

Classificando regimes políticos utilizando análise de conglomerados

Dalson Britto Figueiredo Filho
José Alexandre da Silva Júnior
Enivaldo Carvalho da Rocha

Departamento de Ciência Política
Universidade Federal de Pernambuco

Resumo: O principal objetivo desse artigo é apresentar uma introdução intuitiva à técnica de análise de conglomerados. Metodologicamente, utilizamos os dados de Coppedge, Alvarez e Maldonado (2008) sobre as duas dimensões da poliarquia propostas por Dahl (1971): contestação e inclusividade. A partir dessas dimensões os regimes políticos são classificados em diferentes grupos (*clusters*) de acordo com o grau de similaridade entre eles. Em termos substantivos, esperamos indicar uma ferramenta metodológica para classificação dos regimes políticos e facilitar a compreensão da técnica de análise de conglomerados na Ciência Política.

Palavras-chave: regimes políticos; análise de *cluster*; *Q analysis*; classificação; métodos quantitativos

Abstract: The principal aim of this paper is to provide a intuitive introduction to cluster analysis. Methodologically, we use data from Coppedge, Alvarez e Maldonado (2008) regarding the two dimensions of polyarchy proposed by Dahl (1971): contestation and inclusiveness. Based on these dimensions we classify political regimes in different groups (*clusters*) according to their similarity level. On substantive grounds, we hope to suggest a methodological tool to classify political regimes and facilitate the understanding of cluster analysis in Political Science.

Keywords: political regimes; cluster analysis; *Q analysis*; classification; quantitative methods

“Classification of objects into meaningful sets – clustering – is an important procedure in all of the social sciences”

Richard G. Niemi

“Crude classifications and false generalizations are the curse of the organized life”

H. G. Wells

Introdução¹

Como classificar casos de forma sistemática? Como criar tipologias e taxonomias de forma objetiva? Partindo do pressuposto de que a classificação é um componente central do conhecimento científico, o principal objetivo deste artigo é apresentar a lógica da análise conglomerados (*clusters*) na classificação dos regimes políticos². Em termos metodológicos, utilizamos o banco de dados elaborado por Coppedge, Alvarez e Maldonado (2008) com diferentes indicadores de democracia. Essas medidas são reduzidas a duas dimensões latentes: contestação e inclusividade, seguindo a definição de Dahl (1971). A partir dessas dimensões, os regimes políticos são classificados em diferentes grupos (*clusters*) de acordo com o grau de similaridade entre eles.

Uma motivação central que orienta este artigo é a tímida utilização dessa técnica nas Ciências Sociais brasileira³. Acreditamos que esse fenômeno pode ser parcialmente explicado pela resistência dos cientistas sociais brasileiros aos métodos quantitativos (SOARES, 2005; WERNECK VIANNA et al, 1998; VALLE e SILVA, 1999 e SANTOS e COUTINHO, 2000). Um impedimento adicional refere-se à complexidade matemática envolvida na operacionalização das diferentes técnicas de análise de conglomerados (ALDENDERFER E BLASHFIELD, 1984; BAILEY, 1975). Paraphrasing Mooney (1996), acreditamos que os benefícios associados à utilização da análise de agrupamentos ainda não são evidentes do ponto de vista conceitual. Por exemplo, Aldenderfer e Blashfield afirmam que “apesar de sua popularidade, os métodos de agrupamento ainda são vagamente compreendidos quando comparados com outras técnicas multivariadas como análise fatorial, análise discriminante e escalonamento multidimensional” (ALDENDERFER e BLASHFIELD, 1984, p. 9). Dessa forma, enquanto não ficarem claras as suas potencialidades, é improvável que esse repertório de técnicas seja incorporado ao cotidiano dos pesquisadores brasileiros. Por isso, nosso foco refere-se mais ao *modus operandi* da técnica e menos à interpretação substantiva dos resultados.

Mas o que é análise de conglomerados (*cluster*)? Ainda de acordo com Aldenderfer e Blashfield, “Análise de *Cluster* é uma denominação genérica para um grande grupo de técnicas que podem ser utilizadas para criar uma classificação. Esses procedimentos formam empiricamente *clusters* ou grupos

¹ Agradecemos aos comentários de Natália Leitão a versões anteriores e ao professor Michael Coppedge por gentilmente disponibilizar o seu banco de dados. Eventuais imprecisões são exclusivamente creditadas aos autores. Nosso trabalho é financiado por duas principais fontes: CAPES e CNPQ.

² Para Pohlmann, “a análise de conglomerados tem sido referida como análise de *clusters*, *Q analysis*, *typology*, *classification analysis* e *numerical taxonomy*” (POHLMANN, 2007, p. 325). Neste artigo, por fins meramente estilísticos, utilizamos os termos análise de conglomerados, análise de *cluster* e análise de agrupamentos como sinônimos.

³ Revisamos todos os números de quatro importantes periódicos da área (*DADOS, Revista Brasileira de Ciências Sociais, Revista de Sociologia e Política e Opinião Pública*) e, salvo melhor sistematização, não encontramos um único artigo que tenha utilizado alguma técnica de análise de conglomerados. Curi (2003) agrupa países de acordo com o padrão de vida. Lima et al (2005) utilizam a análise de *cluster* para identificar conglomerados de violência no estado de Pernambuco. No entanto, em ambos os casos, os artigos foram publicados em periódicos de Saúde Pública.

de objetos fortemente similares” (ALDENDERFER e BLASHFIELD, 1984, p.7). Para Hair et al, a “análise de conglomerados agrupa indivíduos ou objetos em *clusters* de modo que objetos em um mesmo *cluster* são mais parecidos entre si do que em relação a outros *clusters*” (HAIR et al, 2006, p. 555). É nesse sentido que o principal objetivo da análise de conglomerados é agrupar casos a partir de determinadas características que os tornam similares⁴. Para tanto, a análise de conglomerados procura não só minimizar a variância dentro do grupo (*within group variance*), mas também maximizar a variância entre os grupos (*between group variance*)⁵.

Para tratar dessas questões, este artigo está dividido em cinco partes. A próxima seção revisa brevemente parte da literatura sobre a análise de conglomerados. O objetivo é fornecer ao leitor um ponto de partida para aprofundar seus conhecimentos sobre essa técnica. A segunda apresenta o planejamento, passo a passo, da análise de *cluster*. A meta é familiarizar o leitor com a terminologia utilizada bem como sistematizar os estágios que devem ser seguidos. A terceira seção oferece um exemplo de desenho de pesquisa utilizando a análise de conglomerados. Depois disso, apresentamos as principais estatísticas de interesse e sua respectiva interpretação. Por fim, a quinta parte apresenta as conclusões do artigo.

