

HAPPY TOGETHER: COMO UTILIZAR ANÁLISE FATORIAL E ANÁLISE DE CLUSTER PARA MENSURAR A QUALIDADE DAS POLÍTICAS PÚBLICAS

DALSON BRITTO FIGUEIREDO FILHO
JOSÉ ALEXANDRE DA SILVA JÚNIOR
RANULFO PARANHOS DOS SANTOS FILHO
ENIVALDO CARVALHO DA ROCHA
WILLBER DA SILVA NASCIMENTO
MARIANA BATISTA DA SILVA
LUCAS EMANUEL DE OLIVEIRA SILVA

RESUMO

Esse artigo demonstra como a análise fatorial e a análise de *cluster* podem ser combinadas para analisar a qualidade de políticas públicas. O desenho de pesquisa replica dados do Banco Interamericano de Desenvolvimento. Primeiramente, utilizamos análise fatorial para estimar um índice de qualidade de políticas públicas a partir de seis variáveis: (1) estabilidade, (2) adaptabilidade; (3) coordenação e coerência; (4) qualidade de implementação; (5) orientação pública e (6) eficiência. Depois disso empregamos análise de *cluster* para classificar os países de acordo com esse indicador. Com esse artigo esperamos difundir a utilização dessas técnicas na pesquisa empírica em Ciência Política.

PALAVRAS - CHAVE

Análise fatorial; análise de *cluster*; políticas públicas.

HAPPY TOGETHER: USING FACTOR ANALYSIS AND CLUSTER ANALYSIS TO MEASURE THE QUALITY OF PUBLIC POLICIES

ABSTRACT

This paper demonstrates how factor analysis and cluster analysis can be combined to examine public policy quality. The research design replicates data from Inter American Development Bank. First, we use factor analysis to estimate a public policy quality index based on six variables: (1) stability, (2) adaptability; (3) coordination and coherence; (4) quality of implementation; (5) public regardness and (6) efficiency. After, we apply cluster analysis to classify countries according to this index. With this paper we hope to diffuse the application of these techniques in Political Science empirical research.

KEYWORDS

Factor analysis; cluster analysis; public policies.

SOBRE OS AUTORES

DALSON BRITTO FIGUEIREDO FILHO

Professor do Departamento de Ciência Política da Universidade Federal de Pernambuco (DCP/UFPE), Doutor e Mestre em Ciência Política pelo Departamento de Ciência Política da Universidade Federal de Pernambuco (DCP/UFPE).

Contato: dalsonbritto@yahoo.com.br.

JOSÉ ALEXANDRE DA SILVA JÚNIOR

Professor da Universidade Federal de Alagoas (UFAL), Doutor e Mestre em Ciência Política pelo Departamento de Ciência Política da Universidade Federal de Pernambuco (DCP/UFPE).

Contato: jasjunior2007@yahoo.com.br.

RANULFO PARANHOS DOS SANTOS FILHO

Professor da Universidade Federal de Alagoas (UFAL), Doutor e Mestre em Ciência Política pelo Departamento de Ciência Política da Universidade Federal de Pernambuco (DCP/UFPE).

Contato: ranulfoparanhos@me.com.

ENIVALDO CARVALHO DA ROCHA

Professor do Departamento de Ciência Política da Universidade Federal de Pernambuco (DCP/UFPE), Pós-doutorando do Departamento de Ciência Política da Universidade Federal de Minas Gerais (DCP/UFMG) e Doutor em Engenharia de Produção pela Universidade Federal do Rio de Janeiro (UFRJ) e Mestre em Estatística pela Universidade de São Paulo (USP)

Contato: enivaldocrocha@gmail.com

WILLBER DA SILVA NASCIMENTO

Graduado em Ciências Sociais pela Universidade Federal de Alagoas (UFAL), Mestre e Doutorando em Ciência Política pela Universidade Federal de Pernambuco (UFPE).

Contato: nascimentowillber@gmail.com.

MARIANA BATISTA DA SILVA

Professora do Departamento de Ciência Política da Universidade Federal de Pernambuco (DCP/UFPE), Doutor e Mestre em Ciência Política pelo Departamento de Ciência Política da Universidade Federal de Pernambuco (DCP/UFPE)

Contato: mariana.bsilva@gmail.com.

LUCAS EMANUEL DE OLIVEIRA SILVA

Graduando em Ciência Política pela Universidade Federal de Pernambuco (UFPE). Membro do Grupo de Métodos de Pesquisa em Ciência Política, (Departamento de Ciência Política da UFPE) e monitor das disciplinas de Métodos Quantitativos e do curso de extensão “SPSS para Cientistas Sociais”. Realiza estudos nas áreas de corrupção, legislativo, replicabilidade e metodologia. Bolsista de iniciação científica do CNPq.

Contato: lukasmanoel@gmail.com.

SUBMETIDO EM

Agosto de 2015.

APROVADO EM

Novembro de 2015.

“Sword of Omens, give me Sight Beyond Sight!”

Lion-O

“Poor people tend to live in clusters”

Eric Cartman

1 - INTRODUÇÃO

A análise da qualidade das políticas públicas é um elemento central na avaliação das ações governamentais. No entanto, a criação de indicadores válidos e confiáveis é um dos principais desafios enfrentados por acadêmicos e gestores públicos. Por um lado, muitas organizações não possuem tecnologias para a coleta sistemática de informações. Por outro, é comum identificar *déficit* de capital humano treinado para estimar indicadores. Em conjunto, esses problemas dificultam a avaliação e o aperfeiçoamento das políticas públicas implementadas por governos.

Spiller *et al.* (2008) elaboraram um dos modelos mais difundidos para a mensuração objetiva da qualidade das políticas. O foco está em características do desenho institucional que teoricamente elevam a qualidade das políticas, independente do seu conteúdo. São elas: (1) estabilidade, (2) adaptabilidade; (3) coordenação e coerência; (4) qualidade de implementação; (5) orientação pública e (6) eficiência. A estabilidade é a capacidade de manter as políticas decididas ou de reforçar os acordos firmados. Adaptabilidade é a capacidade de tomar decisões e resolver problemas. Coordenação e coerência é a capacidade do governo de não “balcanizar” as políticas públicas ou de degenerar o governo em vários “subgovernos” com padrões e clientelas. A qualidade da implementação é a capacidade de traduzir as políticas decididas em ações concretas. A orientação pública é a capacidade dos atores de implementar decisões que beneficiem a população de forma ampla. Por último, a eficiência diz respeito a maximização do retorno dos gastos públicos em termos de resultados, ou seja, fazer mais com menos (Spiller *et al.* 2008).

Como analisar a qualidade das políticas públicas? O principal objetivo deste artigo é demonstrar como as técnicas de análise fatorial e de análise de *cluster* podem ser combinadas para a mensurar a qualidade das políticas implementadas. O foco está na compreensão intuitiva das técnicas e a nossa motivação advém da ausência de literatura pedagógica voltada para a análise de políticas públicas (Kubrusly 2001). Por um lado, a análise fatorial pode ser utilizada para reduzir uma grande quantidade de variáveis observadas em um número menores de fatores/dimensões. Dessa forma, é uma técnica ideal para trabalhar com variáveis altamente correlacionadas. É possível, por exemplo, utilizar a redução de dados para criar indicadores e/ou superar problemas de multicolonariedade em modelos de regressão. Por outro, a análise de conglomerados pode ser utilizada

para classificar casos semelhantes em diferentes grupos. Portanto, é uma técnica bastante adequada para trabalhar com a segmentação de grupos e identificação de padrões. Por exemplo, via análise de *cluster*, pode-se observar que o efeito da variável independente sobre a variável dependente é diferente para os diferentes conglomerados. Por fim, quando consideradas em conjunto, o pesquisador pode empregar a análise fatorial para criar um índice e a análise de conglomerados para classificar os casos de acordo com o indicador síntese. Nesse artigo, ilustramos detalhadamente como esse procedimento pode ser implementado a partir de um exemplo na área de políticas públicas.

Metodologicamente, o desenho de pesquisa replica dados do Banco Interamericano de Desenvolvimento (BID 2013) que operacionaliza as seis dimensões já apresentadas e demonstra como utilizar conjuntamente a análise fatorial e a análise de *cluster* para mensurar a qualidade das políticas públicas. Primeiramente, empregamos a análise fatorial para estimar um índice de qualidade de políticas. Segundo, utilizamos a análise de *cluster* para classificar os países de acordo com esse indicador. Todas as rotinas computacionais foram reportadas com o objetivo de aumentar a transparência e garantir a replicabilidade dos resultados (King 1995; Janz 2015).

