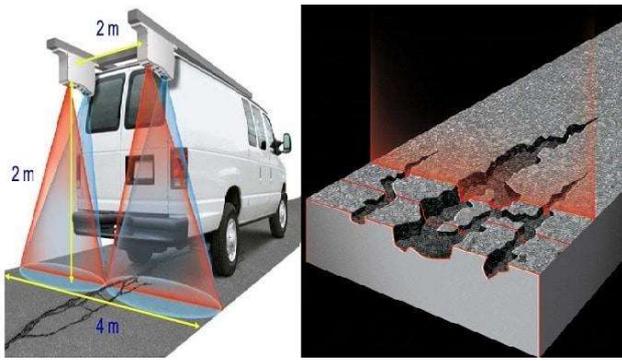


Figura 1 Exemplo de *Pavement Scanner* (Fonte: The Constructor, 2022).

4. RESULTADOS E ANÁLISE

4.1. Coleta e caracterização dos dados

Os dados do aeroporto de estudo foram obtidos junto à empresa que executou o

levantamento. A sua PPD apresentava, à época do levantamento, um comprimento pavimentado em concreto asfáltico de 2.545 m, largura de 45 m e orientação 13-31.

Os defeitos identificados nas seções foram: trincas por fadiga, depressão, trincas longitudinais e transversais, remendo, desagregação e afundamento de trilha de roda (ATR). Os mais frequentes foram a desagregação em baixa severidade e o ATR em baixa e média severidade.

A Tabela 1 apresenta de forma resumida a estatística descritiva dos dados de densidade (D) dos dois defeitos mais ocorrentes nas duas severidades citadas e do PCI. A Figura 2 apresenta uma espacialização dos valores de PCI calculados.

Tabela 1 Estatística descritiva dos dados de densidade dos defeitos e PCI.

Parâmetros	Desagregação (B)	$D_{ATR(B)}$	$D_{ATR(M)}$	PCI
Quantidade de ocorrências	19	22	18	27
Média	0,26	6,04	0,71	71,36
Mediana	0,19	6,46	0,51	63,34
Mínimo	0,03	0,18	0,02	51,93
Máximo	0,80	11,82	2,43	100,00
Desvio padrão	0,18	3,49	0,52	14,20
Variância	0,05	16,50	0,46	266,85
Coefficiente de variação	0,70	0,58	0,73	0,20

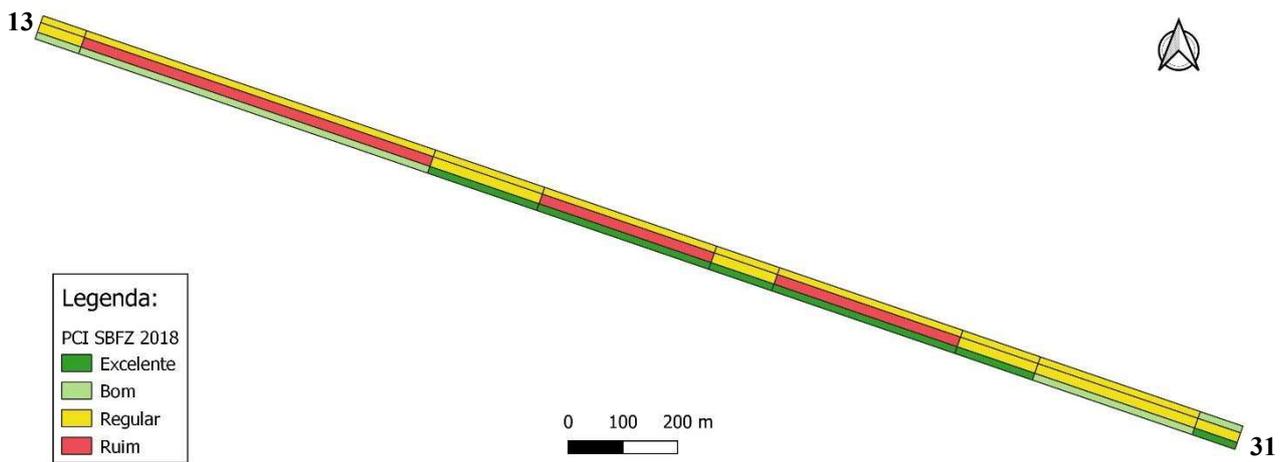


Figura 2 Classificação conforme PCI da pista 13-31 da PPD de estudo em 2018.

