




III MCSM

Modelagem Computacional no Sertão Mineiro



PPGMCS
Programa de Pós-Graduação em
Modelagem Computacional e Sistemas

CAPACIDADE MÉDICA GERAL OU ATENÇÃO PRIMÁRIA? CLUSTERING NA QUALIDADE DA SAÚDE NA RMBH

Arthur Leite Setragni¹ - arthursetragni@gmail.com

Aline Lunkes² - alinelunkesazl@gmail.com

Angélica C. G. Santos³ - angelicacidalia@gmail.com

Matheus Pereira Libório³ - m4th32s@gmail.com

Petr Iakovlevitch Ekel¹ - petr.ekel2709@gmail.com

¹Pontifícia Universidade Católica de Minas Gerais (PUC Minas), Belo Horizonte, MG, Brasil

²Universidade Federal do Pampa (UNIPAMPA), Campus Alegrete, RS, Brasil

³Universidade Estadual de Montes Claros (UNIMONTES), Montes Claros, MG, Brasil

Abstract. *Mais médicos e leitos deveriam, em princípio, reduzir internações evitáveis e mortalidade por doenças crônicas. Este estudo testa essa expectativa nos 34 municípios da Região Metropolitana de Belo Horizonte (RMBH), aplicando o método Smart k-means sobre nove critérios de saúde e financiamento, selecionados por otimização exaustiva a partir dos 12 originais, em escala original e sem exclusão de município em nenhuma etapa. O algoritmo forma quatro grupos (silhueta 0,497), com tamanhos 4, 13, 16 e 1. O grupo de maior capacidade médica e maior despesa por habitante, que inclui Belo Horizonte, ocupa posição intermediária em internações por condições sensíveis à atenção básica (ICSAB). O grupo de melhor resultado tem menos de um terço dessa capacidade. Itatiaiuçu isola-se sozinho, por despesa per capita quase quatro desvios-padrão acima da média e ausência de leitos hospitalares, sem que isso resulte no melhor nem no pior resultado. Na RMBH, maior capacidade médica geral e maior despesa por habitante não caracterizam, portanto, os municípios com melhores resultados em ICSAB. O padrão sugere que fatores associados à atenção primária pesam mais que a estrutura hospitalar para esse desfecho.*

Keywords: *Internações evitáveis, Atenção primária à saúde, Clustering não supervisionado, Smart k-means, Política pública em saúde*

1. INTRODUÇÃO

Avaliar sistemas de saúde por métodos quantitativos é importante porque a condição de saúde de uma população é inerentemente multidimensional, envolvendo acesso, equidade, efetividade, eficiência, qualidade, responsividade e desfechos, sendo que nenhuma medida isolada capta bem esse conjunto (Firza & Mazzitelli, 2025).

Na análise de contextos complexos, surgem técnicas para organizar múltiplas medidas em categorias interpretáveis que facilitem a visão global, comparação e comunicação pública (Libório et al., 2024). Nesse sentido, a análise de agrupamento identifica grupos com alta similaridade interna e heterogeneidade entre grupos (Jain et al., 1999), apoiando a formulação

de políticas públicas direcionadas a cada perfil, em vez de uma resposta única para toda a região. Cabe destacar que heterogeneidade entre os municípios caracteriza o objeto de investigação deste estudo, não algo a ser eliminado ou simplificado previamente.

Como exposto por Alfradique et al. (2009), internações por condições sensíveis à atenção básica (ICSAB) são, por definição, hospitalizações evitáveis quando a atenção primária funciona bem, conforme a lista brasileira construída pelo Projeto ICSAP-Brasil. Em um estudo sobre microrregiões brasileiras, Macinko et al. (2011) analisam cerca de 60 milhões de internações em 558 microrregiões entre 1999 e 2007, mostrando que a disponibilidade do Programa Saúde da Família associou-se a menores taxas de ICSAB, enquanto leitos hospitalares privados ou filantrópicos associaram-se a taxas maiores, evidência de que oferta de atenção primária e oferta hospitalar puxam o indicador em direções opostas. Em Belo Horizonte, Mendonça et al. (2012) observaram que a implantação das equipes de Saúde da Família reduziu as internações por condições sensíveis à atenção primária em 17,9%, frente a 8,3% nas demais internações, com maior impacto nas áreas mais vulneráveis. Posteriormente, Mendonça et al. (2017) mostraram que a qualidade das equipes, mais do que o nível socioeconômico, explica as internações evitáveis no município. Assim como Mendonça et al., Castro et al. (2015), em grandes municípios brasileiros, destacam que a distribuição adequada de médicos e a mudança efetiva do modelo de atenção seguem sendo desafios centrais.