O artigo está assim dividido. A próxima seção introduz as técnicas de análise fatorial e de análise de *cluster*. A segunda parte descreve a metodologia. Em seguida apresentamos os resultados. A última seção sintetiza as conclusões.

2 - ANÁLISE FATORIAL E ANÁLISE DE *CLUSTER*

Essa seção apresenta as principais características da análise fatorial e da análise de *cluster* com os objetivos de descrever os fundamentos e lógica de cada técnica e explicar a sua utilização em um desenho de pesquisa de forma isolada ou conjunta¹.

¹ As técnicas de análise fatorial e análise de *cluster* não são técnicas inferenciais. Quando utilizamos análise fatorial estamos interessados em reduzir uma quantidade grande de variáveis em menos fatores e na análise de *cluster* agrupamos os casos baseados em sua semelhança. Nestas técnicas o pesquisador não deve inferir para população os resultados da amostra utilizada. O objetivo é muito mais descritivo e classificatório do que propriamente inferencial (ver Hair *et al.* 2009).

2.1 - O QUE É E PARA QUE SERVE A ANÁLISE FATORIAL?²

As diferentes modalidades de análise fatorial têm um objetivo comum: reduzir a dimensionalidade dos dados (Costelo e Osborne 2005). Ou seja, reduzir uma grande quantidade de variáveis a um número menor de fatores/componentes (Tabachnick e Fidell 2007). Os fatores/componentes são combinações lineares das variáveis observadas que explicam/representam a variação das variáveis originais (Hair *et al.* 2009). Dessa forma, a análise fatorial é particularmente adequada tanto como técnica de redução de dados (Kubrusly 2001) quanto como ferramenta para mensurar fenômenos não diretamente observáveis (Carmines e Zeller 1980). Para os nossos propósitos, iremos mensurar a qualidade das políticas públicas a partir dos seguintes indicadores:

- V₁. Estabilidade
- V₂. Adaptabilidade
- V₃. Coordenação e Coerência
- V₄. Qualidade da Implementação
- V₅. Orientação Pública
- V₆. Eficiência

Quanto maior o valor em cada variável, maior é a qualidade. Um país com *score* máximo em todas as características possui qualidade superior de suas políticas públicas do que um país com *score* baixo em todas as características. A análise fatorial pode ser utilizada para estimar um fator/componente de qualidade das políticas públicas que não é diretamente observável, mas que representa/explica a variação das variáveis originais³.

A análise fatorial também pode ser utilizada para construir índices. Por exemplo, o Índice de Desenvolvimento Humano (IDH) é calculado a partir da agregação de três indicadores observados: educação, longevidade e renda. A metodologia adotada pelo IDH estabelece que cada variável influenciará igualmente a composição do indicador, ou seja, todas as variáveis têm o mesmo peso. No entanto, com a análise fatorial os pesquisadores não precisam estabelecer de forma *a priori*

² Essa seção se baseia em Figueiredo Filho e Silva Junior (2010) e Figueiredo Filho *et al.* (2013). Para uma introdução à lógica intuitiva da análise fatorial ver Hair *et al.* (2009). Para trabalhos clássicos ver Rummel (1967; 1970), Cooper (1983) e Bartholomew (1984). Para textos introdutórios ver Kim e Mueller (1978) e Zeller e Carmines (1980).

³ Outros exemplos podem ser observados em Lijphart (1999) que utiliza análise fatorial para reduzir dez variáveis observadas dos sistemas políticos a duas dimensões latentes: (1) Executivo-Partidos e (2) Federal-Unitária. Coppedge, Alvarez e Maldonado (2008) utilizam análise fatorial para reduzir diferentes indicadores de democracia às dimensões da *poliarquia* de Dahl (1971): contestação e inclusividade.

ou arbitrária os pesos das variáveis, sejam pesos iguais ou diferentes de acordo com alguma expectativa teórica. Nesses casos, a análise fatorial é ideal já que é possível estabelecer os pesos a partir da contribuição relativa de cada variável para a estimação do índice. Dessa forma, tem-se o indicador mais objetivo e com menos erro de mensuração. Operacionalmente, a análise fatorial deve respeitar alguns pressupostos conceituais e estatísticos. O Quadro 1 sumariza essas informações e descreve os estágios que devem ser seguidos para a correta aplicação dessa técnica.

Quadro 1 - Planejamento da análise fatorial em três estágios

Procedimento	O que deve ser observado
Verificar a adequabilidade da base de dados ⁴	Nível de mensuração das variáveis, tamanho da amostra e padrão de correlação entre as variáveis
Determinar a técnica de extração e o número de fatores a serem extraídos	O tipo de extração (<i>principal components, principal factors, image factoring, maximum likelihood factoring, alpha factoring, unweight least squares, generalized least squares</i>)
Decidir o tipo de rotação dos fatores	Se for ortogonal (<i>Varimax, Quartimax, Equamax</i>), se for oblíqua (<i>direct oblimin, Promax</i>)

Fonte: elaboração dos autores.⁴

O primeiro passo é verificar a adequabilidade da base de dados. Deve-se observar o nível de mensuração das variáveis, o tamanho da amostra e a correlação entre as variáveis.

Em relação ao nível de mensuração, as variáveis devem ser preferencialmente contínuas ou discretas. No entanto, muitas vezes os pesquisadores se deparam com variáveis ordinais e nominais. Hair *et al.* (2009) argumentam que é possível incluir algumas variáveis *dummies* em um modelo de análise fatorial que conta com variáveis

⁴ Lembrete: diferente da regressão, a análise fatorial não é afetada por problemas de multicolinearidade já que a redução dos dados depende exatamente do padrão de correlação observada entre as variáveis originais. Da mesma forma, linearidade, homocedasticidade e normalidade também tendem a não ser um problema em modelos fatoriais (Hair et al. 2009).

quantitativas (discretas e/ou contínuas)⁵. Nesse caso, é normal observar que as comunalidades associadas a essas variáveis serão comparativamente mais baixas do que aquelas observadas entre as variáveis discretas e/ou contínuas. As comunalidades representam o total de variância compartilhada entre as variáveis originais e o fator/componente extraído (Cramer e Howitt 2004: 29/30). Quanto maior a comunalidade, maior é a contribuição daquela variável para a criação do índice.

No que diz respeito ao tamanho da amostra, Hair *et al.* (2009) sugerem um mínimo de 50 casos. Tabachnick e Fidell (2007) indicam 300 casos como um tamanho confiável. Schawb (2007) sugere uma razão mínima de cinco casos para cada variável. O guia elaborado pelo *Institute for Digital Research and Education* da Universidade da Califórnia sugere o mínimo de 10 casos por variável para evitar problemas computacionais⁶. Nossa recomendação é de que quanto maior a amostra, melhor. Lembrete: quanto maior o grau de correlação entre as variáveis, menos casos são necessários para conseguir uma solução aceitável. No entanto, muitas vezes os pesquisadores não dispõem de grandes bases de dados. Nesse caso sugerimos minimizar a quantidade de variáveis incluídas e reportar as variáveis que foram excluídas e a justificativa para exclusão.

Por ser uma técnica de redução de dados, é necessário que as variáveis incluídas estejam correlacionadas (independente do sentido). A literatura sugere que a matriz de correlação deve exibir a maior parte dos coeficientes acima de 0,3 (Schawb 2007). Como o objetivo é identificar dimensões latentes, se não há correlação entre as variáveis, não será produtivo construir um indicador conjunto. Sugestão: quanto maior o nível de correlação linear entre as variáveis, tanto melhor. Contudo, não pode existir perfeita multicolineariedade ($r=1$) entre as variáveis já que isso dificulta a identificação da contribuição individual de cada variável para a solução final do modelo.