Ressalta-se que os defeitos foram considerados na forma de densidade na análise, por ser uma forma de normalização das variáveis para efeito comparativo. Pela Tabela 1 observa-se, que, embora os três defeitos

citados tiveram maior ocorrência que os demais, não foram identificados nas 27 seções avaliadas.

Ainda da análise da Tabela 1, há também uma elevada variabilidade dos dados referentes

aos defeitos, como se verifica por meio do coeficiente de variação (*cv*). No caso da variável PCI, o *cv* é relativamente baixo, o que sugere uma homogeneidade dos dados.

Na Figura 2 pode-se verificar a distribuição conforme escala de avaliação dos valores de PCI. Não há um padrão bem definido, embora existam PCI classificados como “Ruim” em 3 seções da parte central da PPD: uma mais próxima à cabeceira 13, outra mais na região central, e a terceira entre a região central e a cabeceira 31. A Figura 3 apresenta um gráfico de linha dos dados de PCI e os limites inferiores das escalas de classificação do parâmetro, e a Figura 4 o *boxplot* dos valores de PCI também com a indicação dos limites inferiores da escala de classificação.

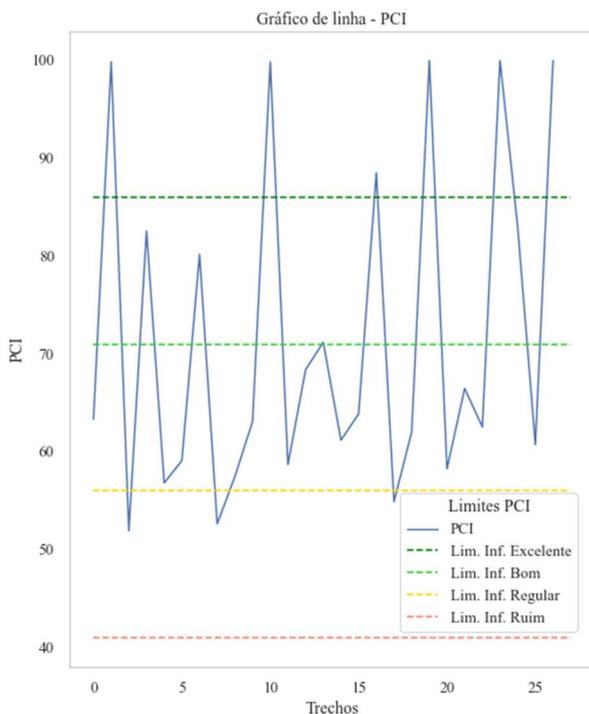


Figura 3 Gráfico de linhas dos dados de PCI da PPD de estudo em 2018.

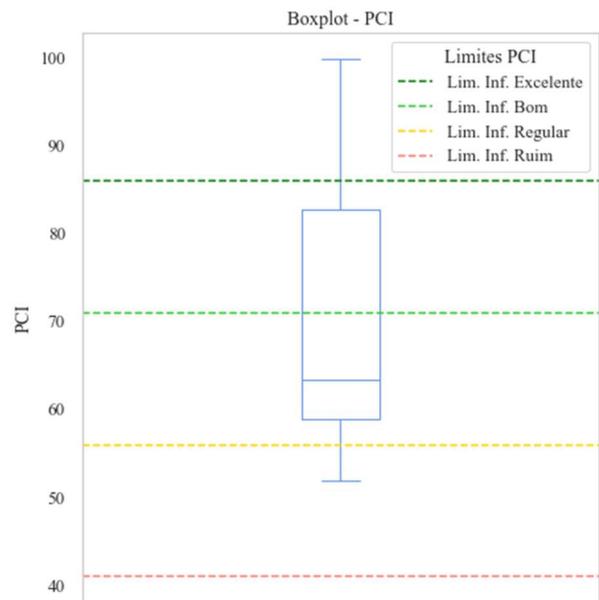


Figura 4 *Boxplot* dos dados de PCI da PPD de estudo.

Pela Figura 3 constata-se que não há uma distribuição padrão das informações, provavelmente pelo baixo tamanho da amostra. Pode-se verificar que poucas informações estão enquadradas na faixa classificada como ruim. A maior parte dos trechos (14) foi classificada pela escala como "Bom".

Quanto ao *boxplot* da Figura 4, constata-se que não há valores do tipo *outliers*. Confirma-se a presença de valores inferiores à média, e não há simetria de dados.

