ConBRepro
XVI CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO
EVENTO ON-LINE
02 a 04 de dezembro de 2026
Inovação e Transformação Digital como Estratégia Competitiva nas Engenharias

SISTEMA DE APOIO À DECISÃO PARA O CONSULTÓRIO NA RUA: MAPEAMENTO PREDITIVO DE ZONAS DE CALOR COM INTELIGÊNCIA ARTIFICIAL E AHP

Ever Santoro
Faculdade de Engenharia de Bauru – UNESP-Univ Estadual Paulista, Engenharia de Produção

Edilaine M. Soler
Faculdade de Ciências – UNESP-Univ Estadual Paulista, Departamento de Matemática

Adriana C. Cherri
Faculdade de Ciências – UNESP-Univ Estadual Paulista, Departamento de Matemática

Resumo: A População em Situação de Rua (PSR) concentra vulnerabilidades clínicas, sociais e territoriais que desafiam a Atenção Primária e a efetividade do Consultório na Rua (CnR). Sem apoio analítico, as equipes itinerantes operam de forma predominantemente reativa, com dificuldade para localizar, no tempo e no espaço, os territórios de maior necessidade e para articular recursos escassos de modo equânime. Este artigo propõe um Sistema de Apoio à Decisão (SAD) que integra Inteligência Artificial e Análise Hierárquica de Processos (AHP) para o mapeamento preditivo de "zonas de calor" da PSR. O modelo combina densidade espacial, vulnerabilidade sociossanitária e segurança territorial, identificando epicentros dinâmicos ao longo do dia (manhã, tarde e noite) e distinguindo concentração geográfica de prioridade operacional. A solução oferece aos gestores municipais um instrumento concreto para antecipar demandas, priorizar deslocamentos e fortalecer o cuidado itinerante no Sistema Único de Saúde (SUS).

Palavras-chave: Inteligência Artificial, Pesquisa Operacional, Saúde Pública, Consultório na Rua.

DECISION SUPPORT SYSTEM FOR STREET CLINIC: PREDICTIVE HOTSPOT MAPPING WITH ARTIFICIAL INTELLIGENCE AND AHP

Abstract: People experiencing homelessness face overlapping clinical, social and territorial vulnerabilities that challenge Primary Care and the effectiveness of Brazil's Consultório na Rua program. Without analytical support, itinerant teams operate in a predominantly reactive manner, struggling to locate, in time and space, the territories of greatest need and to allocate scarce resources more equitably. This paper proposes a Decision Support System (DSS) that integrates Artificial Intelligence and the Analytic Hierarchy Process (AHP) for the predictive mapping of homelessness hotspots. The model combines spatial density, sociosanitary vulnerability and territorial safety, identifying dynamic epicenters throughout the day (morning, afternoon, and night) and distinguishing geographic concentration from operational priority. The solution provides municipal managers with a concrete instrument to anticipate demand, prioritize field displacements and strengthen itinerant care within the Brazilian Unified Health System.

Keywords: Artificial Intelligence, Operations Research, Public Health, Street Clinic.

1. Introdução

O cotidiano da População em Situação de Rua (PSR) representa um dos desafios mais complexos e urgentes para a saúde pública e para a assistência social no Brasil. Mais do que uma estatística demográfica, trata-se de um contingente humano submetido a múltiplas vulnerabilidades, caracterizadas pela pobreza extrema, rompimento de vínculos familiares, violência estrutural e exclusão social sistêmica (BAUMAN, 2005; SICARI; ZANELLA, 2018; OLIVEIRA et al., 2020). Como resposta política e humanitária a essa invisibilidade, o Consultório na Rua (CnR) consolidou-se como estratégia intersetorial vital da Atenção Primária no Sistema Único de Saúde (SUS), ofertando cuidado integral, redução de danos e atendimento itinerante nos territórios de vivência desses sujeitos (ALVES et al., 2021; MEDEIROS; CAVALCANTE, 2018; REIS; AZEVÊDO, 2023).

Historicamente institucionalizado na Política Nacional de Atenção Básica, o CnR possui diretrizes vinculadas a parâmetros demográficos e epidemiológicos que exigem dos municípios a cobertura ativa de territórios com alta concentração de vulnerabilidades. Contudo, a expansão quantitativa da PSR e a obrigatoriedade de assegurar acesso universal e equânime esbarram na rigidez dos modelos tradicionais de gestão, que frequentemente desconsideram a distribuição espacial e a dinamicidade temporal dos fluxos urbanos.

A efetividade dessa política pública enfrenta, ainda, um cenário logístico e operacional adverso. A literatura aponta que os profissionais de saúde lidam com carência crônica de recursos, alta carga de estresse e extrema dificuldade em coordenar abordagens em cenários urbanos dinâmicos (BORYSOW; CONILL; FURTADO, 2017; SANTOS et al., 2021). Por dependerem de abordagens territoriais quase inteiramente reativas e sem amparo de dados de geolocalização exatos, as equipes frequentemente falham em engajar justamente os indivíduos com as vulnerabilidades clínicas, infecciosas e psiquiátricas mais agudas (LO et al., 2022; CARVALHO; CONCEIÇÃO; SANTOS, 2025). O esgotamento dos profissionais e o desperdício de recursos evidenciam que a gestão empírica do cuidado itinerante requer inovações estruturais.