O próximo passo é selecionar a técnica de extração e determinar o número de fatores/componentes que serão extraídos. Existem diversos métodos de extração (ver quadro 1), sendo o método de componentes principais o mais utilizado uma vez que além de utilizar toda a variância entre as variáveis, é mais adequado quando se quer obter um resumo dos dados. Para Costelo e Osborne (2005), a literatura

5 A literatura sugere que as técnicas de redução de dados funcionam satisfatoriamente com variáveis ordinais e que os pesquisadores devem evitar a utilização de variáveis nominais (Tabachnick e Fidel 2007; Hair *et al.* 2009). Caso todas as variáveis sejam qualitativas (ordinais e/ou nominais) é possível utilizar a análise de correspondência (Greenacre 2007). Outra opção é utilizar a técnica de análise de classes latentes (*Latent Class Analysis - LCA*). Para os interessados em aprofundar os conhecimentos nessa técnica ver <<http://methodology.psu.edu/ra/lca>>. Em termos computacionais, é possível utilizar o *software Latent Gold*, ver <<http://statistica-innovations.com/products/latentgold.html>>.

6 Ver <<http://www.ats.ucla.edu/stat/spss/output/factor1.html>> .

sobre métodos de extração é relativamente escassa⁷. Fabrigar *et al.* (1999) sugerem que o método da máxima verossimilhança é mais adequado quando os dados são normalmente distribuídos. Em caso de violação desse pressuposto, deve-se optar pelos diferentes métodos de *principal factors*.

A análise fatorial (AF) produz fatores, enquanto a análise de componentes principais (ACP) gera componentes⁸. A ACP utiliza toda a variância observada (única e compartilhada) enquanto que a AF utiliza apenas a comum. Para Tabachnick e Fidell (2007),

“se você estiver interessado numa solução teórica não contaminada por variabilidade de erro, a análise fatorial deve ser sua escolha. Se você quiser simplesmente um resumo empírico do conjunto de dados, a análise de componentes principais é uma escolha melhor” (Tabachnick e Fidell 2007: 608).

Em síntese, na análise fatorial, o pesquisador acredita que algum fator latente exerce um efeito causal sobre as variáveis observadas. Por isso, elas são correlacionadas. As variáveis são causadas pelo fator não diretamente observável. A análise de componentes é uma ferramenta de redução de dados, sem necessariamente uma motivação teórica bem definida. Os componentes representam de forma parcimoniosa a variância observada nas variáveis originais. Quando a magnitude da correlação entre as variáveis é alta, o número de fatores/componentes a ser extraído for o mesmo e as comunalidades forem similares, os resultados são bastante semelhantes, independente do método de extração (Tabachnick e Fidell 2007; Hair *et al.* 2009).

A determinação do número de fatores/componentes a serem extraídos é um dos principais problemas da análise fatorial (Preacher *et al.* 2007). Em geral, a determinação do número de fatores/componentes pode seguir duas diferentes abordagens: (1) teórica/confirmatória e (2) empírica/exploratória. Na perspectiva confirmatória o pesquisador utiliza a teoria disponível para testar em que medida a solução encontrada por outros trabalhos se mantém consistente. Além disso, é possível estimar em que medida diferentes variáveis podem ser reduzidas a um conjunto menor de fatores/componentes teoricamente inteligíveis. Por outro lado, a perspectiva exploratória é guiada por critérios empíricos de ajuste⁹. Os critérios mais recorrentes são a regra de Kaiser (*eigenvalue*), a análise gráfica do *Scree plot*

7 Tabachnick e Fidell (2007) apresentam uma discussão sistemática sobre as diferentes técnicas de extração.

8 A ACP é mais adequada para fins de redução de dados já que os componentes representam combinações lineares das variáveis observadas. A AF é mais indicada para testar a validade teórica de dimensões latentes que explicam a variação das variáveis originais.

9 Ver <<http://www.theanalysisfactor.com/factor-analysis-how-many-factors/>>.

e a análise da variância acumulada.

O próximo passo é decidir o tipo de rotação. O objetivo da rotação é facilitar a interpretação da solução observada sem alterar as suas propriedades matemáticas originais (Tabachnick e Fidell 2007). Existem duas principais classes de rotação: (1) ortogonal e (2) oblíqua.

A rotação ortogonal produz fatores/componentes independentes. A matriz de autovalores (*loading matrix*) apresenta a correlação entre as variáveis observadas e os fatores/componentes extraídos. Por um lado, a rotação é mais fácil de interpretar. Por outro, é mais difícil assumir teoricamente sua razoabilidade já que pressupõe que os fatores/componentes extraídos são não correlacionados. Imagine utilizar diferentes variáveis observadas para estimar as dimensões não observáveis da Poliarquia de Dahl (1971): contestação e inclusividade (Coopedge, Alvarez e Maldonado 2008). Na rotação ortogonal deve-se assumir que a correlação entre essas duas dimensões é zero, ou seja, elas são estatisticamente independentes (ortogonais). A rotação oblíqua permite que os fatores/componentes sejam correlacionados. Dessa forma ela é teoricamente mais razoável. A desvantagem é que a sua interpretação é mais complicada. Por fim, depois de decidir o tipo de rotação, deve-se fazer a implementação computacional da técnica e interpretar substantivamente os resultados.

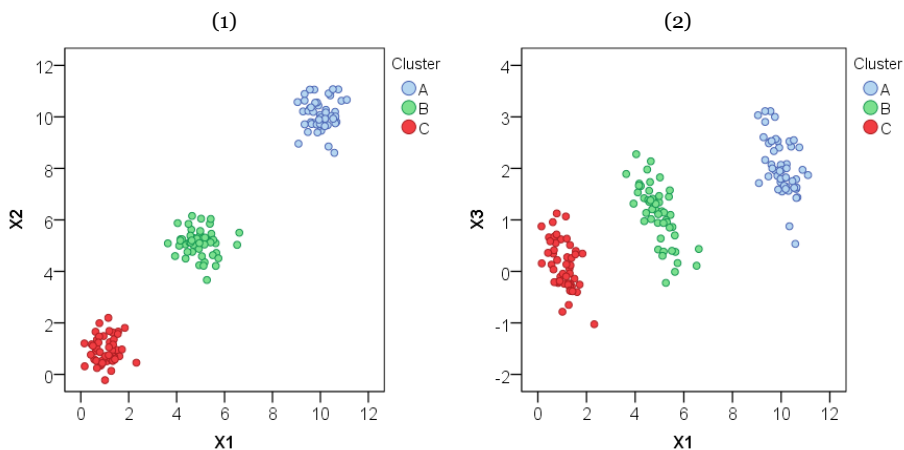
2.2 O QUE É E PARA QUE SERVE A ANÁLISE DE CLUSTER?¹⁰

A análise de *cluster*/agrupamentos/conglomerados é uma denominação genérica dada a um conjunto de diferentes técnicas que podem ser utilizadas para classificar casos em grupos (Aldenderfer e Blashfield 1984). Os casos classificados em um mesmo grupo são mais parecidos entre si e, naturalmente, mais diferentes das observações classificadas em outros grupos (Hair *et al.* 2009). De forma geral, a análise fatorial agrupa variáveis, enquanto a análise de *cluster* agrupa casos. A figura 1 exemplifica a importância de considerar a estrutura conglomerada dos dados antes de fazer inferências sobre a relação entre variáveis.

A figura ilustra a separação dos dados em três grupos (A, B e C) a partir de duas variáveis. Ao se considerar a figura da esquerda, observa-se uma correlação de 0,980 (p -valor < 0,001; $n = 150$), considerando todos os casos juntos. No entanto,

¹⁰ Neste trabalho utilizamos os termos “*cluster*”, “conglomerado” e “agrupamento” como equivalentes. Essa seção se baseia em Figueiredo Filho, Silva Junior e Rocha (2011) e Figueiredo Filho *et al.* (2014). Para trabalhos clássicos utilizando a análise de *cluster* ver Zubin (1938), Tryon (1939) e Driver e Kroeber (1932). Para uma revisão da literatura ver Bailey (1975). Para uma introdução ver Aldenderfer e Blashfield (1984). Para uma análise de *cluster* das votações congressuais ver MacRae (1966).

Figura 1 - Exemplo de uma análise de *cluster*



Fonte: elaboração dos autores.

ao se considerar a análise desagregada por *cluster*, a correlação desaparece: A ($r = 0,019$; p -valor = $0,897$; $n = 50$), B ($r = -0,096$; p -valor = $0,509$; $n = 50$) e C ($r = 0,052$; p -valor = $0,719$; $n = 50$). Similarmente, ao se analisar a figura da direita, observa-se uma correlação positiva de $0,776$. Todavia, a análise por *cluster* revela um padrão totalmente diferente: a correlação é negativa para todos os grupos: A ($r = -0,528$; p -valor = $0,001$; $n = 50$), B ($r = -0,701$; p -valor = $0,001$; $n = 50$) e C ($r = -0,501$; p -valor = $0,001$; $n = 50$). Esses exemplos demonstram que ignorar a natureza conglomerada dos dados pode levar o pesquisador a inferências erradas¹¹. Além disso, em muitas oportunidades os pesquisadores desejam classificar casos em grupos. A análise de *cluster* é ideal na medida em que fornece uma ferramenta objetiva e replicável que pode ser utilizada na construção de tipologias teoricamente orientadas e/ou análises exploratórias mais sistemáticas.