O parâmetro referente à densidade do ATR-B foi inserido na análise por ter sido o defeito mais frequente na PPD de estudo quando analisado, com o intuito de utilizá-lo como variável explicativa do PCI. A Figura 5 apresenta o *boxplot* da densidade do ATR-B. Verifica-se que há uma concentração de valores acima da média e que não há simetria dos dados de ATR-B. A regressão linear que considera o PCI como variável dependente, explicada pelo ATR-B resulta em um coeficiente de determinação (R^2) de 0,71.

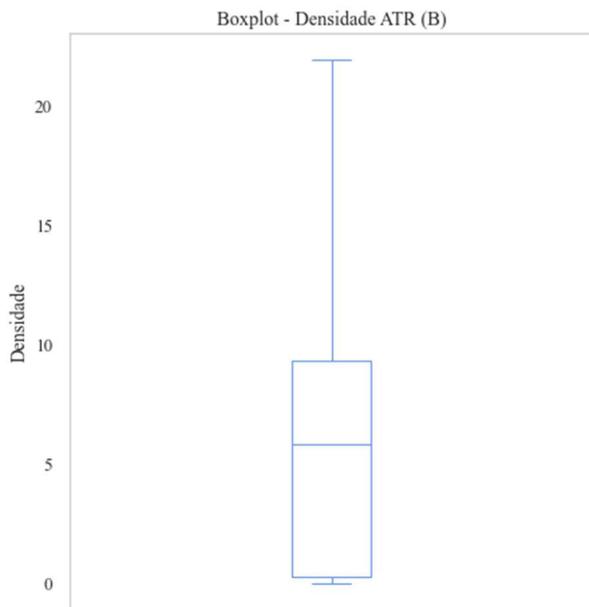


Figura 5 *Boxplot* dos dados de densidade do ATR-B da PPD de estudo.

4.2. Determinação das matrizes de ponderação

Para as matrizes de ponderação foram adotadas as de contiguidade *queen* e *rook*, além da matriz dos vizinhos mais próximos (*k-nearest*) com diferentes quantidades de vizinhos a serem considerados. A Tabela 2 apresenta algumas informações das matrizes de ponderação criadas para o cálculo da autocorrelação espacial. As matrizes *k-nearest* foram criadas considerando a quantidade máxima de 6 vizinhos mais próximos, já que foi identificado que a partir desse limite os valores de I de Moran estavam estabilizados.

Tabela 2 Matrizes de ponderação para análise.

Matriz	Número de Vizinhos
<i>Queen</i>	3 - 8
<i>Rook</i>	2 - 4
<i>k-nearest 1</i>	1
<i>k-nearest 2</i>	2
<i>k-nearest 3</i>	3
<i>k-nearest 4</i>	4
<i>k-nearest 5</i>	5
<i>k-nearest 6</i>	6

4.3. Determinação do I de Moran

O I de Moran foi determinado considerando as variáveis PCI e ATR-B. A Tabela 3 apresenta os resultados obtidos.

Tabela 3 I de Moran dos parâmetros de acordo com as matrizes de ponderação.

Matriz	PCI	ATR-B
<i>Queen</i>	0,030	-0,147
<i>Rook</i>	0,298	0,214
<i>k-nearest 1</i>	-0,499	-0,802
<i>k-nearest 2</i>	-0,345	-0,408
<i>k-nearest 3</i>	0,025	0,067
<i>k-nearest 4</i>	-0,067	-0,138
<i>k-nearest 5</i>	-0,146	-0,143
<i>k-nearest 6</i>	0,021	0,008

Dos valores da Tabela 3 observa-se que, para a variável PCI, o melhor valor do I de Moran (-0,499) ocorreu na matriz de ponderação *k-nearest* considerando um vizinho. Para o ATR-B o melhor valor do I de Moran ocorreu na mesma matriz de ponderação, porém o valor (-0,802) foi ainda mais próximo do limite considerado ideal.

Os valores com sinais negativos também expressam que a distribuição de informações ocorre de forma mais dispersa espacialmente. As figuras 6 e 7 apresentam os gráficos do I de Moran do PCI e da densidade do defeito ATR de baixa severidade (D_{ATR-B}), respectivamente, para a matriz de ponderação *k-nearest 1*.