Este estudo aplica o método Smart k-means (Martins et al., 2024) selecionando variáveis por otimização exaustiva e silhueta, para os 34 municípios da Região Metropolitana de Belo Horizonte (RMBH). A análise investiga se os grupos formados revelam alguma relação entre capacidade médica geral e os desfechos estudados, e o que essa relação sugere para a alocação de recursos públicos. Com esse intuito, além desta introdução, a seção 2 apresenta os métodos, a seção 3 os resultados e a discussão, e a seção 4 conclui o estudo.

2. METODOLOGIA

2.1 Coleta de dados

A matriz de dados reúne os 34 municípios da RMBH (Lei Complementar Estadual nº 89/2006) e 12 critérios de saúde e financiamento, com dados de 2022 do Departamento de Informática do SUS (DATASUS), do Sistema de Informações sobre Orçamentos Públicos em Saúde (SIOPS) e do Censo do Instituto Brasileiro de Geografia e Estatística (IBGE), sem exclusão de município em nenhuma etapa. Os nove critérios utilizados na classificação, selecionados por otimização exaustiva conforme detalhado na próxima subseção, estão descritos na Tabela 1.

Tabela 1: Critérios mantidos após a exclusão por otimização exaustiva

Dimensão	Critérios mantidos
Estrutura	C1 Médicos/1k, C2 Leitos/1k, C3 Cobertura ESF, C4 Equipes ESF/1k
Resultados	C5 Mort. infantil, C6 ICSAB, C7 Mort. DCNT
Financiamento	C9 Despesa <i>per capita</i> , C10 % Receita própria

2.2 Smart k-means

O k-means constitui um algoritmo de particionamento amplamente utilizado, cujo procedimento iterativo alterna entre a atribuição de cada observação ao centroide mais próximo e a atualização dos centroides a partir da média das observações pertencentes a cada grupo (MacQueen, 1967). Esse processo é repetido até que se atinja a convergência (Kassambara, 2017). Embora tenha como objetivo minimizar a inércia intragrupo, o desempenho do algoritmo pode ser comprometido pela inclusão de indicadores irrelevantes ou redundantes, uma vez que

tais variáveis tendem a comprimir o espaço de atributos, distorcer as distâncias euclidianas e, conseqüentemente, reduzir a qualidade dos agrupamentos, conforme avaliada pelo coeficiente de Silhueta (Rousseeuw, 1987).

O Smart k-means por otimização exaustiva é uma extensão do algoritmo k-means que busca maximizar simultaneamente a qualidade estatística e a interpretabilidade dos agrupamentos por meio de uma busca sistemática no espaço de soluções. Inicialmente, o usuário define um intervalo plausível para o número de clusters (por exemplo, $k = 3$ a $k = 5$) e um limiar mínimo de qualidade, normalmente um coeficiente de Silhueta $\geq 0,50$ (Rousseeuw, 1987). Para cada valor de k , o algoritmo executa sucessivas clusterizações avaliando todas as combinações possíveis de subconjuntos de variáveis (subindicadores). Cada combinação é submetida ao k-means e sua qualidade é mensurada pelo coeficiente médio de Silhueta. Apenas as soluções que atendem ao limiar estabelecido são consideradas admissíveis. Entre essas, seleciona-se aquela que preserva o maior número de subindicadores, minimizando a exclusão de informação sem comprometer a coesão e a separação entre os grupos (Martins et al., 2024).