A lógica subjacente da análise de *cluster* é semelhante à análise fatorial. A análise fatorial procura representar uma determinada quantidade de variáveis a partir de um número mais reduzido de fatores/componentes. Já a análise de conglomerados procura representar uma determinada quantidade de casos a partir de um número reduzido de grupos (*clusters*). Os casos são agrupados de acordo

11 Por exemplo, o paradoxo de Simpson surge quando o efeito observado para um determinado grupo desaparece ou até mesmo é troca de sinal quando os grupos são combinados em uma mesma análise. Em geral, ele ocorre quando o pesquisador omite a inclusão de uma variável categórica que pode afetar a relação de interesse. Ver, por exemplo, <<http://www.toomandre.com/alunos/init/simpson.pdf>> e <<http://www3.nd.edu/~bu-siforc/handouts/Other%20Articles/simpsonparadox.html>>. Para uma ilustração bastante didática sobre o paradoxo ver <<http://vudlab.com/simpsons/>>. Agradecemos ao parecerista por essa observação.

com o nível de similaridade mútua e essa semelhança é calculada em termos de alguma medida de distância. Existem diferentes formas de mensurar a distância entre diferentes pontos. Em geral, procura-se maximizar a diferença *entre* os grupos e minimizar a diferença *dentro* do grupo. O planejamento de uma análise de *cluster* deve seguir cinco estágios:

1. Seleção/identificação da amostra/população
2. Seleção das variáveis
3. Determinação da medida de similaridade e do método de aglomeração
4. Definição do número de grupos (*clusters*)
5. Validação dos resultados

Diferente de outras técnicas, a determinação do tamanho da amostra na análise de *cluster* não diz respeito à inferência estatística. Ou seja, o pesquisador não está interessado em estimar em que medida os resultados observados na amostra podem ser generalizados para a população. Contudo, a amostra deve ser grande o suficiente para que pequenos grupos existentes na população sejam representados. Dolnicar (2002) afirma que não existe uma regra geral sobre a determinação do número de casos. Sugestão: quanto mais variáveis, maior deve ser o tamanho da amostra. Uma possibilidade é utilizar uma regra similar àquela utilizada na determinação do tamanho da amostra em um modelo de regressão, para cada parâmetro estimado ter no mínimo 50 casos (Tabachnick e Fidell 2007). Lembrando que a análise de *cluster* também é sensível à presença de *outliers*, de modo que o pesquisador deve utilizar as ferramentas disponíveis para a detecção de observações atípicas e decidir como lidar com esses casos (Figueiredo Filho *et al.* 2014). Por exemplo, Hair *et al.* (2009) sugerem a inspeção do gráfico do diagrama de perfil (*profile diagram*) e a recodificação/exclusão de casos muito destoantes.

O segundo passo é selecionar as variáveis que serão utilizadas para calcular a similaridade entre os casos. Para Aldenderfer e Blashfield (1984), a seleção das variáveis é um dos procedimentos mais importantes da análise de *cluster*. Hair *et al.* (2009) sugerem que apenas variáveis teoricamente relevantes devem ser incluídas. Como a técnica sempre separa as observações em grupos, a inclusão indutiva de variáveis pode produzir resultados conceitualmente vazios que não contribuem para o acúmulo do conhecimento científico.

Depois de selecionar as variáveis, o próximo passo é definir a medida de similaridade. Existem diferentes formas de medir o nível de semelhança das observações e diferentes medidas tendem a produzir soluções distintas. O pesquisador deve observar o nível de mensuração das variáveis bem como o conhecimento específico de sua área de pesquisa. O importante é definir de forma transparente as escolhas metodológicas. Recomendação: analistas com pouca familiaridade devem optar pelas medidas mais convencionais e utilizar outras

medidas ao longo de seu processo de aprendizagem. Comparativamente, a distância euclidiana e o quadrado da distância euclidiana são medidas de similaridade usualmente empregadas (Tabachnick e Fidell 2007).

Depois de selecionar a medida, deve-se definir o método de aglomeração. Ou seja, o pesquisador deve definir como a distância será calculada e quantos grupos devem ser criados. Existem três grandes famílias de métodos aglomerativos: (1) método hierárquico; (2) *K-means* e (3) *two-step*. No método hierárquico, os *clusters* são aninhados, ou seja, não são mutuamente excludentes. É possível determinar uma amplitude de *clusters* ou definir exatamente o número de grupos. A abordagem *k-means* é especialmente apropriada para grandes amostras ($n > 1.000$) já que não calcula a matriz de distância entre todos os casos. Como medida de similaridade, a abordagem *k-means* utiliza a distância euclidiana e define o número de *clusters a priori*. O método *two-step* deve ser utilizado para trabalhar com bases de dados grandes (*big data*) já que tanto o método hierárquico quanto o *k-means* podem apresentar problemas de convergência quando a amostra é demasiadamente grande. Além disso, a abordagem *two-step* é mais informativa, incluindo um gráfico que compara a importância de cada variável na definição dos *clusters*.

O próximo passo é definir o número de grupos/*clusters* (K). É preferível que essa escolha seja teoricamente orientada. Por exemplo, se outros estudos sugerem a existência de uma estrutura $k = 3$ (três grupos/*clusters*), uma possibilidade analítica é replicar o número de grupos com o objetivo de avaliar a estabilidade da solução. Na ausência de orientação teórica, o pesquisador tem mais liberdade para adotar uma perspectiva exploratória.

Por fim, os resultados devem ser validados (Hair *et al.* 2009). Para tanto, o pesquisador pode dividir aleatoriamente a amostra original em dois grupos e comparar as soluções obtidas em cada grupo. Outro procedimento de validação é analisar a distribuição de uma variável exógena que não tenha sido utilizada no modelo inicial. Por exemplo, ao classificar países de acordo com o nível de democratização, o pesquisador pode estimar em que medida a probabilidade de entrar em conflito varia entre diferentes níveis de democratização, assumindo que quanto mais democrático, menor é a chance de conflito. As próximas seções apresentam a metodologia e a aplicação da análise fatorial e da análise de *cluster* ao estudo da qualidade de políticas públicas.

3 - METODOLOGIA

Essa seção descreve todos os procedimentos metodológicos afim de facilitar a replicabilidade dos resultados (King 1995; King 2003; Bowers 2011; Lupia 2014;

Dafoe 2014). O quadro 2 sumariza as principais características do desenho de pesquisa.

Quadro 2 - Desenho de pesquisa

População	209 países
Variáveis	(1) estabilidade, (2) adaptabilidade; (3) coordenação e coerência; (4) qualidade de implementação; (5) orientação pública e (6) eficiência.
Técnicas	Análise fatorial e análise de <i>cluster</i>
Fonte	<i>Inter American Development Bank</i> ¹²

Fonte: elaboração dos autores com base em Chuaire e Scartascini (2014). ¹²

A matriz original conta com 209 observações e mais de 500 variáveis. Para os propósitos desse artigo, serão utilizados os seguintes indicadores: (1) estabilidade, (2) adaptabilidade; (3) coordenação e coerência; (4) qualidade de implementação; (5) orientação pública e (6) eficiência. O quadro 3 apresenta a forma como cada variável foi mensurada:

Quadro 3- Descrição das variáveis de qualidade das políticas públicas

Variável	Descrição	Indicadores
Estabilidade	Extensão em que as políticas são estáveis ao longo do tempo	<ul style="list-style-type: none"> - Adaptabilidade: resposta em uma escala de 1 a 10 para a pergunta "Quão inovador e flexível é o governo?" - Resposta Efetiva: resposta em uma escala de 1 a 10 sobre a habilidade do governo de responder efetivamente a problemas econômicos domésticos - Capacidade Decisória: avaliação de especialistas sobre a capacidade decisória das autoridades políticas numa escala de 1 a 4
Adaptabilidade	Extensão em que as políticas possam ser mudadas quando falham ou quando as circunstâncias mudam	<ul style="list-style-type: none"> - Índice Fraser: desvio-padrão do Índice Fraser de Liberdade Econômica - Mudanças: identifica se mudanças legais ou políticas ocorreram nos últimos 5 anos numa escala de 1 a 7 - Comprometimento: identifica se novos governos honram os contratos estabelecidos por governos anteriores numa escala de 1 a 7 - Consistência: avaliação de especialistas sobre a consistência e continuidade da ação governamental na economia numa escala de 1 a 4
Coordenação e Coerência	Grau em que as políticas são consistentes com políticas relacionadas	<ul style="list-style-type: none"> - Coordenação: classificação da efetividade e coordenação entre o governo central e organizações do governo local numa escala de 0 a 10 - Coordenação: classificação da coordenação e cooperação entre os ministros e no interior da administração numa escala de 1 a 4

¹² A base de dados utilizada nesse trabalho está disponível em: <http://www.iadb.org/en/research-and-data/publication-details,3169.html?pub_id=IDB-DB-112>.