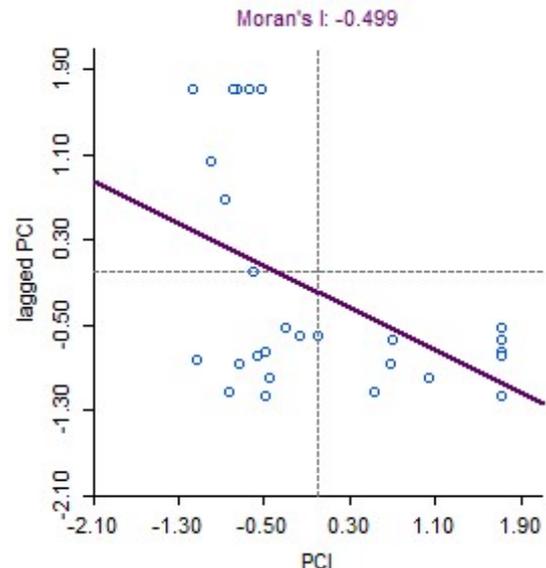


Figura 6 I de Moran do PCI (*k-nearest 1*).

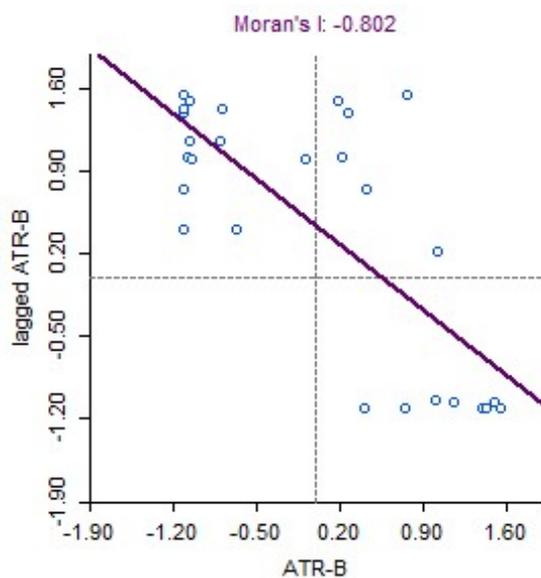


Figura 7 I de Moran da D_{ATR-B} (k -nearest 1).

Esses resultados mostram que, para uma divisão de seções na forma que o PCI demanda, a região em análise é influenciada por somente uma seção vizinha, considerando as variáveis analisadas. Porém, como não é possível realizar análise de modelos espaciais com a matriz k -nearest 1 devido à quantidade de vizinhos ser mínima, será adotada a matriz k -nearest 2, que obteve os melhores resultados com maior quantidade de vizinhos. As figuras 8 e 9 apresentam os gráficos de dispersão do I de Moran do PCI e D_{ATR-B} , respectivamente, para a matriz k -nearest 2.

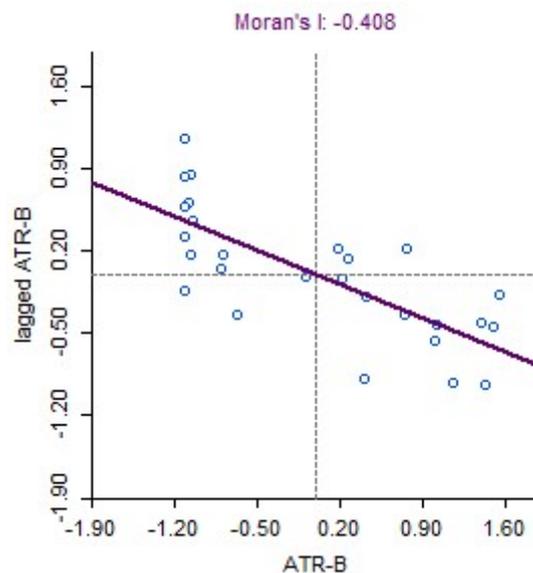


Figura 9 I de Moran da D_{ATR-B} (k -nearest 2).

4.4. Regressão espacial

Para verificar o desempenho da regressão espacial, em que a D_{ATR-B} é utilizada como variável explicativa do PCI, foi realizada uma estimativa de mínimos quadrados ordinários (MQO ou OLS). A variável explicativa, com p-valor de 0,00, pode ser definida como significativa, e assim é um indício de que é adequada para ser considerada.

A partir desta etapa, serão verificadas as premissas do modelo de regressão, com um nível de significância de 0,05. A Tabela 4 apresenta os resultados que não são influenciados pelas matrizes de ponderação.

Tabela 4 Resultados do diagnóstico dos erros da regressão espacial.