Breve revisão da literatura⁶

De acordo com Bailey (1975), a análise de *cluster* tem sua origem na psicologia a partir dos trabalhos pioneiros de Zubin (1933) e Tryon (1939) e na antropologia a partir do artigo “*Quantitative expressions of cultural relationships*” de Driver e Kroeber (1932)⁷. Para Aldenderfer e Blashfield (1984), uma importante contribuição ao desenvolvimento das técnicas de *clustering* (agrupamento) foi feita a partir do livro “*Principles of Numerical Taxonomy*” de Sokal e Sneath (1963). Em Economia, Fisher (1969), na Geografia, Berry e Ray (1966) e em Ciência Política, Kaiser (1966) foram pioneiros na aplicação da técnica em suas respectivas áreas de interesse (BAILEY, 1975). No entanto, tanto Aldenderfer e Blashfield quanto Bailey destacam que, durante muito tempo, as diferentes técnicas de análise de *cluster* ficaram restritas a um grupo mais reduzido de pesquisadores devido a sua complexidade matemática.

⁴ Uma forma bastante intuitiva de compreender a lógica da análise de conglomerados é imaginar a organização de um supermercado. Em geral, itens semelhantes são agrupados em um mesmo setor: cerveja, vinho e refrigerantes se agrupam no setor de bebidas. Banana, maçã e laranja se agrupam no setor de hortifrutigranjeiro, etc.

⁵ Variância é um conceito central em Estatística e em análise multivariada de dados. Algebricamente: $\sigma^2 = \frac{1}{N} \sum_{i=0}^n (Y_i - \mu)$ Onde, μ representa a média e N representa o tamanho da população. Para calcular a variância da amostra a fórmula é a seguinte: $S^2 = \frac{1}{1-N} \sum_{i=1}^n (x_i - \bar{x})^2$

Onde, \bar{x} representa a média da variável na amostra e n representa o tamanho da amostra. Na análise de conglomerados, busca-se garantir que tanto a homogeneidade dentro dos grupos (*clusters*) quanto a heterogeneidade entre os grupos sejam maximizadas.

⁶ Para os propósitos deste artigo, o grau de complexidade matemática foi minimizado. Para os leitores interessados em aprofundar seus conhecimentos, sugerimos consultar a bibliografia citada: para trabalhos clássicos utilizando a análise de *cluster*, Zubin (1938), Tryon (1939), Driver e Kroeber (1932) e Sokal e Sneath (1963). 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). Para uma tipologia de famílias de rua utilizando a referida técnica, ver Danseco e Holden (1998). Para uma aplicação em demografia, ver Peters (1958). Para um exame de atitudes políticas utilizando análise de *cluster*, ver Fleishman (1986). Goldstein e Linden (1969) empregam análise de conglomerados para classificar 513 alcoólatras em quatro diferentes grupos. Para um estudo sobre mercado de trabalho, ver Vanneman (1977). Burton e Romney (1975) analisaram o papel de diferentes termos linguísticos a partir da referida técnica. Filsinger, Faulkner e Warland (1979) utilizaram análise de *cluster* para classificar indivíduos a partir da variável religião.

⁷ Os interessados podem acessar o referido trabalho a partir do seguinte endereço eletrônico: <<http://digitalassets.lib.berkeley.edu/anthpubs/ucb/text/ucp031-005.pdf>>. Outros textos importantes foram produzidos por Czekanowski (1911), Driver (1965) e Johnson (1967).


Esses autores argumentam que o avanço computacional é um elemento central para explicar a propagação da técnica entre os diferentes ramos do conhecimento. Atualmente, os algoritmos matemáticos e os cálculos de distância entre os casos são realizados quase instantaneamente pela maior parte dos pacotes estatísticos, isso facilita a utilização da análise de conglomerados por pesquisadores que não dominam as complexidades matemáticas, mas compreendem a lógica intuitiva da técnica.

Mas para que serve a análise de *cluster* afinal? Hair et al (2006) afirmam que a “Análise de *Cluster* é um grupo de técnicas multivariadas cujo principal objetivo é agrupar objetos a partir de suas características” (HAIR et al, 2006, p. 559). De acordo com Garson (2010), a “Análise de *Cluster* (...) procura identificar subgrupos homogêneos de casos na população, quer dizer, a análise de *Cluster* é utilizada quando o pesquisador não sabe *a priori* o número de grupos, mas deseja identificá-los e analisar níveis de pertencimento” (GARSON, 2010).

Para Aldenderfer e Blashfield (1984), “o principal motivo para utilizar análise de conglomerados é encontrar grupos de objetos similares em uma amostra de dados. Esses grupos são convenientemente chamados de *clusters*” (ALDENDERFER e BLASHFIELD, 1984, p. 33). Em síntese, fica claro que o principal objetivo da referida técnica é agrupar casos de acordo com o grau de semelhança observado entre eles. Hair et al (2006) afirmam que a lógica subjacente à análise de *cluster* é semelhante à lógica da análise fatorial. A diferença básica é que, na análise fatorial, o pesquisador está interessado em representar um conjunto de variáveis observadas a partir de um número menor de fatores enquanto na análise de conglomerados o pesquisador procura representar um conjunto de casos a partir de um número menor de grupos (*clusters*). Em uma frase: na análise fatorial, agrupam-se variáveis, na análise de conglomerados, agrupam-se casos⁸. A Figura 1 ilustra um tipo ideal de análise de conglomerados.

⁸ É importante lembrar que alguns pacotes estatísticos apresentam a opção de utilizar a análise de conglomerados para agrupar variáveis, é o caso, por exemplo, do *Statistical Package for Social Sciences* (SPSS).

Figura 1
Exemplo da análise de conglomerados



Fonte: elaboração dos autores a partir de Hair et al (2005).

Os casos são agrupados de acordo com o grau de proximidade recíproca, é o que a literatura denomina de distância/similaridade. Existem diferentes formas de estimar quão distantes/próximas são as observações⁹. Em geral, procura-se garantir o máximo de homogeneidade dentro do *cluster* ao mesmo tempo em que se maximiza a heterogeneidade entre os grupos. Como é impossível maximizar duas variáveis ao mesmo tempo, espera-se encontrar uma solução que otimize essa relação. Para tanto, é importante entender o conceito de *variate*. Para Hair et al, “A *variate* do conglomerado é um grupo de variáveis que representam as características utilizadas para comparar os objetos na análise de *cluster*” (HAIR et al, 2006, p. 559). É exatamente a partir da *variate* que os casos são classificados, formando os diferentes grupos (*clusters*)¹⁰. A próxima seção ilustra o planejamento de uma análise de conglomerados.