Como todas as combinações viáveis são examinadas, o método aproxima-se da solução global ótima para o conjunto de restrições definido. Entretanto, o custo computacional cresce combinatoriamente com o número de variáveis, sendo indicado principalmente para problemas de baixa ou média dimensionalidade.

Diferentemente de outros métodos que agregam, critérios em um escore ponderado, exigindo normalização prévia, o k-means agrupa municípios pela distância entre eles no espaço das variáveis. Dessa forma, os critérios são considerados em sua escala original, sem padronização, para aplicação do k-means (MacQueen, 1967) e o valor de k é avaliado pelo método Smart k-means para o conjunto de dados em análise.

3. RESULTADOS E DISCUSSÃO

A busca por otimização exaustiva do método Smart k-means (D’Angelo et al., 2026; Martins et al., 2024) identificou que a exclusão de três critérios, mortalidade materna (C8), transferências SUS *per capita* (C11) e gasto próprio sobre transferências (C12), preserva o maior número de variáveis entre as combinações que atingem o piso de silhueta de 0,50. Os nove critérios remanescentes (Tabela 1) foram mantidos.

O k-means com $k = 4$, aplicado às nove variáveis em escala original, atinge silhueta = 0,497, muito próxima do piso de referência de 0,50. A Figura 1 mostra o tamanho de cada grupo, e a Tabela 2 resume o perfil nas variáveis mais relevantes para a discussão.




Figura 1: Número de municípios por grupo (k-means, $k=4$).

Tabela 2: Perfil dos grupos (k-means, $k=4$, dados brutos), médias por grupo

Grupo	n	C1	C2	C6 (%)	C9 (R\$)
1 (maior capacidade)	4	3,65	1,90	1,13	2.338,46
2 (melhor resultado)	13	1,21	0,56	0,83	1.460,21
3 (resultado desfavorável)	16	0,88	0,76	1,27	866,24
4 (outlier)	1	2,39	0,00	1,10	4.199,48

Grupo 1, maior capacidade (n=4): Belo Horizonte, Brumadinho, Confins e Nova Lima. Tem o maior C1 (3,65 médicos/1.000 hab., mais que o triplo da média da amostra) e o maior C2 (1,90 leitos/1.000 hab.) entre os quatro grupos, além da maior despesa *per capita* (R\$ 2.338). Ainda assim, seu C6 médio (1,13%) fica em posição intermediária, não a melhor.

Grupo 2, melhor resultado (n=13): Betim, Contagem, Florestal, Juatuba, Lagoa Santa, Mateus Leme, Nova União, Rio Acima, Rio Manso, São Joaquim de Bicas, Sarzedo, Taquaraçu de Minas e Baldim. Tem o melhor C6 da amostra (0,83%) com capacidade intermediária (C1=1,21), bem abaixo do Grupo 1.

Grupo 3, resultado desfavorável (n=16): o maior grupo, incluindo Ibitaré, Ribeirão das Neves, Sabará, Santa Luzia, Itaguara, entre outros. Tem o pior C6 (1,27%) com a menor despesa *per capita* (R\$ 866) e capacidade abaixo da média (C1=0,88).

Grupo 4, outlier (n=1): Itatiaiuçu, isolado por uma combinação incomum, C2 (leitos) igual a zero e despesa *per capita* de R\$ 4.199, quase quatro desvios-padrão acima da média da amostra (R\$ 1.365), sem que isso resulte no melhor C6 (1,10%, posição intermediária).

A Figura 2 mapeia os 34 municípios por grupo. Os municípios do Grupo 3 (resultado desfavorável, em vermelho) e do Grupo 2 (melhor resultado, em verde) aparecem espacialmente misturados ao redor da capital, sem uma divisão clara de centro-periferia ou direção cardeal predominante. Essa distribuição reforça que proximidade com a capital, por si só, não explica o resultado em ICSAB.




Figura 2: Municípios da RMBH por grupo (k-means, k=4).

