

## ESTATÍSTICA MULTIVARIADA EM ESTUDO DE PARÂMETROS DE CONCRETOS AUTOADENSÁVEIS

**MELO, Cássia Vanessa Albuquerque de<sup>1</sup>;**

**CARVALHO, Frede de Oliveira<sup>2</sup>;**

**GOMES, Paulo César Correia<sup>3</sup>.**

<sup>1</sup> Doutora, UFAL, Maceió-AL (cassiamelo@ctec.ufal.br).

<sup>2</sup> Doutor, UFAL, Maceió-AL (fredecarvalho@ctec.ufal.br).

<sup>3</sup> Doutor, UFAL, Maceió-AL (pgomes@ctec.ufal.br).

**Resumo.** Neste artigo buscou-se estudar a variabilidade dos parâmetros de graduação de agregados (PGA) e das variáveis de resposta dos concretos autoadensáveis (CAA), empregando-se uma técnica estatística multivariada denominada análise de componentes principais (ACP). O objetivo desse estudo consiste em implementar esta técnica para detecção e remoção de erros grosseiros, redução de dimensionalidade e investigação da variabilidade das características em relação ao conjunto de dados, no tocante a interpretar a concordância entre as variáveis de altas cargas e resumir, em poucas e relevantes dimensões, a maior parte da variabilidade da matriz de dados formada por amostras de CAA. A ferramenta estatística foi testada para os dados de amostras que incluíram os CAA de estudos disponibilizados na literatura, como também os CAA obtidos em laboratório. Como resultado, a avaliação estatística dos parâmetros dos concretos apresentou-se eficiente, o que demonstrou o seu potencial em se tornar uma ferramenta útil no estudo de concretos. Dos agrupamentos com características mais importantes referente à combinação algébrica das variáveis originais em componentes principais dos CAA, permitiu-se extrair informações da relação dos parâmetros mais relevantes, ou seja, permitiu apresentar uma interpretação da relação entre os PGA que colaboraram com o atendimento à autoadensabilidade.

**Palavras-chave:** Componentes principais, Concreto, Composições de agregados.

## 1 INTRODUÇÃO

A técnica de análise de componentes principais (ou PCA – *Principal Component Analysis*) foi descrita, inicialmente, pelo matemático Karl Pearson em 1901, sendo uma das técnicas estatísticas mais aplicadas em diferentes áreas do conhecimento, como construção civil, agronomia, medicina, química, entre outros (HONGYU *et al.*, 2015).

Na área de materiais cimentícios, CRUZ & NAGAHAMA (2017) avaliaram dados de resistência à compressão e módulo de deformação de concreto de resíduos de construção e demolição, de vários estudos, com 24 variáveis de entrada (módulos de finuras dos agregados miúdos e graúdos naturais e reciclados, percentuais de agregados miúdos e graúdos reciclados, entre outras), e reduziram para 10 variáveis, que explicaram mais de 98,1% da variância total dos dados. Em estudos de pastas, LANG *et al.* (2015) aplicaram a PCA em busca da otimização da trabalhabilidade, com 24 dados experimentais e 4 variáveis originais (concentração de sólidos, relação resíduo/cimento, massa específica e *slump*), para avaliação da influência desses fatores nas propriedades reológicas (tensão de escoamento e viscosidade plástica). Duas componentes principais explicaram 98,63% da variabilidade dos dados.

Vários trabalhos aplicaram a PCA, como o de RAHARJO *et al.* (2013), que buscaram estudar a otimização de misturas de concreto autoadensável, nos quais diferentes dosagens de adições minerais e aditivos químicos foram testados, chegando-se a avaliar 33 composições de de CAA. A variável de resposta estimada foi a resistência à compressão. Reduziu-se para 7 variáveis preditoras, tais como cimento, água, areia, pedra britada, entre outros, para 2 componentes principais, correspondendo a 78,48 % da variabilidade dos dados. No campo de misturas asfálticas, VARGAS-NORDCBECK *et al.* (2017) também mostraram que o uso da técnica multivariada tem respondido de forma eficiente. Estes autores analisaram 12 misturas, cuja propriedade avaliada foi resistência à compressão. No total, 6 variáveis preditoras foram analisadas, entre elas: resistência à tração condicionada e seca, módulo dinâmico condicionado e seco, entre outras, e três componentes principais foram identificados, sendo a primeira componente explicando 61 % dos dados.