Planejamento de uma análise de conglomerados¹¹

Que requisitos precisam ser satisfeitos para utilizar a técnica de análise de *cluster* em um determinado desenho de pesquisa (HAIR et al, 2006). O objetivo desta seção é sumarizar essas informações. A Tabela 1 sintetiza o planejamento de uma análise de conglomerados em cinco estágios.

Tabela 1
Planejamento de uma análise de conglomerados em cinco estágios

Estágio	Procedimento
1º	Selecionar a amostra
2º	Determinar as variáveis
3º	Definir a medida de similaridade e decidir o método (algoritmo) de aglomeração
4º	Delimitar o número de grupos (<i>clusters</i>)
5º	Validar o resultado

Fonte: elaboração dos autores a partir de Aldenderfer e Blashfield (1984)

⁹ Aldenderfer e Blashfield (1984), Garson (2010) e Hair et al (2006) discutem diferentes métodos para estimar a distância/similaridade entre os casos. Para os propósitos deste artigo, optamos por não reproduzir integralmente o debate, nos limitando aos aspectos mais básicos da técnica.

¹⁰ Uma forma mais intuitiva para pensar o conceito de *variate* é imaginar uma medida síntese que seja utilizada para calcular o nível de similaridade entre os casos analisados. Neste artigo, evitamos utilizar o termo *variate*, optando pelo termo variável. Agradecemos ao parecerista por essa sugestão.

¹¹ Aldenderfer e Blashfield alertam para quatro precauções que os pesquisadores devem atentar antes de utilizar a análise de conglomerados em seus desenhos de pesquisa. Em primeiro lugar, os autores afirmam que “a maior parte dos métodos de análise de conglomerados são procedimentos relativamente simples que, em geral, não necessitam de extenso suporte estatístico” (ALDENDERFER e BLASHFIELD, 1984, p.14). Em segundo lugar, os autores afirmam que a análise de conglomerados está intimamente ligada ao desenvolvimento metodológico de diferentes disciplinas, carregando, dessa forma, os avanços e os vieses de diferentes ramos do conhecimento. Por exemplo, o que é importante em Psicologia pode ser dispensável em Ciência Política e vice-versa. Nesse sentido, cabe ao pesquisador não só garantir que os procedimentos técnicos sejam devidamente seguidos, mas, principalmente, conferir interpretação substantiva aos resultados encontrados. Em terceiro lugar, Aldenderfer e Blashfield afirmam que “diferentes métodos de agrupamento podem e, em geral, produzem diferentes soluções para o mesmo conjunto de dados” (ALDENDERFER e BLASHFIELD, 1984, p.15). É importante que o pesquisador esteja atento a este fato na hora de replicar testes de outros pesquisadores e, sempre que possível, procure validar os resultados encontrados. Por fim, os autores destacam que “enquanto a estratégia da análise de *cluster* é *structure-seeking*, sua operacionalização é *structure-imposing*” (ALDENDERFER e BLASHFIELD, 1984, p.16), i.e., grupos (conglomerados) sempre serão criados, já que a análise parte do pressuposto de que existe uma estrutura inerente aos dados que não pode ser observada visualmente.

O primeiro passo é definir a amostra. Para Hair et al (2006), o tamanho da amostra na análise de *cluster* não se relaciona com questões de inferência estatística como em análise de regressão, por exemplo. Ou seja, não se procura estimar em que medida os resultados encontrados na amostra podem ser estendidos à população. Na verdade, o tamanho da amostra deve garantir que os pequenos grupos da população sejam devidamente representados. Além disso, diferente de outras técnicas multivariadas, não existe uma regra geral para especificar o tamanho mínimo da amostra¹² (DOLNICAR, 2002). Nossa recomendação é que ao se elevar a quantidade de variáveis incluídas na análise deve-se aumentar também o número de casos. Um procedimento importante que deve ser empregado ainda no primeiro estágio é a identificação de *outliers*. Isso porque a análise de conglomerados é sensível à presença de observações muito destoantes. Hair et al (2006) sugerem a inspeção gráfica do diagrama de perfil (*profile diagram*). O pesquisador também pode utilizar o *blox-plot* e gráficos de dispersão para identificar *outliers*, além dos testes-padrão disponíveis nos diferentes pacotes estatísticos. Pohlmann sugere “calcular o escore padronizado Z e considerar como *outliers* as observações cujos escores, em valores absolutos, sejam maiores do que três” (POHLMANN, 2007, p. 333)¹³.

Depois de selecionar a amostra (1º estágio), o pesquisador deve decidir que variáveis serão utilizadas para estimar a distância/similaridade entre os casos (2º estágio). Como a análise de *cluster* não diferencia entre variáveis relevantes e irrelevantes, é necessário que essa inclusão seja teoricamente orientada. Hair et al afirmam que devem ser incluídas apenas as variáveis que caracterizem os objetos que serão agrupados e se relacionem especificamente aos objetivos da análise de *cluster* (HAIR et al, 2006, p. 570). Para Aldenderfer e Blashfield, “a escolha das variáveis que serão utilizadas na análise de conglomerados é um dos passos mais importantes do processo de pesquisa, mas, infelizmente, um dos menos compreendidos” (ALDENDERFER e BLASHFIELD, 1984, p.19). Idealmente, o desenho de pesquisa deve selecionar apenas variáveis teoricamente relevantes para proceder à classificação dos casos. Os autores advertem que, caso contrário, existe um sério risco de o pesquisador enveredar por um empirismo ingênuo, produzindo resultados conceitualmente vazios e que não contribuem para o avanço do conhecimento. No que diz respeito ao nível de mensuração, Hair et al (2006) destacam as medidas correlacionais e as medidas de distância. As correlacionais permitem trabalhar com variáveis categóricas, já as de distância exigem variáveis métricas¹⁴. Outro ponto importante diz respeito à padronização das variáveis incluídas na análise de *cluster*. Alguns especialistas recomendam que variáveis medidas em diferentes escalas devem ser padronizadas (média zero e variância igual a um) para que a comparação entre elas seja inteligível. O problema da ponderação (criar pesos) também divide a opinião dos pesquisadores¹⁵.