Esse resultado é o achado central deste estudo. Na RMBH, maior capacidade médica geral e maior despesa por habitante não caracterizam os municípios com melhores resultados em ICSAB. Esse constitui o achado mais robusto deste estudo e contraria a expectativa inicial. O grupo com maior capacidade instalada e maior despesa da amostra, que inclui Belo Horizonte, apresenta desempenho intermediário. O Grupo 2, com menos de um terço do C1 do Grupo 1, tem o melhor resultado da amostra. A Figura 3 mostra o escore-z de cada grupo em cada

variável, o Grupo 1 destaca-se em capacidade e despesa (tons mais escuros à esquerda), mas não em C6, enquanto o Grupo 2 tem o melhor C6 sem se destacar em nenhuma variável de estrutura. A concentração de médicos em Belo Horizonte que caracteriza o Grupo 1 reflete um padrão nacional documentado, o relatório Demografia Médica no Brasil 2025 (Scheffer et al., 2025) mostra que 48 cidades brasileiras com mais de 500 mil habitantes concentram 58% dos médicos do país com apenas 31% da população. A RMBH reproduz essa assimetria em escala regional, sem que a concentração de médicos e leitos na capital garanta o melhor resultado em ICSAB.




Figura 3: Escore-z médio de cada grupo, por variável (dados brutos, k=4).

Em síntese, os resultados indicam que, na RMBH, maior capacidade médica e maior despesa *per capita* não se traduzem necessariamente em melhores indicadores de ICSAB. O Grupo 2, mesmo com menor estrutura, apresentou o melhor desempenho da amostra, enquanto o Grupo 1 permaneceu em posição intermediária. A presença de Itatiaiuçu como outlier e a ausência de um padrão espacial centro-periferia reforçam que a oferta hospitalar, o volume de recursos e a proximidade com a capital não explicam isoladamente os desfechos observados. Esses achados sugerem que fatores associados à atenção primária podem ter papel mais relevante na redução das internações evitáveis.

4. CONCLUSÃO

Na RMBH, maior capacidade médica geral e maior despesa por habitante não caracterizam os municípios com melhores resultados em ICSAB. Esse constitui o achado mais robusto deste estudo e contraria a expectativa inicial.

O grupo com maior capacidade instalada e maior despesa da amostra, que inclui Belo Horizonte, apresenta desempenho intermediário. O grupo de melhor resultado tem menos de um terço dessa capacidade. Itatiaiuçu isola-se por uma combinação de ausência de leitos e despesa extrema, sem que isso resulte no melhor nem no pior resultado. Esse padrão sugere que fatores ligados à atenção primária, não à estrutura hospitalar nem ao volume de gasto, pesam mais para esse desfecho nesta amostra, uma direção consistente com a literatura nacional (Macinko et al., 2011; Castro et al., 2015; Mendonça et al., 2012, 2017), ainda que este estudo não meça diretamente atenção primária nem teste essa hipótese complementar de forma independente.

Esse achado também dialoga com o financiamento vigente do SUS. O orçamento de 2025 destina R\$116 bilhões à assistência hospitalar e ambulatorial contra R\$55 bilhões à atenção básica, uma proporção de mais de 2 para 1 que a nova metodologia de cofinanciamento por desempenho da atenção primária (Brasil, 2024) busca começar a corrigir. Os resultados aqui relatados reforçam essa direção, sem a pretensão de avaliá-la diretamente.

A recomendação sugerida (investir em atenção primária rende mais que ampliar médicos, leitos e despesa) exige cautela, pois o desenho transversal não descarta causalidade reversa e

a amostra limita a força dessa hipótese. Os dados sustentam apenas a parte negativa, mais capacidade e mais gasto não caracterizam os municípios de melhor resultado. Como melhorias para estudos futuros, sugere-se o uso de dados em painel de múltiplos anos, o teste formal da hipótese de compensação por atenção primária, a extensão da análise a mais anos e municípios, e a investigação junto a Itatiaiuçu da combinação de despesa elevada e ausência de leitos observada.

Agradecimentos

Os autores agradecem à FAPEMIG (grant nº OET-00243-26) e ao apoio do projeto APD-00860-25.