Qualidade da Implementação	Grau em que as políticas são implementadas adequadamente após aprovação pelo Legislativo	<ul style="list-style-type: none"> - Salário Mínimo: avaliação por especialistas numa escala de 1 a 7 do grau de implementação do salário mínimo no país - Sonegação de Impostos: avaliação por especialistas numa escala de 1 a 7 do grau da sonegação de impostos no país - Regulação Ambiental: avaliação por especialistas numa escala de 1 a 7 do grau de implementação da regulação ambiental - Implementação: resposta na escala de 1 a 10 para a pergunta: “quão efetivo é o governo na implementação de suas políticas?” - Decisividade: classificação numa escala de 1 a 10 da habilidade do governo de formular e implementar iniciativas de políticas nacionais - Impostos: classificação da efetividade do Estado no recolhimento dos impostos numa escala de 0 a 10
Orientação Pública	Grau em que as políticas buscam o interesse público	<ul style="list-style-type: none"> - Favoritismo: resposta numa escala de 1 a 7 para a pergunta: “Em que medida os governantes mostram favoritismo para indivíduos e firmas bem-conectadas na decisão sobre políticas e contratos?” - Transferências Sociais: avaliação por especialistas se as transferências sociais vão prioritariamente mais pobres numa escala de 1 a 7 - Corrupção: percepção de corrupção numa escala de 1 a 7
Eficiência	Extensão em que as políticas refletem a alocação de recursos de modo a alcançar o maior retorno	<ul style="list-style-type: none"> - Gastos Públicos: classificação da qualidade dos gastos numa escala de 1 a 7 - Eficiência: resposta numa escala de 1 a 10 para a questão: “Em que medida o governo faz uso eficiente dos recursos humanos, financeiros e organizacionais?” - Eficiência: classificação por especialistas numa escala de 0 a 4 da efetividade do sistema político na formulação e execução das políticas.

Fonte: elaboração dos autores com base em Chuaire e Scartascini (2014).

Cada variável analisada é por si só um indicador composto de outras variáveis de modo a capturar a complexidade do tema. Todas as variáveis foram padronizadas para variar no mesmo sentido (quanto maior melhor) e no mesmo intervalo (entre 0 e 4). Quanto maior, mais desenvolvida é a capacidade. Os autores do estudo original selecionaram os indicadores para compor cada variável e construíram as seis variáveis de qualidade das políticas públicas com base na expectativa teórica anterior e considerando a correlação entre os indicadores (Chuaire e Scartascini 2014)

A análise fatorial também poderia ser utilizada para confirmar as dimensões estabelecidas a partir dessas seis variáveis. Contudo, o objetivo do presente trabalho é usar a análise fatorial para estimar um índice padronizado de qualidade de políticas públicas e a análise de *cluster* para classificar os países de acordo com esse indicador. As análises estatísticas foram realizadas a partir do *SPSS (Statistical Package of Social Science)* e todas as rotinas computacionais foram devidamente reportadas em notas de rodapé. Notar que o número de casos e o tipo das variáveis são apropriados para o uso das técnicas apresentadas a seguir.

4 - RESULTADOS

A tabela 1 mostra a matriz de correlação das variáveis descritas no quadro 3, primeiro passo substantivo para a análise fatorial. Nesse trabalho, utilizamos seis indicadores calculados a partir da ponderação de diferentes indicadores observados em vários níveis de mensuração. O efeito disso é um maior nível de variabilidade, o que torna a aplicação da técnica mais adequada. Por exemplo, ao se calcular a média de duas variáveis discretas (número de mortes e quantidade de assaltos), o resultado é uma variável contínua.

Para que a base de dados seja considerada adequada para realização da análise fatorial, a matriz de correlação deve apresentar a maior parte dos coeficientes superior a 0,3 (independente do sinal) (Hair *et al.* 2009). Quanto maior a magnitude da correlação entre as variáveis tanto melhor. Em nosso exemplo, todos os coeficientes superaram o patamar mínimo de 0,3, sugerindo que o padrão de correlação entre as variáveis é consistente. O próximo passo é analisar as estatísticas de adequação da amostra. A tabela 2 sumariza essas informações.

Tabela 1 - Matriz de correlação¹³

r p-valor n	Estabilidade	Adaptabi- lidade	Coordenação	Imple- mentação	Orientação Pública	Eficiência
Estabilidade	1	0,444 0,000 132	0,452 0,000 119	0,485 0,000 135	0,499 0,000 140	0,482 0,000 137
Adaptabilidade		1	0,635 0,000 130	0,776 0,000 147	0,680 0,000 147	0,703 0,000 146
Coordenação			1	0,776 0,000 130	0,772 0,000 130	0,656 0,000 129
Implementação				1	0,813 0,000 151	0,779 0,000 150
Orientação Pú- blica					1	0,850 0,000 160
Eficiência						1

Fonte: elaboração dos autores.

¹³ Rotina: *analyze--> correlate--> bivariate.*

Tabela 2 - Adequação da amostra¹⁴

KMO	0,899
BTS (chi2)	599,975
p-valor	0,001

Fonte: elaboração dos autores.

O teste Kaiser-Meyer-Olkin (KMO) é uma medida de adequação da amostra que testa se as correlações parciais entre todos os itens são pequenas. O resultado do teste varia entre 0 e 1 e quanto mais perto de 1, mais adequado. Deve-se evitar a aplicação da análise fatorial quando o KMO for inferior a 0,6. O teste de esfericidade de Bartlett's (BTS) também informa a adequabilidade dos dados. O teste identifica se a matriz de correlação é uma identidade, caso em que o modelo fatorial é inapropriado. A hipótese nula defende que as variáveis não são correlacionadas ($r = 0$). Dessa forma, um resultado estatisticamente significativo ($p\text{-valor} < 0,05$) indica que a hipótese nula deve ser rejeitada. Em nosso exemplo, o KMO foi de 0,899 com um BTS estatisticamente significativo ($p\text{-valor} < 0,001$). Ou seja, ambos indicadores sugerem que a amostra é adequada. O próximo passo é observar as comunalidades. A tabela 3 apresenta essas informações.

Tabela 3 - Comunalidades

Variável	Extração
Estabilidade	0,392
Adaptabilidade	0,750
Coordenação e coerência	0,739
Implementação	0,862
Orientação Pública (OP)	0,876
Eficiência	0,810

Fonte: elaboração dos autores

As comunalidades representam a proporção da variância explicada pelo fator/ componente extraído, ou seja, elas indicam o peso/importância de cada variável sobre a construção do índice. A variável *Estabilidade* apresentou a menor comunalidades (0,392). A literatura sugere que apenas variáveis com comunalidades acima de 0,4

¹⁴Rotina: *analyze--> dimension reduction--> factor / descriptives--> KMO and Bartlett's test of sphericity.*

devem ser mantidas na estimação do modelo final (Tabachnick e Fidell 2007). O pesquisador deve então excluir a variável uma vez que ela contribui menos para a criação do fator/componente. Contudo, se a variável for importante teoricamente e o seu desvio do limite mínimo for pequeno, o pesquisador pode optar por manter a variável, justificando e reconhecendo o seu efeito sobre a contribuição das demais variáveis.

Outro procedimento para avaliar o padrão de correlação entre as variáveis é examinar o Alfa de Cronbach¹⁵. Ele varia entre 0 e 1. Quanto maior, mais confiável. A análise de confiabilidade com todas as variáveis apresentou um Alfa de Cronbach de 0,923. Ao se excluir a variável *Estabilidade*, a variância da escala passaria para 12,830 (maior comparativamente) com um nível de correlação corrigida entre os itens de 0,528 (menor comparativamente), produzindo um novo Alfa de 0,940. A tabela 4 sumariza esses dados.