¹² Formann (1984) sugere que o número de casos (n) deve ser igual a $5 \cdot 2^k$, onde k representa o número de variáveis. Logo, se o pesquisador utilizar três variáveis, ele deve contar com, no mínimo, $(5 \cdot 2^3) = 40$ casos.

¹³ Para padronizar uma variável, deve-se subtrair o seu valor pela média e dividir o resultado pelo desvio-padrão. Algebricamente,
$$Z = \frac{x_i - \mu}{\sigma}$$

Onde x_i representa o valor da observação, μ representa a média da população e σ representa o desvio-padrão.

¹⁴ Aldenderfer e Blashfield (1984) argumentam que a mais importante discussão a respeito das diferentes medidas de distância/similaridade pode ser encontrada no trabalho de Sneath e Sokal (1973).

¹⁵ Para o leitor interessado em um debate inicial sobre esses temas, ver Aldenderfer e Blashfield (1984). Para uma discussão mais aprofundada, ver Everitt (1980).

Depois de selecionar as variáveis utilizadas para estimar a similaridade entre os casos (2º estágio), o pesquisador deve definir a medida de similaridade utilizada (3º estágio). Pohlmann afirma que “a similaridade entre objetos (*interobject similarity*) é uma medida de correspondência, ou semelhança, entre os objetos a serem agrupados” (POHLMANN, 2007, p.333). Existem diferentes maneiras de calcular essas medidas e diferentes medidas tendem a produzir soluções distintas. Para Pohlmann, “existe frequentemente um grande grau de subjetividade envolvido na escolha da medida de similaridade. Importantes considerações incluem a natureza das variáveis (discretas, contínuas, binárias), escalas de medida (nominal, ordinal, intervalar, proporcional) e o conhecimento da matéria objeto da pesquisa” (POHLMANN, 2007, p.333-334). Recomendamos que pesquisadores iniciantes utilizem as medidas de similaridade mais convencionais, incorporando diferentes medidas ao longo do seu processo de aprendizado.

Uma vez calculada a similaridade, o próximo passo é decidir o método (algoritmo matemático) de aglomeração. Ou seja, o pesquisador deve definir como as distâncias serão calculadas e quantos conglomerados (grupos) devem ser criados¹⁶. O *Statistical Package for Social Sciences*, versão 16, fornece três abordagens gerais para criar os conglomerados: a) *Hierarchical clustering* (agrupamento hierárquico); b) *K-means clustering* e c) *Two-step clustering*¹⁷. A abordagem *Hierarchical clustering* (HCA) é mais apropriada para amostras pequenas - em geral, $N < 250$ (GARSON, 2010). Na medida em que o tamanho da amostra cresce, a solução do algoritmo tende a ficar mais lenta, podendo, inclusive, travar o computador. Na HCA, os *clusters* são aninhados, ou seja, não são mutuamente exclusivos. O pesquisador pode escolher a amplitude do número de *clusters* ou a quantidade exata de grupos que devem ser criados a partir dos casos observados.

A opção *K-means clustering* é mais indicada para amostras maiores ($N > 1.000$) já que ela não computa a matriz de proximidade de distâncias/similaridade entre todos os casos observados. Como medida de similaridade, a abordagem *K-means clustering* utiliza a distância Euclidiana¹⁸ e o pesquisador deve especificar antecipadamente o número de grupos (conglomerados) que serão formados (GARSON, 2010).

A abordagem *Two-step clustering* é considerada ideal para grandes bases de dados, já que tanto o agrupamento hierárquico quanto a *K-means clustering* podem apresentar problemas de escalonamento quando a amostra é demasiadamente grande. Além disso, a saída do *output* apresenta mais opções, inclusive um gráfico que compara a importância de cada variável na formação dos conglomerados.

Depois de escolher a medida de similaridade e o método (algoritmo matemático) de aglomeração (3º estágio), o pesquisador deve identificar o número de grupos (K) que serão formados (4º

¹⁶ A versão 16 do SPSS contempla as seguintes medidas de similaridade para variáveis métricas: *euclidian distances*, *squared euclidian distances*, *Cosine*, *Pearson correlation*, *Chebychev*, *Block*, *Minkowski* e *Customized*. Como métodos de aglomeração o referido *software* dispõe do seguinte: *between groups-linkage*, *within groups-linkage*, *Nearest neighbor*, *Furthest neighbor*, *Centroid clustering*, *Median clustering* e *Ward's method*. Para uma discussão sobre cada um deles, ver Garson (2010).

¹⁷ Para as diferenças entre as três abordagens, ver Garson (2010).

¹⁸ Algebricamente, $d_{ij} = \sqrt{\sum_{k=1}^p (x_{ik} - x_{jk})^2}$

Onde d_{ij} representa a distância entre os casos i e j ; x_{ik} é o valor da K -ésima variável para o i -ésimo caso. Para evitar a utilização da raiz quadrada, é possível elevar o valor da distância ao quadrado (d_{ij}^2) produzindo, dessa forma, a distância Euclidiana ao quadrado (*squared Euclidian distance*).

estágio). Nesse momento, ele deverá utilizar a teoria para orientar a sua escolha. Por exemplo, se trabalhos anteriores sugerem a existência de três grupos, uma possibilidade analítica é replicar o número de grupos com o objetivo de verificar em que medida a solução encontrada é mais ou menos robusta. Na ausência de teoria sobre o assunto, o pesquisador pode adotar uma perspectiva exploratória e repetir a análise variando o número de grupos (K). As diferentes soluções devem ser comparadas à luz da literatura especializada sobre o tema em busca de uma explicação substantiva.

Por fim, no 5º estágio, o pesquisador deve validar os resultados encontrados. Hair et al alertam que “o pesquisador deve ter muito cuidado na validação e na garantia de significância prática da solução final” (HAIR et al, 2005, p.405). A validação consiste em garantir que a solução encontrada seja representativa da população, descrevendo um padrão relativamente estável para outras amostras. Um procedimento para executar a validação consiste no particionamento (divisão) da amostra original em outras separadas e comparar as soluções obtidas em ambos os casos, verificando a correspondência dos resultados (HAIR et al, 2005). Outro caminho é testar a capacidade preditiva da solução gerada a partir da comparação de uma variável aleatória que não tenha sido utilizada na solução inicial de geração dos conglomerados. Por exemplo, ao separar grupos de acordo com o hábito tabagista, espera-se que, em média, a resistência física dos não fumantes seja maior do que a dos fumantes. Dessa forma, depois de separar os grupos, o pesquisador pode conduzir uma bateria de testes físicos e verificar se o grupo dos não fumantes, de fato, apresenta um rendimento superior à performance dos fumantes. Ou, ao classificar regimes políticos de acordo com o seu nível de democratização, o pesquisador pode estimar em que medida a desigualdade de renda varia entre os diferentes grupos de países, assumindo que democracias tendem a promover maior distribuição de renda do que não-democracias.