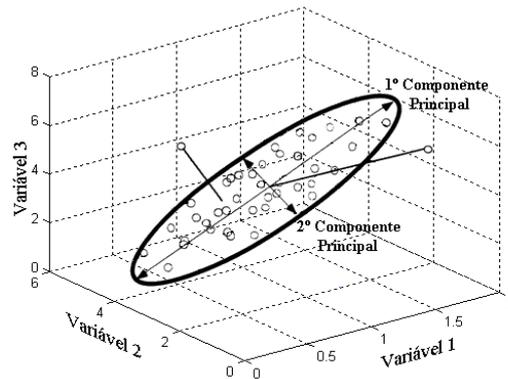
Neste artigo, o estudo se concentrou no uso da técnica multivariada PCA para redução de dimensionalidade e investigação da variabilidade das características em relação ao conjunto de dados, possibilitando a interpretação da concordância entre as variáveis de altas cargas, a fim de condensar a maior parte da variabilidade da matriz de dados formada por amostras de CAA.

## 2 METODOLOGIA

A aplicação da análise de componentes principais se deu com dados de composições de agregados, com dimensão máxima característica dos agregados graúdos de 12,5 mm (G12). Foram consideradas as graduações desenvolvidas neste estudo juntamente com as reportadas na literatura, MONTEIRO *et al.* (2015), FAROKHZAD *et al.* (2016) e NIARAKI e FAROKHZAD (2017), CAVALCANTI (2006), MELO (2005) e GOMES (2002), totalizando 36 amostras, sendo esta uma prática adotada na literatura. A análise PCA foi modelada na dimensão R6, utilizando o *software Statistica* versão 13, considerando seis variáveis: X1 – predominância de diâmetros de partículas (PDP), X2 – coeficiente de uniformidade (CU), X3 – porcentagem de agregado graúdo (PAG), X4 – diâmetro de espalhamento (*slump flow* – SF), X5 – tempo de fluidez no funil V (VF) e X6 – habilidade passante na caixa L (HP).

A análise dos componentes principais é uma ferramenta de estatística multivariada para compressão de dados e extração de informações, que encontra combinações de variáveis, ou

fatores, e descrevem a maior tendência nos dados. Segundo BEEBE (1998), a PCA consiste numa manipulação da matriz de dados com o objetivo de representar variações presentes em muitas variáveis, através de um número menor de fatores. Constrói-se, pela rotação dos eixos originais, um novo sistema de eixos (denominados de fatores, componentes principais, variáveis latentes ou autovetores) para representar as amostras, no qual a natureza multivariada dos dados pode ser visualizada em poucas dimensões (Fig. 1). Essas componentes são obtidas a partir de combinações lineares, Eq. (1), dos dados originais como definido abaixo na Eq(1).



**Figura 1. Representação gráfica das Componentes Principais. Fonte: CARVALHO et al. (2009)**

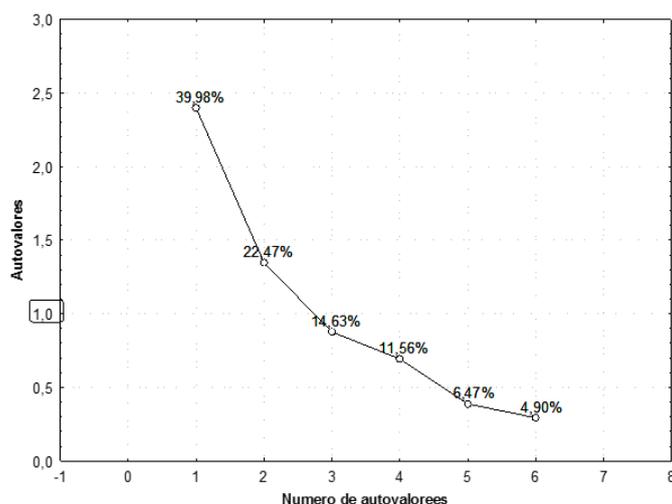
$$\begin{aligned} Z_1 &= c_{11}x_{11} + c_{12}x_2 + \dots + c_{1p}x_p \\ Z_2 &= c_{21}x_1 + c_{22}x_2 + \dots + c_{2p}x_p \\ Z_p &= c_{p1}x_1 + c_{p2}x_2 + \dots + c_{pp}x_p \end{aligned} \quad (1)$$

Onde,  $z_i$  são as componentes principais,  $c_{ij}$  são coeficientes a serem determinados e  $x_{ij}$  são as variáveis originais.