Tabela 4 - Estatística da escala¹⁶

Variável	Variância da escala se o item for excluído	Correlação corrigida	Alfa Cronbach da escala se o item for excluído
Estabilidade	12,830	0,528	0,940
Adaptabilidade	11,239	0,794	0,907
Coordenação e coerência	10,621	0,787	0,910
Implementação	11,505	0,881	0,897
Orientação Pública	10,826	0,891	0,893
Eficiência	11,750	0,840	0,902

Fonte: elaboração dos autores.

Tanto a análise das comunalidades quanto a análise de confiabilidade indicam que a variável Estabilidade contribui menos para a criação de um índice/componente/fator de qualidade de políticas públicas. Como a variável possui relevância teórica e o desvio é pequeno, optamos por manter essa variável na análise. No entanto, o pesquisador pode cogitar a exclusão e/ou comparação das soluções com e sem a variável. Independente da opção, sugerimos que todos os procedimentos sejam devidamente reportados para aumentar a transparência dos

¹⁵ Esse coeficiente mensura o grau de consistência interna, ou seja, ele mede o nível de relacionamento entre as variáveis incluídas na análise. Em geral, é utilizado para medir a confiabilidade de itens de questionário, principalmente na área da Psicologia. Tecnicamente, o coeficiente é calculado como função do número e da média da correlação entre os itens. Ver <<http://www.ats.ucla.edu/stat/spss/faq/alpha.html>>.

¹⁶ Rotina: *analyze--> scale --> reliability analysis*.

resultados.

Depois de observar a adequação da amostra, o próximo passo é decidir quantos fatores/componentes serão extraídos. Tanto a variância acumulada quanto o *scree plot*¹⁷ auxiliam o pesquisador a tomar essa decisão. Utilizamos o método de análise de componentes principais (ACP). Em nosso exemplo, o fator/componente extraído a partir do modelo com todas as variáveis carregou 73,80% da variância das variáveis originais com um autovalor 4,428. A literatura sugere que o fator/componente deve extrair, no mínimo, 60% de informação das variáveis observadas. A tabela 5 e a figura 2 sumarizam essas informações.

A regra de Kaiser sugere que apenas componentes com autovalor >1 devem ser extraídos (ver linha paralela ao eixo X no gráfico). Em relação ao *Scree plot*, deve-se observar a variação do autovalor entre os componentes extraídos. Uma queda abrupta indica que muita variância (informação) foi perdida, logo, o pesquisador deve parar a extração dos fatores/componentes. Em síntese, tanto a variância acumulada, quanto a regra de Kaiser e o exame do *Scree plot* indicam que apenas um fator/componente deve ser extraído para representar/explicar a variação das variáveis originais. A extração de um único fator para as seis variáveis indica que o conjunto dessas variáveis pode formar um índice, que chamaremos de Índice de Qualidade de Políticas Públicas (IQPP). Por fim, deve-se analisar a matriz de componentes. A tabela 6 sintetiza essas informações.


Tabela 5 - Autovalor e variância extraída

Componente	Total	Variância (%)	Acumulada (%)
1	4,428	73,800	73,800
2	0,672	11,200	
3	0,360	6,003	
4	0,262	4,375	
5	0,165	2,743	
6	0,113	1,879	

Fonte: Elaboração dos autores.

¹⁷ Rotina: *analyze--> dimension reduction--> factor / extraction--> scree plot*.

Figura 2 - Scree plot



Fonte: Elaboração dos autores.

Deve-se observar a carga fatorial de cada variável¹⁸. No caso da extração de mais de um componente/fator, o pesquisador deve observar três elementos: (1) em que medida a correlação entre as variáveis e o componente/fator é teoricamente inteligível; (2) verificar se nenhuma variável viola o pressuposto da estrutura simples, ou seja, nenhuma variável pode apresentar carga fatorial acima de 0,4 em mais de um fator/componente e (3) observar se alguma variável viola o pressuposto “do bloco do eu sozinho”, ou seja, nenhuma variável pode criar isoladamente um fator/componente. Se for o caso, deve-se eliminar as variáveis problemáticas da análise e estimar o modelo novamente (Schawb 2007). O procedimento final é salvar os valores do componente/fator associado a cada observação da base de dados¹⁹. Uma vez salvos, os valores dos fatores podem ser usados como uma nova variável para análise descritiva ou como variável dependente ou independente em outros modelos²⁰. A Figura 3 apresenta a distribuição dos países de acordo com o Índice de Qualidade de Políticas Públicas (IQPP).

18 Só faz sentido pensar em rotacionar os fatores/componentes quando a solução final do modelo extrair mais de uma dimensão. Em nosso caso, todas as estatísticas de ajuste (Kaiser, variância acumulada e gráfico de sedimentação) sugerem apenas um único fator/componente.

19 Rotina: *analyze--> dimension reduction--> factor / scores-->save as variables (regression)*


20 Uma das vantagens da redução de dados é superar o problema gerado por altos níveis de correlação entre as variáveis independentes (multicolinearidade). Isso porque, como os fatores/componentes são estimados a partir da variância compartilhada entre as variáveis originais, o pesquisador pode empregar essa técnica antes de estimar seu modelo de regressão.

Tabela 6 - Matriz de componentes

Variável	Componente 1
Estabilidade	0,626
Adaptabilidade	0,866
Coordenação e coerência	0,860
Implementação	0,928
Orientação Pública (OP)	0,936
Eficiência	0,900

Fonte: elaboração dos autores.

Figura 3 - Distribuição dos países de acordo com a Qualidade das Políticas Públicas



Fonte: elaboração dos autores

As dimensões estimadas a partir da análise fatorial possuem média 0 e desvio-padrão igual a 1. O nosso indicador permite observar a variação da qualidade das políticas em perspectiva comparada. Quanto maior o valor do índice, melhor a qualidade da política pública. Observamos uma concentração de casos no lado esquerdo (abaixo da média), indicando países com limitada qualidade de suas políticas. Para garantir resultados mais robustos estimamos uma correlação entre o IQPP e o *Policy Index* criado pelo BID (2013). O coeficiente foi de 0,999 com

p-valor <0,001 (n = 174), ou seja, são estatisticamente iguais.

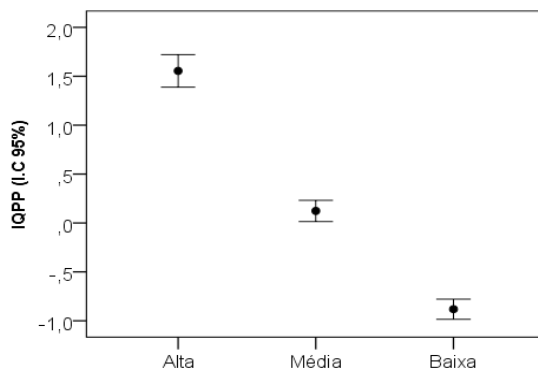
Depois de estimar o IQPP, o próximo passo é utilizar esse indicador para classificar os casos de acordo com seus níveis de similaridade. Inicialmente, utilizaremos a análise de *cluster* para classificar os países em três grupos de acordo com a qualidade das políticas públicas: (1) alta; (2) média e (3) baixa. Em particular, optamos pela solução *K-means cluster*. A tabela 7 e a figura 4 ilustram os resultados.

Tabela 7 - análise de cluster²¹

IQPP	n	média	dp	cv
Alta	25	1,55	0,40	0,26
Média	41	0,12	0,34	2,83
Baixa	51	-0,88	0,37	0,42

Fonte: Elaboração dos autores. ²¹

Figura 4- *Clusters* - Qualidade das Políticas Públicas



Fonte: Elaboração dos autores.

O grupo de países com alta qualidade de políticas públicas apresentou média de 1,55, desvio padrão de 0,40 e coeficiente de variação de 0,26. O grupo com qualidade média tem o valor final do centro do *cluster* de 0,12, desvio padrão de 0,34 e coeficiente de variação de 2,83. Comparativamente, esses resultados sugerem que o segundo grupo é significativamente mais heterogêneo do que o


²¹ Rotina: Analyze -->classify --> K-means Cluster.

primeiro. O último grupo (qualidade baixa) apresenta média de -0,88, com desvio padrão de 0,37 e coeficiente de variação de 0,42. Ao se considerar a figura 4 é possível visualizar melhor a diferença de magnitude da média de cada grupo. Como a análise de *cluster* maximiza a homogeneidade interna, não há interseção entre os intervalos de confiança da distribuição de cada grupo.