Exemplo de desenho de pesquisa: classificando regimes políticos

Retomando a questão de pesquisa: como classificar casos sistematicamente? Como criar tipologias e taxonomias de forma objetiva? Para responder a essas questões, utilizamos a análise de conglomerados para classificar regimes políticos. Em termos metodológicos, utilizamos o banco de dados elaborado por Coppedge, Alvarez e Maldonado (2008) (1º estágio), analisando as duas dimensões da poliarquia propostas por Dahl (1971): contestação e inclusividade (2º estágio)¹⁹. A amostra contempla diferentes países no período entre 1950 e 2000. Finalizado o segundo estágio, o próximo passo é definir o tipo de distância e decidir o método de aglomeração (3º estágio). Para os propósitos deste artigo, utilizamos a medida mais comum: o quadrado da distância Euclidiana. Além disso, como a amostra é relativamente pequena e todas as variáveis são contínuas, optamos por utilizar as abordagens *Hierarchical clustering* e *K-means clustering*. Depois disso, essas dimensões (contestação e inclusividade)

¹⁹ Coppedge, Alvarez e Maldonado (2008) utilizam um modelo de análise fatorial para reduzir diferentes indicadores de democracia nas duas dimensões da poliarquia propostas por Dahl (1971), contestação e inclusividade. Essas dimensões são utilizadas no presente artigo como as variáveis de referência para classificar os regimes políticos em diferentes conglomerados. Aldenderfer e Blashfield (1984), Hair et al (2006) e Garson (2010) advertem que a análise de conglomerados pode não ser eficientemente realizada quando as variáveis utilizadas são fatores ou componentes extraídos via análise fatorial. Essa preocupação se justifica por que, em muitas soluções, os fatores extraídos carregam pouca variância ($S^2 < 60\%$), o que, de fato, pode prejudicar o poder aglomerativo das variáveis. A solução fatorial encontrada no presente banco de dados explica mais de 75% da variância total das variáveis observadas, o que assegura um maior nível de capacidade de as dimensões latentes (contestação e inclusividade) agruparem os casos observados em diferentes *clusters*.

foram utilizadas para classificar os regimes políticos (4º estágio). Por fim, utilizamos a validação por amostras particionadas, além disso, comparamos nossa classificação, produzida via análise de conglomerados, com a classificação proposta por Mainwaring, Brinks e Pérez-Liñán (2001) (5º estágio).

Resultados²⁰

Os dados mais recentes disponíveis no banco referem-se ao ano de 2000. Optamos por trabalhar com essas informações, totalizando 192 observações²¹. Por motivos pedagógicos, selecionamos uma amostra aleatória de 20%, já que os resultados computacionais, produzidos utilizando todas as observações no método de agrupamento hierárquico, dificulta a edição das informações dada a magnitude das tabelas²². Dessa forma, foram selecionados 41 casos. Do método de agrupamento hierárquico, analisamos apenas o dendograma, concedendo mais atenção às saídas produzidas pelo método de agrupamento *K-means clustering*.

O dendograma é uma síntese gráfica da análise de conglomerados e agrupa os casos em função do padrão de similaridade, dispensando a determinação prévia da quantidade de grupos²³. Os casos estão listados no eixo vertical, no caso, os países. Quanto mais casos, maior é o peso do conglomerado. O eixo horizontal ilustra a distância entre os *clusters* (grupos) quando eles são agrupados. É uma medida de diferenciação entre os grupos. Quanto maior a distância, maior é a diferença entre os casos.


²⁰ Neste artigo, todo o trabalho computacional foi efetuado a partir do *Statistical Package for Social Sciences* (SPSS), versão 16. Para solicitar a análise de *cluster* no SPSS, o pesquisador deve escolher as opções *Analyze, Classify* e, então, optar pelo método de aglomeração desejado (*Hierarchical clustering* ou *K-means clustering* ou *Two-step clustering*).

²¹ O banco de dados utilizado neste artigo está disponível no seguinte endereço eletrônico: <<http://www.nd.edu/~mcoppedg/crd/datacrd.htm>>.

²² Como procedimento padrão, o *Statistical Package for Social Sciences*, versão 16, disponibiliza duas diferentes saídas: a) *case processing summary* e b) *agglomeration schedule*. O primeiro representa a frequência dos casos analisados, bem como o número de casos *missing*. Caso o pesquisador observe que o número de casos com informações ausentes seja alto, ele deve repensar a utilização da técnica e/ou preencher as informações faltantes. A segunda saída ilustra o processo de aglomeração. Ela indica, passo a passo, os casos que foram aglomerados para formar um determinado *cluster*. O *linkage plot* fornece a mesma informação em formato gráfico.

²³ Além do dendograma, a saída computacional do método de aglomeração hierárquica fornece a matriz de proximidade, desde que requisitada na opção "estatísticas". Como ela estima a distância de cada caso em relação aos demais, quanto maior é o N, tanto mais complicada é a sua edição gráfica. Por esse motivo, nos furtamos de reportá-la aqui. O importante é observar que a matriz de proximidade resume o grau de semelhança/diferença de cada caso em relação aos demais ao mesmo tempo.


Figura 2
Dendograma



Analisando o dendograma de cima para baixo, observa-se a existência de diferentes *clusters*. O primeiro conglomerado agrupa os seguintes países: Finlândia (FIN), Nova Zelândia (NZL), Dinamarca (DNK) e Áustria (AUT). O segundo grupo é formado por 10 observações, são elas: Suíça (CHE), Estados Unidos (USA), Costa Rica (CRI), Argentina (ARG), Islândia (ISL), Reino Unido (GBR), República Dominicana (DOM), Guiana (GUY), Brasil (BRA) e Belize (BLZ). O terceiro grupo reúne 10 casos: Sri Lanka (LKA), Ucrânia (UKR), Bulgária (BGR), Kiribati (KIR), San Marino (SMR), Cabo Verde (CPV), Mônaco (COM), Barbados (BRB), Andorra (ADO) e Peru (PER). O quarto *cluster* é formado por apenas um caso: Gana (GHA). O quinto conglomerado é formado por Cuba (CUB) e Uzbequistão (UZB). O sexto agrupamento conglo mera três países: Argélia (DZA), Camarões (CMR) e Kazaquistão (KAZ). O sétimo *cluster* tem apenas um caso: Djibuti (DJI). O oitavo conglomerado é formado por dois casos, são eles, Baren (BHR) e Líbia (LBI). Por fim, o último grupo é formado por um único caso: Kuwait (KWT). Mas qual é a interpretação substantiva que o pesquisador pode extrair desses dados? Os resultados revelam que os casos que se encontram no mesmo grupo são, ao mesmo tempo, mais parecidos entre si e mais diferentes das observações que se localizaram nos demais grupos.