O uso de técnicas de estatística multivariada pode ser mais adequado para o tratamento de dados, pois permite a redução da dimensionalidade do problema, tornando possível resumir a informação contida num grande número de variáveis altamente correlacionadas por um número menor de componentes principais. Antes de iniciar qualquer análise multivariada é necessária a realização de uma manipulação matemática prévia dos dados ou, até mesmo, a remoção de possíveis fontes de variação, AZEVEDO et al. (2000). Em diversos problemas existem variáveis com diferentes dimensões e amplitudes e é necessário um tratamento prévio (autoescalamento) para expressar cada observação em dimensões e amplitudes equivalentes, sem perda de informações. No presente trabalho, utilizou-se o autoescalamento como técnica para pré-processamento dos dados. No autoescalamento é a média de cada variável é subtraída de seus respectivos elementos e dividido pelo desvio padrão.

### 2.3 Resultados

Na aplicação na técnica de análise multivariada, com o pré-processamento das variáveis, obteve-se os três primeiros autovalores indicadores da variância dos autovetores, representando cerca de 77,07 % da variância. A primeira componente representou 39,98 % da variância, enquanto que a segunda e a terceira componente representaram 22,47 % e 14,63 % da variabilidade dos dados, respectivamente. Observa-se, na Figura 2, que até a terceira componente obteve uma maior explicação dos dados e houve uma certa estabilização do gráfico a partir da quarta componente. A rotação dos eixos foi a *Varimax normalized*, mantendo os eixos perpendiculares entre si (Tabela 1).



**Figura 2. Scree plot dos autovalores explicando as proporções de variação derivadas de cada componente principal para o grupo G12.**

**Tabela 1. Composição das componentes principais com as variáveis originais para o grupo G12**

Variáveis originais	CP1	CP2	CP3
PDP (Predominância de diâmetro de partícula)	0,05507	0,88735	0,06244
CU (Coeficiente de uniformidade)	0,78776	-0,29060	0,18964
PAG (Porcentagem de agregado graúdo)	0,82380	0,22675	0,06412
SF (Diâmetro de espalhamento)	-0,00369	0,11759	0,96240
VF (Tempo de fluidez)	0,77471	-0,07333	-0,29951
HP (Habilidade de passagem)	-0,54927	0,57499	0,29545

Conforme as variáveis (Tabela 1), às que melhor explicaram a CP 1 foram as combinações de CU, PAG, VF e HP. CU tem o mesmo sinal de VF e PAG e contrário a HP, estando condizente com a disposição destas variáveis na CP 1, já que a fluidez e habilidade passante são afetadas pela elevada descontinuidade da mistura. Na CP 1, as variáveis agrupadas foram representativas da uniformidade do concreto. Na CP 2, tem as representativas de PDP, que apresentou o maior peso, contribuindo para CP 2. A CP 3 modelou a fluidez do CAA devido a variável SF de maior peso. Observa-se que, na CP 1, as variáveis CU, PAG e VF estão associadas entre si, bem como PDP e HP na CP 2. Na Figura 3, observa-se as projeções espaciais com a dispersão de variáveis, sendo possível identificar as variáveis relacionadas. Na CP 1, Fig. 3a, observa-se que a variável CU correlacionou-se diretamente com PAG e VF; e inversamente com HP. Na CP 2, PDP correlacionou-se diretamente com SF e inversamente com PAG. E na CP 3, PDP se correlacionou diretamente com SF (Fig. 2b).