Teste	Verificação	p-valor	Premissa
Jarque-Bera	Normalidade	0,47	Atende
Breusch-Pagan	Variância	0,07	Não atende
Koenker-Bassett	Variância	0,01	Atende
White	Variância	0,01	Atende
I de Moran	Dependência espacial	0,76	Atende

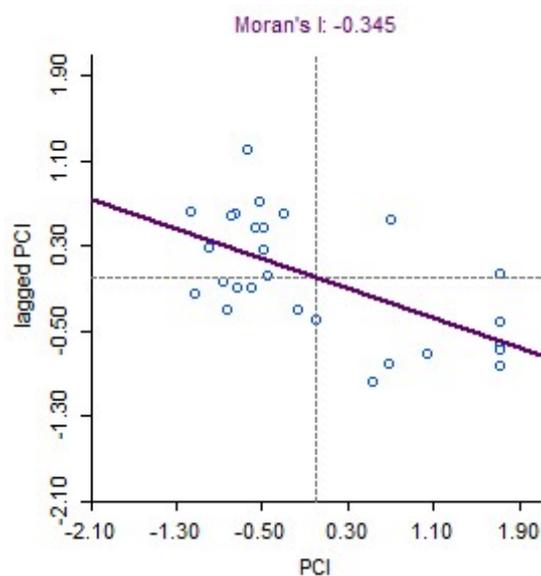


Figura 8 I de Moran do PCI (k -nearest 2).

Assim, com as premissas de normalidade, variância constante (apesar de um teste não ter atendido, mas pelos demais considera-se que a premissa foi atendida) e não dependência espacial atendidas, define-se que a variável D_{ATR-B} pode ser utilizada para explicar o PCI espacialmente. Embora isso seja esperado, por ser uma variável que é contabilizada na determinação do PCI, é

importante verificar a forma como ela pode ser empregada.

4.5. Modelos espaciais

Foram testados, além da regressão apresentada anteriormente, os modelos espaciais SAR e SEM. A Tabela 5 apresenta os resultados das probabilidades obtidas a partir desses modelos, considerando a matriz k -nearest 2.

Tabela 5 Resultados dos parâmetros de análise dos modelos espaciais.

Parâmetro	Valor	Probabilidade
ML (<i>lag</i>)	0,914	0,339
ML (<i>error</i>)	0,041	0,839
ML robusto (<i>lag</i>)	2,531	0,112
ML robusto (<i>error</i>)	1,656	0,198

Pelos valores de probabilidade, verifica-se que nenhum dos modelos foi significativo. Os modelos foram calibrados, apesar de não serem significativos, para efeito comparativo com os dados oriundos da regressão. A Tabela 6 apresenta os resultados da calibração e os indicadores de desempenho considerando a regressão (OLS), o SAR e o SEM.

Tabela 6 Resumo dos modelos espaciais.

Parâmetro	OLS	SAR	SEM
Constante	86,941	93,026	86,917
ATR-B	-3,165	-3,033	-3,160
Rho (ρ)	-	-0,094	-
Lambda (λ)	-	-	-0,022
AIC	197,909	199,639	197,896
Log Likelihood	-96,954	-96,819	-96,948
I de Moran	-0,040	-0,429	-0,408

Os valores obtidos dos modelos, conforme Tabela 6, com exceção do I de Moran e dos coeficientes ρ e λ (inerentes dos modelos espaciais), foram muito próximos, principalmente ao analisar os indicadores de desempenho. Caso tivessem sido significativos, o SEM seria o ideal a ser adotado em estimativas espaciais considerando o AIC, ou o SAR, considerando o I de Moran. Como o modelo de regressão linear simples foi o único que apresentou significância, a Equação (6) apresenta como é a estimativa do PCI com base na densidade do ATR-B (D_{ATR-B}).

$$PCI = 86,941 - 3,165(D_{ATR-B}) \quad (6)$$

Embora o resultado tenha indicado que o modelo simples é o melhor dentre os analisados, vale ressaltar que o PCI é um índice que considera muitos defeitos na sua formulação, o que pode ter afetado a análise. Assim, a Equação (6) poderia ser utilizada com caráter de tomada de decisão, identificando os momentos de alteração dos valores de PCI para realização de levantamentos mais completos.

5. CONCLUSÕES

A estatística espacial utilizada neste artigo permitiu realizar uma análise exploratória dos dados do *Pavement Condition Index* (PCI) de uma pista de pouso e decolagem (PPD) brasileira. Verificou-se que a dependência espacial das variáveis analisadas apresentou um padrão mais disperso, mais evidente ainda quando se analisa a densidade do afundamento de trilha de roda de baixa severidade (D_{ATR-B}). Esse defeito foi considerado pois foi o mais ocorrente nas seções da PPD estudada.