Para ilustrar as vantagens analíticas da análise de conglomerados, iremos examinar a correlação entre o índice de qualidade de políticas públicas (IQPP) e o índice de capacidade de governo (ICG). A figura 5 ilustra essas informações.

A correlação entre os indicadores é forte ($r = 0,912$) e estatisticamente significativa ($p\text{-valor} < 0,001$; $n = 118$). No entanto, ao se desagregar a análise por *cluster*, observa-se que o nível de correlação para o grupo de baixa qualidade é de 0,569 ($p\text{-valor} < 0,001$; $n = 51$), muito próximo do coeficiente do grupo de média qualidade ($r = 0,571$; $p\text{-valor} < 0,001$; $n = 41$). A correlação entre os dois indicadores no *cluster* de alta qualidade é de 0,735 ($p\text{-valor} < 0,001$; $n = 26$). É preciso diferenciar a correlação entre os grupos da correlação entre os grupos. Como se observa na Figura 5 a correlação entre os grupos é bem mais forte que a correlação dentro dos grupos. Em certos casos a associação entre grupos pode ser inexistente enquanto que ela pode ser forte dentro dos grupos. A figura 6 ilustra esses diferentes padrões.


Figura 5 - Correlação entre IQPP e ICG²²



Fonte: elaboração dos autores

22 Rotina: *Graphs--> legacy dialogs--> scatter/dot.*

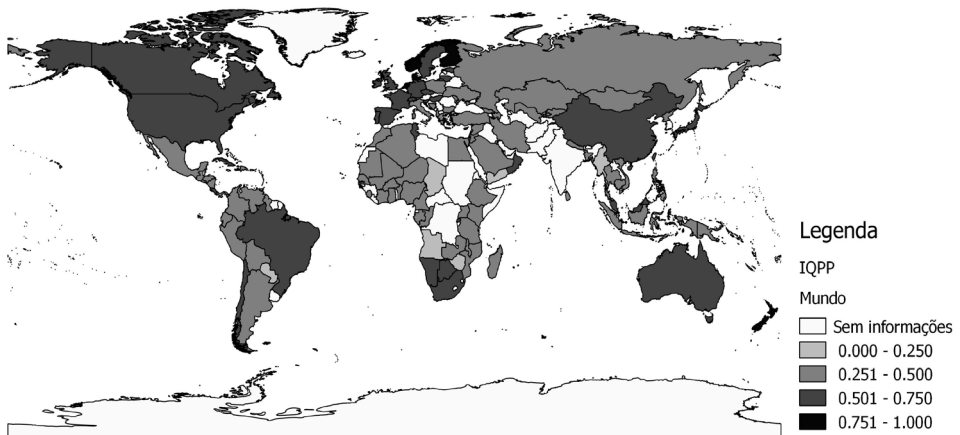
Figura 6 - Correlação entre IQPP e ICG por *cluster*



Fonte: elaboração dos autores

O gráfico mostra a importância de levar em consideração a estrutura clogomerada dos dados. O padrão de correlação é diferente entre os três níveis de qualidade das políticas públicas, de forma que é provável que inferências equivocadas sejam realizadas quando esse tipo de análise não é feita.

Figura 7. Distribuição do IQPP no mundo²³



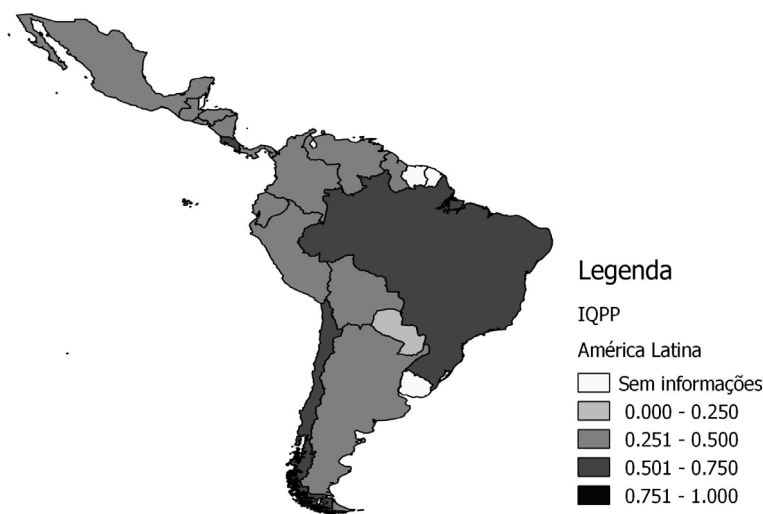
Fonte: Elaboração dos autores.

²³ Os scores do IQPP foram normalizados para que variem entre 0 e 1.

Para finalizar a descrição do IQPP apresentamos um mapa classificando os países do mundo dentro das escalas do índice. De acordo com o mapa, quanto mais escura for a cor do país, maior será seu *score* de IQPP. Essas informações são apresentadas na figura 7.

Os países que possuem os maiores scores do IQPP são Singapura, Finlândia e Dinamarca. No lado oposto estão Chad, República Democrática do Congo e o Haiti. A figura 8 apresenta as mesmas informações para os países da América Latina.

Figura 8 - Distribuição do IQPP na América Latina



Fonte: Elaboração dos autores.

Os países com os mais elevados *scores* do IQPP na América Latina foram Chile, Costa Rica e Cuba. Enquanto que os piores foram Haiti, Paraguai e Venezuela. Em anexo pode ser encontrado um *rank* do IQPP com a posição de todos os países que possuímos informação.

5 - CONSIDERAÇÕES FINAIS

O principal objetivo desse artigo foi demonstrar como as técnicas de análise fatorial e análise de *cluster* podem ser combinadas em um mesmo desenho de pesquisa. Metodologicamente, replicamos os dados do *Inter American Development Bank*, utilizando seis indicadores de qualidade das políticas públicas. Com base

nesses dados construímos um indicador original e replicável de qualidade das políticas (IQPP) com o uso da análise fatorial e agrupamos os países de acordo com o nível da qualidade de suas políticas via análise de *cluster*. Com esse artigo esperamos contribuir para o estudo sistemático da análise da qualidade das políticas públicas e difundir a utilização da análise fatorial e da análise de *cluster* na pesquisa empírica em Ciência Política e Políticas Públicas.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALDENDERFER, M. S. e BLASHFIELD, R. K. 1984. Cluster Analysis. *Sage University Paper Series: Quantitative Applications in the Social Science*.
- BARTHOLOMEW, D. J. 1984. The foundations of factor analysis. *Biometrika*, 71, 221-232.
- BAILEY, K. D. 1975. Cluster Analysis. *Sociological Methodology*, vol. 6, p. 59-128.
- BOWERS, J. 2011. *Reproduction Compendium for: "Making Effects Manifest in Randomized Experiments"*. <http://hdl.handle.net/1902.1/15499>
- CHUAIRE, M. F., e SCARTASCINI, C. 2014. *The Politics of Policies: Revisiting the Quality of Public Policies and Government Capabilities in Latin America and the Caribbean*. Policy Brief IDB-PB-220. Washington, DC, United States. Inter-American Development Bank.
- COOPER, J. C.B. 1983. Factor Analysis: An Overview. *The American Statistician*, 37, 2, 141- 147.
- COPPEDGE, M.; ALVAREZ, A.; MALDONADO, C. 2008. Two Persistent Dimensions of Democracy: Contestation and Inclusiveness. *Journal of Politics*, v. 70, n. 3, p. 145.
- COSTELLO, A. B.; OSBORNE, J. W. 2005. Best practices in exploratory factor analysis: Four recommendations for getting the most from your analysis. *Practical Assessment Research & Evaluation*, 10, 7, 13-24.
- CRAMER, D. & HOWITT, D. L. 2004. *The Sage dictionary of statistics: a practical resource for students in the social sciences*. Sage.
- DAFOE, A. 2014. Science Deserves Better: The Imperative to Share Complete Replication Files. *PS: Political Science & Politics*, 47:60-66.
- DAHL, R. 1971. *Poliarquia. Participação e oposição*. São Paulo: Editora da Universidade de São Paulo.
- DOLNICAR, S. 2002. *A review of unquestioned standards in used cluster analysis for data-driven market segmentation*. Faculty of Commerce – Papers. Disponível em: < <http://ro.uow.edu.au/commpapers/273> >.
- DRIVER, H. E.; KROEBER, A. L. 1932. *Quantitative Expressions of Cultural*
- FABRIGAR, L. R., WEGENER, D. T., MACCALLUM, R. C., & STRAHAN, E. J. 1999. Evaluating the use of exploratory factor analysis in psychological research. *Psychological Methods*, 4(3), 272-299.
- FIGUEIREDO FILHO, D. B.; SILVA JÚNIOR, J. A. da. 2010. Visão além do alcance: uma introdução à análise fatorial. *Opinião Pública*, v. 16, n. 1, p. 160-185.
- FIGUEIREDO FILHO, D. B. ; SILVA JÚNIOR, José Alexandre ; ROCHA, E. C. 2011. What is R² all about?. *Leviathan - Cadernos de Pesquisa Política*, v. 3, p. 60-68.