No entanto, é importante lembrar que a definição do número de conglomerados é um processo subjetivo. Isso porque a análise de conglomerados sempre encontrará uma solução que separa os casos em grupos, mas cabe ao pesquisador determinar o número de grupos efetivamente extraídos. Nesse sentido, reforçamos a ideia de que essa técnica deve ser utilizada com cautela em sua modalidade exploratória. É preferível que o pesquisador tenha alguma motivação teórica para agrupar seus casos em diferentes grupos. Neste artigo, estimamos como a análise de *cluster* classificaria os regimes políticos a partir das duas dimensões propostas por Dahl (1971): inclusividade e contestação. O objetivo é comparar o agrupamento realizado através da média com o agrupamento produzido via análise de *cluster*. Para colocar em prática essa opção, selecionamos o método de aglomeração *K-means clustering*. O Gráfico 1 ilustra a dispersão dos países divididos em quatro *clusters*, lembrando que as linhas pontilhadas representam as médias das respectivas variáveis.

Gráfico 1
Dispersão dos países em quatro grupos



Os valores estão padronizados de tal modo que a média é zero e a distância entre as observações é calculado em termos de desvio-padrão. O *cluster* 1 é formado por Arábia Saudita (SAL) e

Afganistão (AFG), ambos os regimes apresentam baixa inclusividade e reduzida contestação pública. A maior parte dos regimes políticos do *cluster 2* está acima da média na dimensão da inclusividade. Quanto à contestação, todos eles estão abaixo do termo médio. A exceção de Togo (TON), todos os países do conglomerado 3 estão acima da média nas duas dimensões. Similarmente, todos os países agrupados pelo *cluster 4* também apresentam inclusividade e contestação acima da média. À primeira vista, o leitor seria levado a acreditar que a análise de *cluster* falhou em classificar os regimes políticos. Isso porque agrupou países com médias de contestação e inclusividade semelhantes dentro de diferentes conglomerados (*clusters 3 e 4*). No entanto, os conglomerados são criados de forma relacional, considerando todos os países ao mesmo tempo em função do centro do *cluster*. Tem-se, então, uma medida de similaridade entre os regimes políticos tendo como parâmetro não a média, mas sim a distância de cada um deles em relação ao centro do conglomerado. Por exemplo, ao se utilizar a média como referência, Haiti (HTI), Canadá (CAN) e França (FRA) formam um mesmo grupo, localizado no quadrante superior direito. Porém, via análise de *cluster*, o pesquisador chegaria a um resultado bem diferente e concluiria que o Haiti (HTI) é mais semelhante a Togo (TON) e Serra Leoa (SLE).

Mas quão diferentes são esses grupos (*clusters*)? Tecnicamente, o pesquisador pode avaliar em que medida a solução encontrada é estatisticamente aceitável. Garson (2010) recomenda analisar a distância média das observações em relação ao centro do *cluster* após a formação dos diferentes conglomerados. Quanto maior for a diferença entre essas médias, maior é o grau de diferenciação entre os grupos. A Tabela 2 sumariza essas informações.

Tabela 2
Centro do *Cluster* final

Dimensões	Cluster			
	1	2	3	4
Inclusividade	-1,94	0,26	0,05	0,83
Contestação	-1,03	-0,68	0,39	1,16

Observando os valores da distância final de cada grupo (*cluster*) para cada uma das dimensões, tem-se que o *cluster 4* apresenta os maiores níveis de inclusividade (0,83) e contestação (1,16). No outro oposto, o *cluster 1* apresenta os valores mais reduzidos de inclusividade (-1,94) e contestação (-1,03). A Tabela 3 apresenta a estatística F e os respectivos níveis de significância estatística para cada dimensão analisada²⁴.

²⁴ É importante lembrar que como a análise de *cluster* maximiza a diferença entre os grupos, a estatística F não pode ser interpretada como representando um teste de hipótese de diferença entre os grupos. A sua interpretação mais adequada deve se restringir ao aspecto descritivo.


Tabela 3
Análise de Variância (ANOVA)

ANOVA						
Dimensões	Cluster		Erro		F	Sig.
	Mean Square	gl	Mean Square	gl		
Inclusividade	5,61	3	0,086	45	65.28	0,000
Contestação	11,51	3	0,149	45	77.08	0,000

Por fim, é importante validar os resultados encontrados. Neste artigo, optamos por duas formas de validação: a primeira consiste em selecionar outra amostra aleatória a partir da amostra original e replicar a análise. O segundo procedimento é comparar a classificação produzida via análise de conglomerados com a taxonomia proposta por Mainwaring, Brinks e Pérez-Liñán (2000).

Em relação à primeira forma de validação, extraímos outra amostra aleatória a partir do banco de dados original. O Gráfico 2 ilustra a dispersão dos países divididos em quatro *clusters*.

Gráfico 2
Dispersão dos países em quatro grupos (validação 1)



O *cluster* 1 se localiza integralmente no quadrante inferior esquerdo (ambas as dimensões abaixo da média) e agrupa Kuwait (KWT), Barém (BHR) e Líbia (LBI). O *cluster* 2, por sua vez, apresenta também distribuição homogênea, localizando-se no quadrante superior direito (ambas acima da média). O *cluster* 3 agrupa os países com inclusividade acima da média e contestação abaixo do termo médio. Finalmente, o conglomerado 4 também agrupa os países com níveis de inclusividade e contestação acima da média. Em uma análise de dispersão convencional (olhando para as médias), o pesquisador seria levado a classificar os regimes políticos dos *clusters* 2 e 4 sob uma mesma categoria. No entanto, é visualmente perceptível a diferença que existe entre os regimes políticos dos *clusters* 2 e 4, registre-se: os regimes políticos agrupados no grupo 4 são mais democráticos do que aqueles aglomerados no 2, embora eles estejam contidos no mesmo quadrante. Dessa forma, uma primeira vantagem associada à utilização da análise de conglomerados é o maior grau de precisão analítica que o pesquisador pode atingir. Como a classificação de um determinado regime político é mais objetiva, o pesquisador reduz a probabilidade de produzir classificações grosseiras. Além disso, é possível avaliar quão diferente é um caso em relação às demais observações do seu grupo bem como ponderar o nível de diferenciação entre os diferentes grupos.