O PCI, porém, é um índice que leva em consideração a existência de outros defeitos nas seções, embora possa ser explicado com base na D_{ATR-B} por meio de regressão simples com um coeficiente de determinação de 0,71. Vale destacar que essa estimativa deve ocorrer apenas para fins de apoio à tomada de decisão para identificar o momento em que se deve realizar novo levantamento de determinação do PCI ou intervir com as estratégias de manutenção e reabilitação mais adequadas.

Ao verificar a aplicação dos modelos espaciais, a matriz de ponderação que resultou nos maiores valores do I de Moran não foi adequada, uma vez que não é possível realizar a modelagem com somente 1 vizinho. Assim, a matriz de 2 vizinhos mais próximos (k -nearest 2), com os melhores resultados após a exclusão da anterior, foi adotada.

Os modelos espaciais autorregressivo e de erro não apresentaram significância. Assim, para efeito de modelagem, esses modelos podem não ser adequados para o caso analisado. O ideal é que a PPD fosse mais segmentada, pois facilitaria a análise espacial e, para tanto, é necessário que os defeitos sejam espacializados.

Referências

- Adeli, S., Gilani, V. N. M., Novin, M. K., Motesharei, E., & Salehfard, R. (2021). Development of a Relationship between Pavement Condition Index and International Roughness Index in Rural Road Network. *Advances in Civil Engineering*. Volume 2021, 6635820. DOI: 10.1155/2021/6635820.
- Almeida, E. (2012). *Econometria Espacial Aplicada*. Campinas, SP. Editora Alínea.
- ANAC. (2017). *Manual de Sistema de Gerenciamento de Pavimentos Aeroportuários – SGPA*. Agência Nacional de Aviação Civil.
- Anselin, L. (1996). The Moran scatterplot as an ESDA tool to assess local instability in spatial association. *Spatial Analytical Perspectives on GIS*. Londres, Routledge, 268p. DOI: 10.1201/9780203739051.
- ASTM. (2012). *Standard Test Method for Airport Pavement Condition Index Surveys*. ASTM D5340-12. Pennsylvania: American Society for Testing and Materials.
- ASTM. (2020). *Standard Test Method for Airport Pavement Condition Index Surveys*. ASTM D5340-20. Pennsylvania: American Society for Testing and Materials.
- Cereceda, D., Medel-Vera, C., Ortiz, M., & Tramon, J. (2022). Roughness and condition prediction models for airfield pavements using digital image processing. *Automation in Construction*. 139. DOI: 10.1016/j.autcon.2022.104325.
- FAA. (2014). *Airfield Pavement Surface Evaluation and Rating Manuals*. Advisory Circular (AC) N° 150/5320-17A. Washington, D.C.: Federal Aviation Administration.
- Golgher, A. B. (2015). *Introdução à Econometria Espacial*. 384p. Jundiaí. Paco Editorial.
- Issa, A., Samaneh, H., & Ghanim, M. (2022). Predicting pavement condition index using artificial neural networks approach. *Ain Shams Engineering Journal*, 13. DOI: 10.1016/j.asej.2021.04.033.
- Kırbaş, U., & Karaşahin, M. (2017). *Estimating PCI Using Vibration Data for Asphalt Concrete Pavements*. Proceedings of the 2nd World Congress on Civil, Structural, and Environmental Engineering (CSEE'17) Barcelona, Spain. Paper No. ICTE 114. DOI: 10.11159/ictel7.114.
- Plaigin, C. (2009). *Exploratory study on the presence of cultural and institutional growth spillovers*. Brussels Economic Review. Working Paper, N°09-03. Research Series.
- Shahin, M. Y., & Becker, J. M. (1984). Development of Performance Prediction Models for Airfield Pavements. *Transportation Research Record*. TRR 985.
- The Constructor. (2022). Laser Crack Measurement System for Pavements. Disponível em: <https://theconstructor.org/transportation/laser-crack-measurement-system-pavements/21081>. Acesso em 30 de julho de 2022.
- Wang, H., Guo, L., & Chen, X. (2019). *Airfield Pavement Management Framework using a Multi-Objective Decision Making Process*. Final Report. New Jersey: The State University of New Jersey.
- Zakaria, S., & Deni, A. (2020). *Application of pavement condition index (PCI) on the assessment of the Kalumata highway section of the City of South Ternate*. IOP Conference Series: Earth and Environmental Science. DOI: 10.1088/1755-1315/419/1/012016.