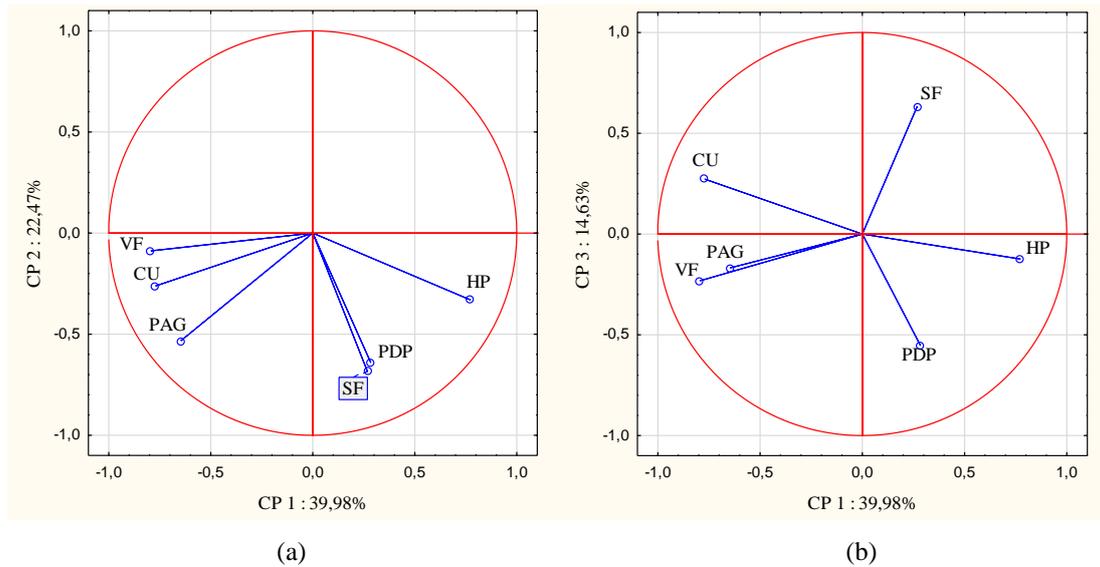


Figura 3. Projeções espaciais da ordenação dos vetores das variáveis para (a) CP1 e CP2, e (b) CP1 e CP3.

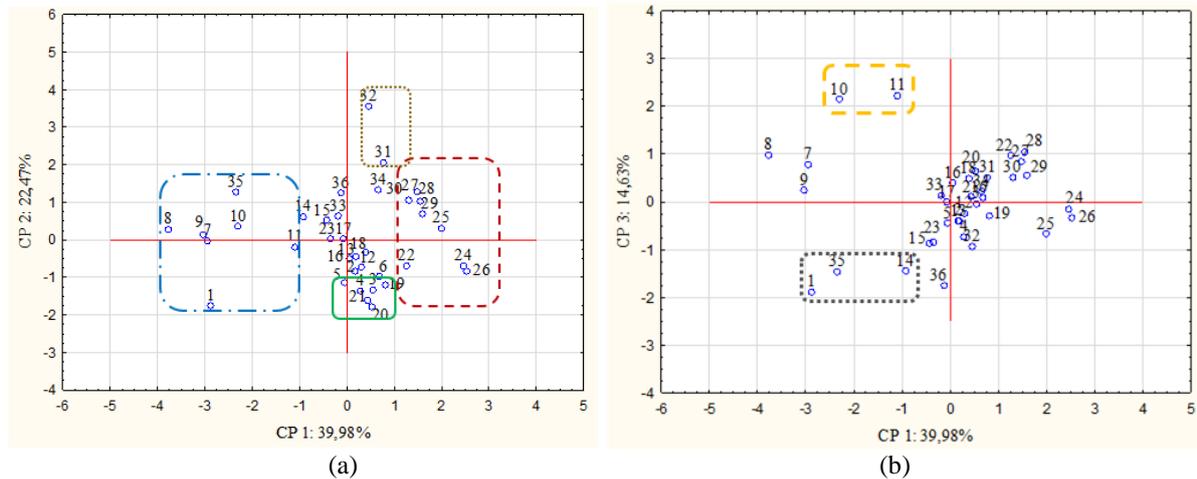


Figura 4. Projeções espaciais de dispersão (a) e (b) dos escores das amostras nestas projeções.

Os escores (autovetores) dos componentes principais, Fig. 4, vê-se a proximidade entre os pontos-amostra, devido a uma certa similaridade. Na CP 1 (Fig. 4a), um grupo de amostras, linha vermelha e tracejada, correlacionou-se diretamente com HP, e inversamente com VF, CU e PAG. Outro grupo, linha azul e traço-ponto, correlacionou-se diretamente com as variáveis VF, CU e PAG, inversamente com HP. Na CP2, observa-se que amostras (linha verde e cheia) se correlacionaram diretamente com as variáveis SF, PDP e PAG. As amostras do grupo (linha marrom pontilhada) correlacionaram-se inversamente com as variáveis SF, PDP e PAG. Na CP 3, notou-se que as amostras (linha amarela tracejada) são diretamente proporcionais a SF e inversamente a PDP. Do lado oposto, as amostras, em linha cinza pontilhada, estão diretamente relacionadas à PDP.