O segundo procedimento adotado para validar os resultados é comparar as soluções encontradas via análise de conglomerados com a classificação elaborada por Mainwaring, Brinks e Pérez-Liñán (2000). Para tanto, realizamos uma nova aglomeração com os 19 casos analisados por esses autores, tendo o ano de 1999 como referência. Utilizamos o método *K-means clustering* de aglomeração e definimos a criação de quatro grupos. A Tabela 4 apresenta a classificação proposta por Mainwaring, Brinks e Pérez-Liñán (2000) bem como os níveis de contestação e inclusividade de cada país e o seu respectivo *cluster*.

Tabela 4
Comparação entre a classificação de MBP (2000) e análise de *cluster*

País	Período	MBP (2000)	Contest99	Inclus99	Cluster
Argentina	1983-99	D	1,09	1,03	3
Bolívia	1982-99	D	1,43	0,54	4
Brasil	1985-99	D	1,37	0,79	4
Chile	1990-99	D	1,43	0,78	4
Colômbia	1990-99	S	0,94	0,80	3
Costa Rica	1949-99	D	1,70	0,72	4
República Dominicana	1996-99	D	0,91	0,88	3
Equador	1979-99	D	0,96	0,81	3
El Salvador	1992-99	D	1,23	0,68	4
Guatemala	1986-99	S	1,00	0,72	3
Haiti	1945-99	A	0,33	0,01	2
Honduras	1982-99	S	1,08	0,82	3
México	1988-99	S	0,91	0,69	3
Nicarágua	1984-99	S	1,12	0,88	3
Panamá	1994-99	D	1,44	0,93	4
Paraguai	1989-99	S	0,73	0,25	2
Peru	1995-99	S	0,21	0,77	1
Uruguai	1985-99	D	1,71	0,94	4
Venezuela	1958-99	D	0,95	0,87	3

Seguindo a classificação proposta por Mainwaring, Brinks e Pérez-Liñán (2000), observa-se que 11 dos 19 regimes políticos são classificados como democráticos (57,89%), 36,84% dos casos são classificados como semi-democráticos (7 observações) e apenas o regime político do Haiti foi classificado como autoritário. No entanto, é interessante notar que países classificados com o mesmo regime foram agrupados em diferentes *clusters*, como é o caso de Argentina (*cluster* 3) e Bolívia (*cluster* 4). O Gráfico 3 ilustra a dispersão dos países analisados por Mainwaring, Brinks e Pérez-Liñán (2000) divididos em 4 grupos.

Gráfico 3
Dispersão dos países em quatro grupos (validação 2)



Em primeiro lugar, observa-se uma grande correspondência entre o *cluster* 3 e o grupo de países classificados como semi-democracias segundo a tipologia elaborada por Mainwaring, Brinks e Pérez-Liñán (2000). A exceção fica por conta do Peru (PER) -*cluster* 2 - e Paraguai (PRY) -conglomerado 1. Em relação a este último, Mainwaring, Brinks e Pérez-Liñán (2000), o classificam como semi-democracia. No entanto, a análise de *cluster* sugere que o regime político paraguaio está mais próximo do Haiti (HTI), único país classificado como autoritário segundo a tipologia elaborada por Mainwaring, Brinks e Pérez-Liñán (2000). Além disso, os países considerados democráticos pelos referidos autores estão divididos entre os *clusters* 3 e 4. Por exemplo, Venezuela (VEN) - *cluster* 3 - e Uruguai (URY) - *cluster* 4 - estão agrupados sob a mesma categoria: democracia. Todavia, os países do *cluster* 4 são nitidamente mais democráticos do que os regimes políticos do conglomerado 3. Isso quer dizer que a taxonomia proposta por Mainwaring, Brinks e Pérez-Liñán (2000) não permite observar a variação dentro dos grupos. A depender de quanta variação esteja presente, corre-se o risco de chamar “urubu de meu louro”. Em termos mais técnicos, corre-se o risco de produzir classificações e tipologias inconsistentes que não discriminam os casos de interesse a partir das categorias analíticas utilizadas.

Conclusão

Como elevar a precisão analítica de tipologias teoricamente orientadas? O principal objetivo deste artigo foi apresentar, passo a passo, a lógica intuitiva da técnica de análise de conglomerados. Isso porque acreditamos que a classificação de casos em categorias é uma etapa fundamental do conhecimento científico. Comparativamente, observou-se que a classificação de regimes políticos via análise de agrupamentos fornece um maior grau de precisão do que classificações categóricas do tipo: democracia versus autoritarismo; democracia, semi-democracia e autoritarismo, etc. Com a análise de conglomerados, o pesquisador tem como estimar com maior precisão o grau de semelhança/diferença entre os seus casos de interesse. Entendemos que essa técnica proporciona um avanço metodológico importante e, caso seja aplicada adequadamente, pode nos ajudar a melhor classificar nossos casos em categorias teoricamente inteligíveis.

E qual é o problema de agrupar casos diferentes sob a mesma categoria? Fundamentalmente, perde-se poder de sensibilidade analítica. Ou seja, a variável de interesse perde a sua capacidade explicativa em relação a outras variáveis. Por exemplo, se o pesquisador acredita que democracias tendem a promover um maior nível de redistribuição de renda, a classificação inadequada dos regimes políticos vai influenciar negativamente a capacidade de encontrar o efeito esperado. Não porque o efeito não existe e sim porque as categorias utilizadas não possuem poder discriminatório.

Atribui-se a Charles Darwin a seguinte passagem: “A ignorância gera mais frequentemente confiança do que o conhecimento: são os que sabem pouco, e não aqueles que sabem muito, que afirmam de uma forma tão categórica que este ou aquele problema nunca será resolvido pela ciência”. Acreditamos que a empreitada do conhecimento é um caminho tortuoso e quanto mais precisos forem nossos instrumentos para investigar a realidade, tanto mais capacitados estaremos para responder às questões que nos interessam. Com este artigo, esperamos ter facilitado a compreensão da técnica de análise de conglomerados nas Ciências Sociais em geral e difundido a sua aplicação prática na Ciência Política em particular.