REFERENCES

- Alfradique, M.E., Bonolo, P.F., Dourado, I., Lima-Costa, M.F., Macinko, J., Mendonça, C.S. et al. (2009), “Internações por Condições Sensíveis à Atenção Primária: a Construção da Lista Brasileira como Ferramenta para Medir o Desempenho do Sistema de Saúde (Projeto ICSAP-Brasil)”, *Cadernos de Saúde Pública*, vol. 25, no. 6, 1337-1349.
- Brasil, Ministério da Saúde (2024), *Portaria GM/MS nº 3.493, de 10 de abril de 2024*, Diário Oficial da União, Brasília.
- Castro, A.L.B., Andrade, C.L.T., Machado, C.V. e Lima, L.D. (2015), “Condições Socioeconômicas, Oferta de Médicos e Internações por Condições Sensíveis à Atenção Primária em Grandes Municípios do Brasil”, *Cadernos de Saúde Pública*, vol. 31, no. 11, 2353-2366.
- D’Angelo, M.F.S.V., Martins, D.C., Libório, M.P., Santos, A.C.G., Vieira, A.W., Ekel, P.Ya. e Cardoso, D.N. (2026), “Smart k-means: An Open-Source Tool for Reliable Representation of Multidimensional Phenomena”, *Software Impacts*, vol. 29, 100847.
- Firza, N. e Mazzitelli, D. (2025), “Composite Indicators for Performance Evaluation in Healthcare”, em Gervasi, O. et al. (orgs.), *Computational Science and Its Applications – ICCSA 2025*, LNCS vol. 15650, Springer, Cham.
- Jain, A.K., Murty, M.N. e Flynn, P.J. (1999), “Data Clustering: A Review”, *ACM Computing Surveys*, vol. 31, no. 3, 264-323.
- Kassambara, A. (2017), *Practical Guide to Cluster Analysis in R*, STHDA, 2ª ed.
- Libório, M.P., Karagiannis, R., Diniz, A.M.A., Ekel, P.I., Vieira, D.A.G. e Ribeiro, L.C. (2024), “The Use of Information Entropy and Expert Opinion in Maximizing the Discriminating Power of Composite Indicators”, *Entropy*, vol. 26, no. 2, 143.
- Macinko, J., de Oliveira, V.B., Turci, M.A., Guanais, F.C., Bonolo, P.F. e Lima-Costa, M.F. (2011), “The Influence of Primary Care and Hospital Supply on Ambulatory Care-Sensitive Hospitalizations Among Adults in Brazil, 1999-2007”, *American Journal of Public Health*, vol. 101, no. 10, 1963-1970.
- MacQueen, J.B. (1967), “Some Methods for Classification and Analysis of Multivariate Observations”, *Proceedings of the 5th Berkeley Symposium on Mathematical Statistics and Probability*, vol. 1, 281-297.
- Martins, D.C., Laudares, S., Ekel, P.I., D’Angelo, M.F.S.V. e Libório, M.P. (2024), “Novo Método para Representação de Fenômenos Sociais Multidimensionais: Smart k-means”, *Anais do LVI Simpósio Brasileiro de Pesquisa Operacional (SBPO)*.
- Mendonça, C.S., Harzheim, E., Duncan, B.B., Nunes, L.N. e Leyh, W. (2012), “Trends in Hospitalizations for Primary Care Sensitive Conditions Following the Implementation of Family Health Teams in Belo Horizonte, Brazil”, *Health Policy and Planning*, vol. 27, no. 4, 348-355.
- Mendonça, C.S., Leotti, V.B., Dias-da-Costa, J.S. e Harzheim, E. (2017), “Hospitalizations for Primary Care Sensitive Conditions: Association with Socioeconomic Status and Quality of Family Health Teams in Belo Horizonte, Brazil”, *Health Policy and Planning*, vol. 32, no. 10, 1368-1374.
- Rousseeuw, P.J. (1987), “Silhouettes: A Graphical Aid to the Interpretation and Validation of Cluster Analysis”, *Journal of Computational and Applied Mathematics*, vol. 20, 53-65.
- Scheffer, M. et al. (2025), *Demografia Médica no Brasil 2025*, FMUSP, Associação Médica Brasileira e Ministério da Saúde, São Paulo.