### 3 CONSIDERAÇÕES FINAIS

Com a aplicação da técnica estatística multivariada, com distintas formulações de CAA, permitiu interpretar as variáveis agrupadas. Os resultados confirmaram que as predominâncias das frações miúdas e graúdas, nos CAA, influenciaram nas propriedades do estado fresco.

Distribuições granulométricas mais bem graduadas apresentam melhor continuidade e, devido a isso, as relações de menores PDP e  $PAG \leq 50\%$  tenderam a reduzir a variável SF. No caso em estudo, HP e VF foram inversamente proporcionais, enquanto SF foi diretamente correlacionado à PDP, e vice-versa. Comprova-se, então, a relevância destes ensaios e dos parâmetros de graduação na avaliação de composições de agregados para CAA.

## REFERÊNCIAS

- Azevedo, F. M.; Brasil, L.M.; Oliveira, R. C. L., 2009. Redes Neurais com Aplicações em Controle e em Sistemas Especialistas. **Bookstore**.
- Beebe, K. R., Pell, R. J., Seasholtz, M. B., 1998. **Chemometrics: A Practical Guide**, Wiley-Interscience Publication.
- Carvalho, F. D. O., Garcia, C. A. B., Garcia, H. L., Coelho, F. A., Wanderley, H. S., Santos, R. R. C., Cavalcanti, J., 2009. Sistemas Inteligentes (Redes Neurais) e Estatística Multivariada (PCA) aplicados a qualidade da água. **XVIII Simpósio Brasileiro de Recursos Hídricos**, Campo Grande-MS.
- Cavalcanti, D. J de H., 2006. **Contribuição ao estudo de propriedades de concreto autoadensável visando sua aplicação em elementos estruturais**. Dissertação (Mestrado), Universidade Federal de Alagoas, 141f
- Cruz, K. D.; Nagahama, K. DE J., 2017. Análise da influência de teores de substituição de agregados de resíduo de construção e demolição em concretos utilizando a análise de componentes principais. **Seminário de Iniciação Científica**, n. 21.
- Farokhzad, R.; Mahdikhani, M.; Bagheri, A.; Baghdadi, J., 2016. Representing a logical grading zone for self-consolidating concrete. **Construction and Building Materials**, v. 115, pp.735-745.
- Gomes, P. C. C., 2002. **Optimization and Characterization of High-Strength Self-Compacting Concrete**. Tese (Doutorado) - Universitat Politècnica de Catalunya, 136f.
- Lang, L., 2015. Rheological properties of cemented tailing backfill and the construction of a prediction model. **Materials**, v. 8, n. 5, 2076-2092.
- Matiatos, I., 2016. Nitrate source identification in groundwater of multiple land-use areas by combining isotopes and multivariate statistical analysis: a case study of Asopos basin (Central Greece). **Science of the Total Environment**, v. 541, pp. 802-814.
- Melo, K. A., 2005. **Contribuição à dosagem de concreto autoadensável com adição de fíler calcário**. Dissertação (Mestrado em Engenharia Civil) - UFSC, 2005, 183f.
- Niaraki, R. J.; Farokhzad, R., 2017. Prediction of mechanical and fresh properties of self-consolidating concrete (SCC) using multi-objective genetic algorithm (MOGA). **Journal of Structural Engineering and Geotechnics**, 7 (2), pp.1-13.
- Raharjo, D.; Subakti, A., 2013. Mixed concrete optimization using fly ash, silica fume and iron slag on the SCC's compressive strength. **Procedia Engineering**, v. 54, p. 827-839.
- Vargas-Nordbeck, A.; Leiva-Villacorta, F.; Aguiar-Moya, J. P.; Loria-Salazar, L. G., 2017. Principal component and clustering analysis in moisture damage evaluation of Hot-Mix-Asphalt. **96th Annual Meeting of the Transportation Research Board**, n.17.
- Statistica for Windows software, v. 13, USA, 2013.*