Referências Bibliográficas

ALDENDERFER, M. S. e BLASHFIELD, R. K. “Cluster Analysis”. Sage University Paper Series: Quantitative Applications in the Social Science, 1984.

BAILEY, K. D. “Cluster Analysis”. *Sociological Methodology*, vol. 6, p. 59-128, 1975.

BERRY, B. J. L. and RAY, M. Multivariate socio-economic regionalization: A pilot study in central Canada. Unpublished manuscript. Department of Geography, University of Chicago, 1966.

BURTON, M. C. e ROMMEY, A. K. “A Multidimensional Representation of Role Terms”. *American Ethnologist*, v. 2, n.3, p.397-407, 1975.

COPPEDGE, M.; ALVAREZ, A.; MALDONADO, C. “Two Persistent Dimensions of Democracy: Contestation and Inclusiveness”. *Journal of Politics*, v. 70, n. 3, p. 1-45, 2008.

CZEKANOWSKI, J. “Objectiv Kriterien in der Ethnologie”. *Korrespondenz-Blatt der Deutschen Gesellschaft für Anthropologie, Ethnologie und Urgeschichte*, 42, p.71-75, Hamburg, 1911.

- DAHL, R. *Poliarquia: Participação e Oposição*. São Paulo: Edusp, 1971.
- DANSECO, E. R.; HOLDEN, E. W. "Are There Different Types of Homeless Families? A Typology of Homeless Families Based On Cluster Analysis". *Family Relations*, v. 47, n. 2, p. 159-165.
- DOLNICAR, S. A review of unquestioned standards in used cluster analysis for data-driven market segmentation. *Faculty of Commerce – Papers*. 2002. Disponível em: < <http://ro.uow.edu.au/commpapers/273> >.
- DRIVER, H. E. Survey of numerical classification in anthropology. In: HYMES, D. (Ed.). *The Use of Computers in Anthropology*. The Hague: Mouton, 1965.
- DRIVER, H. E.; KROEBER, A. L. *Quantitative Expressions of Cultural Relationships*. Berkeley: University of California Press, 1932.
- EVERITT, B.S. *Cluster Analysis*. Second Edition, London: Heineman Educational Books Ltd, 1980.
- FILSINGER, E.; FAULKNER, J. & WARLAND, R. "Empirical taxonomy of religious individuals: An investigation among college students". *Sociological Analysis*, v. 40, 136-146, 1979.
- FISHER, W. D. *Clustering and Aggregation in Economics*. Baltimore: Johns Hopkins, 1969.
- FLEISHMAN, J. A. "Types of Political Attitude Structure: Results of a Cluster Analysis". *The Public Opinion Quarterly*, v. 50, n. 3, p. 371-386, 1986.
- FORMANN, A.K. *Die Latent-Class-Analyse: Einführung in die Theorie und Anwendung*. Weinheim: Beltz, 1984.
- GARSON, G. D. *Statnotes: Topics in Multivariate Analysis* [online]. Disponível em: <<http://faculty.chass.ncsu.edu/garson/PA765/statnote.htm>> Acesso em 22 jan. 2010.
- GOLDSTEIN, S. G. and LINDEN, J. "Multivariate Classification of alcoholics by means of MMPI". *Journal of abnormal Psychology*, v. 14, n. 6, p. 661-669.
- HAIR, Jr; BLACK, W. C; BABIN, B. J.; ANDERSON, R. E.; TATHAM, R. L. *Análise Multivariada de Dados*. Porto Alegre: Bookman, 2005.
- _____. *Multivariate Data Analysis*. 6ª edição. Upper Saddle River, NJ: Pearson Prentice Hall, 2006.
- JOHNSON, S. "Hierarchical clustering schemes". *Psychometrika*, 38, p.241-254, 1967.
- KAISER, H. F. "An objective method for establishing legislative districts". *Midwest Journal of Political Science*, v. 10, p. 200-213, 1966.
- KING, G.; KEOHANE, R.; VERBA, S. *Designing Social Inquiry: Scientific Inference in Qualitative Research*, Princeton: Princeton university Press, 1994.
- MACRAE, D. Jr. "Cluster Analysis of Congressional Votes with the BC TRY System". *The Western Political Quarterly*, v. 19, n. 4, p. 631-638.
- MAINWARING, S.; BRINKS, D.; PÉREZ-LIÑÁN, A. "Classificando Regimes Políticos na América Latina, 1945-1999". *Dados*, v. 44, n. 4, 2001.
- MOONEY, C. Z. "Bootstrap Statistical Inference: examples and evaluation for Political Science". *American Journal of Political Science*, v. 40, n. 2, p. 570-602.
- PETERS, W. S. "Cluster Analysis in Urban Demography", *Social Forces*, v. 37, n. 1, p. 38-44, 1958.
- POHLMANN, M. C. Análise de Conglomerados. In: CORRAR, L. J.; EDÍLSON, P.; DIAS FILHO, J. M. (Orgs.). *Análise Multivariada*. São Paulo: Atlas, 2007.
- SANTOS, M. H; COUTINHO, M. "Política comparada: estado das artes e perspectivas no Brasil", *BIB*, v. 5, n. 4, p. 3-146, 2000.
- SOARES, G. "O calcanhar metodológico da ciência política no Brasil". *Sociologia, Problemas e Práticas*, v. II, n. 48, p. 27-52, 2005.
- SOKAL, R. R.; SNEATH, P. H. A. *Principles of Numerical Taxonomy*. San Francisco: W. H. Freeman, 1963.

TRYON, R. Cluster Analysis. New York: McGraw-Hill, 1939.

VALLE e SILVA, N. *Relatório de Consultoria sobre Melhoria do Treinamento em Ciência Social Quantitativa e Aplicada no Brasil*. Rio de Janeiro, Laboratório Nacional de Computação Científica, 1999.

VANNEMAN, R. "The Occupational Composition of American Classes: Results from Cluster Analysis". *The American Journal of Sociology*, v. 82, n. 4, p. 783-807, 1977.

WERNECK VIANNA, L. et al. "Doutores e teses em ciências sociais", *Dados*, v. 41, n. 3, p. 453-515, 1998.

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

Dalson Britto Figueiredo Filho - dalsonbritto@yahoo.com.br

José Alexandre da Silva Júnior - jasjunior2007@yahoo.com.br

Enivaldo Carvalho da Rocha - eni-rocha@hotmail.com

Recebido para publicação em setembro de 2010.

Aprovado para publicação em junho de 2011.