- FIGUEIREDO FILHO, D. B.; PARANHOS, R.; ROCHA, E. C. da; SILVA JUNIOR, J. A.; MAIA, R. 2013. Análise de componentes principais para construção de indicadores sociais. *Revista Brasileira de Biometria*, v. 31, p. 61-78.
- FIGUEIREDO FILHO, D. B.; ROCHA, E. C.; SILVA, M. B.; PARANHOS, R.; SILVA JÚNIOR, J. A.; DUARTE, B. S. F. 2014. Cluster analysis for Political Scientists. *Applied Mathematics*, v. 5, p. 2408-2415.
- GREENACRE, M. J. 2007. *Correspondence Analysis in Practice*. Chapman & Hall/CRC, Boca Raton, second edition.
- HAIR, J. F. et al. 2009. *Análise Multivariada de Dados*. 6. Ed. Porto Alegre: Bookman.
- KING, G. 1995. "Replication, Replication." *PS: Political Science and Politics*, 28: 443-499. Disponível: <http://gking.harvard.edu/gking/files/replication.pdf>
- KING, G. 2003. "The Future of Replication." *International Studies Perspectives* 4: 443-499. Disponível: <http://gking.harvard.edu/gking/files/replvdc.pdf>
- KIM, J.; MUELLER, C. W. 1978. *Factor analysis: Statistical methods and practical issues*. Beverly Hills, CA. Sage.
- KUBRUSLY, L. S. 2001. Um Procedimento para Calcular Índices a partir de uma Base de Dados Multivariados. *Pesquisa Operacional*, 21(1): 107-117.
- JANZ, N. 2015. Bringing the Gold Standard Into the Class Room: Replication in University Teaching. *International Studies Perspectives*, Article first published online: 9 MAR 2015. DOI: 10.1111/insp.12104.
- LIJPHART, A. 1999. *Modelos de Democracia: Desempenho e Padrões de Governo em 36 Países*. Rio de Janeiro. Civilização Brasileira, 3 ed.
- LUPIA, A. 2014. What Is the Value of Social Science? Challenges for Researchers and Government Funders. *PS: Political Science and Politics*, 47 (1): this issue.
- MACRAE, D. Jr. 1966. Cluster Analysis of Congressional Votes with the BC TRY System. *The Western Political Quarterly*, v. 19, n. 4, p. 631-638.
- PREACHER, K. J., RUCKER, D. D., & HAYES, A. F. 2007. Addressing moderated mediation hypotheses: Theory, methods, and prescriptions. *Multivariate Behavioral Research*, 42, 185-227.
- RUMMEL, R. J. 1967. Understanding Factor Analysis. *The Journal of Conflict Resolution*, 11, 4, 444-480.
- RUMMEL, R. J. 1970. *Applied Factor Analysis*. Evanston. Northwestern University Press.
- SCHWAB, J. 2007. *Eletronic Classroom*. [Online] Disponível em: <<http://www.utexas.edu/ssw/eclassroom/schwab.html>> Acesso em: 22dez. 2015.
- TABACHNICK, B. e FIDELL, L. (2007). *Using Multivariate Statistics*. 5ed., Boston: Allyn e Bacon.
- TRYON, R. 1939. *Cluster Analysis*. New York: McGraw-Hill.

ZELLER, R. A. and CARMINES, E. G. 1980. *Measurement in the social sciences: the link between theory and data*. Cambridge, Cambridge University Press.

ZUBIN, J. A. 1938. A technique for measuring likemindedness. *Journal of Abnormal and Social Psychology*, 33, p.508-516.

ANEXOS

Tabela 7 - Índice da Qualidade de Políticas Públicas (IQPP)

Ranking	País	Score	Ranking	País	Score
1	Singapore	2,388	60	Bulgaria	-0,247
2	Finland	2,212	61	Indonesia	-0,248
3	Denmark	2,205	62	Benin	-0,252
4	New Zealand	1,934	63	Peru	-0,277
5	Netherlands	1,923	64	Panama	-0,312
6	Norway	1,907	65	Morocco	-0,351
7	Switzerland	1,848	66	Zambia	-0,358
8	United Kingdom	1,797	67	Dominican Re- public	-0,371
9	Sweden	1,738	68	Guyana	-0,402
10	Canada	1,683	69	Burkina Faso	-0,405
11	Germany	1,610	70	Kyrgyz Republic	-0,423
12	Australia	1,591	71	Egypt, Arab Rep.	-0,430
13	Hong Kong, Ch	1,519	72	Mongolia	-0,476
14	Chile	1,453	73	Moldova	-0,490
15	Ireland	1,415	74	Georgia	-0,492
16	United States	1,390	75	B. and Herzegovina	-0,495
17	Spain	1,325	76	Ethiopia	-0,496
18	Slovenia	1,214	77	Iran, Islamic Rep.	-0,510
19	Cyprus	1,195	78	Gabon	-0,519
20	Japan	1,193	79	Mauritania	-0,536
21	France	1,158	80	Mali	-0,581
22	Oman	1,149	81	Kenya	-0,584
23	Taiwan	1,023	82	Madagascar	-0,589
24	Israel	1,023	83	Philippines	-0,618
25	Botswana	1,000	84	Argentina	-0,625
26	Estonia	0,991	85	Syrian Arab Re- public	-0,627
27	Tunisia	0,771	86	Albania	-0,645
28	Malaysia	0,667	87	Azerbaijan	-0,690
29	Portugal	0,638	88	Ukraine	-0,705

30	Bahrain	0,616	89	Congo, Rep.	-0,776
31	Hungary	0,582	90	Malawi	-0,787
32	South Africa	0,574	91	Uzbekistan	-0,807
33	Costa Rica	0,554	92	Bolivia	-0,843
34	Namibia	0,551	93	Russian Federation	-0,859
35	Cuba	0,461	94	Cameroon	-0,873
36	Rwanda	0,454	95	Papua New Guinea	-0,879
37	Lithuania	0,410	96	Cambodia	-0,894
38	China	0,394	97	Algeria	-0,896
39	Czech Republic	0,385	98	Nicaragua	-0,914
40	Brazil	0,320	99	Bangladesh	-0,983
41	Poland	0,291	100	Nepal	-0,989
42	Greece	0,274	101	Ecuador	-1,004
43	Thailand	0,219	102	Honduras	-1,005
44	Jordan	0,191	103	Niger	-1,007
45	Saudi Arabia	0,186	104	Sierra Leone	-1,023
46	Kuwait	0,117	105	Korea, Dem. Rep.	-1,051
47	Italy	0,104	106	Lebanon	-1,123
48	Ghana	0,023	107	Guatemala	-1,156
49	Mexico	0,003	108	Côte d'Ivoire	-1,190
50	Uganda	-0,019	109	Nigeria	-1,205
51	Turkey	-0,034	110	Venezuela	-1,208
52	Mozambique	-0,049	111	Angola	-1,275
53	Vietnam	-0,084	112	Paraguay	-1,276
54	Colombia	-0,159	113	Yemen, Rep.	-1,355
55	Tanzania	-0,172	114	Myanmar	-1,523
56	Kazakhstan	-0,178	115	Zimbabwe	-1,578
57	El Salvador	-0,189	116	Haiti	-1,639
58	Sri Lanka	-0,212	117	Congo, Dem. Rep.	-1,709
59	Senegal	-0,218	118	Chad	-1,774