No campo da Engenharia de Produção, o problema de coordenar equipes médicas que se deslocam até os pacientes é amplamente tratado por formulações do *Home Health Care Routing and Scheduling Problem* (HHCRSP) e do *Vehicle Routing Problem* (VRP) (FIKAR; HIRSCH, 2017; CATTARUZZA et al., 2017). Contudo, a demanda móvel e estocástica do CnR limita a aplicação direta desses motores sem uma camada prévia de inteligência espacial – lacuna que a Inteligência Artificial e a análise multicritério podem preencher (CHEN et al., 2017; SAATY, 1980).

Diante dessa lacuna, o presente artigo tem como objetivo propor um Sistema de Apoio à Decisão (SAD) focado no mapeamento preditivo da PSR. A abordagem utiliza algoritmos de *Machine Learning* para processar indicadores de vulnerabilidade e identificar “zonas de calor” (*heatmaps*) probabilísticas na malha urbana, traduzindo dados brutos de atendimento em priorização territorial imediata. A solução destaca-se por aplicabilidade prática: uma interface visual em Java (*Spring Boot*), integrada a um microserviço de importação, permite que gestores municipais carreguem dados em formato CSV (*Comma-Separated Values*, planilha em texto cujos campos são separados por vírgula) e visualizem a dinâmica socioterritorial por turno, com epicentros de vulnerabilidade que mudam ao longo do dia.

Este artigo está organizado em cinco seções. A Seção 1 apresenta esta introdução. A Seção 2 apresenta a revisão bibliográfica sobre PSR, CnR, Pesquisa Operacional e Inteligência Artificial aplicada à saúde. A Seção 3 descreve a metodologia, abrangendo a arquitetura de dados espaciais, a geração de dados sintéticos e a modelagem preditiva via AHP. A Seção 4 discute os resultados. A Seção 5 sintetiza as considerações finais e as limitações do estudo.

2. Revisão bibliográfica

2.1 População em Situação de Rua e Consultório na Rua

Revisões sistemáticas nacionais evidenciam o aumento da PSR e a recorrência de vulnerabilidades como uso de álcool e outras drogas, violência, preconceito e fragilização de vínculos familiares (OLIVEIRA et al., 2020; SICARI; ZANELLA, 2018). No plano das políticas públicas, a consolidação de marcos legais e de serviços socioassistenciais como por exemplo o Centro Pop e do próprio CnR, amplia o reconhecimento de direitos, embora persistem desafios de reinserção social e de articulação intersetorial (REIS; AZEVÊDO, 2023; MEDEIROS; CAVALCANTE, 2018).

Estudos comparados sobre unidades móveis em Portugal, Estados Unidos e Brasil mostram potencial de melhoria de acesso, busca ativa e trabalho multidisciplinar, com divergências quanto ao vínculo com a atenção primária e ao financiamento (BORYSOW; CONILL; FURTADO, 2017). No cotidiano do cuidado, psicólogos e demais profissionais enfrentam escassez de recursos e baixa articulação territorial (SANTOS et al., 2021; CARVALHO; CONCEIÇÃO; SANTOS, 2025). Evidências internacionais sobre *street outreach* reforçam que programas itinerantes engajam mais pessoas em situação de rua, mas nem sempre alcançam os indivíduos com as vulnerabilidades clínicas mais graves (LO et al., 2022), o que motiva ferramentas de priorização territorial baseadas em dados.

A literatura também destaca a importância do diagnóstico socioterritorial, da escuta qualificada e da redução de danos como eixos da atuação profissional junto à PSR, valorizando singularidades e buscando garantir direitos humanos e cidadania (REIS; AZEVÊDO, 2023; ALVES et al., 2021). Nesse contexto, tecnologias de apoio à decisão não substituem o cuidado clínico, mas podem reduzir a aleatoriedade logística que hoje compromete a efetividade do CnR.

2.2 Pesquisa Operacional e Inteligência Artificial na logística em saúde

No campo da Engenharia de Produção e da Pesquisa Operacional (PO), o desafio de coordenar equipes que se deslocam até os pacientes é tratado por formulações do *Home Health Care Routing and Scheduling Problem* (HHCRSP) e do *Vehicle Routing Problem* (VRP) aplicados à logística urbana (FIKAR; HIRSCH, 2017; CATTARUZZA et al., 2017). Modelos recentes incorporam sincronização e ressuprimento de clínicas móveis para maximizar a cobertura de atendimento (ALKAABNEH; SUTHARSON, 2024). Entretanto, ao contrário do atendimento domiciliar clássico em que o destino é fixo, o ambiente do CnR apresenta demanda móvel e altamente estocástica, limitando a aplicação direta de heurísticas de roteamento sem uma camada prévia de inteligência espacial.

É neste hiato metodológico que a Inteligência Artificial (IA) torna-se imperativa. Estudos recentes demonstram que algoritmos de *Machine Learning* processam volumes elevados de dados sociodemográficos para prever padrões de risco e antecipar demandas em saúde pública (CHEN et al., 2017; KOH; MONTGOMERY; O'BRIEN, 2022). A aplicação preditiva permite transformar a gestão de uma postura reativa para uma abordagem proativa e territorializada, estruturando a demanda espacial de forma quantificável e auditável.

A Análise Hierárquica de Processos (AHP) (SAATY, 1980) complementa essa abordagem ao estruturar julgamentos multicritério de forma auditável, o que é particularmente relevante quando se agregam densidade espacial, vulnerabilidade sociossanitária e segurança territorial (inverso da periculosidade do local) em um único índice de prioridade. Em síntese, a literatura converge para a necessidade de integrar predição espacial e decisão multicritério no apoio à gestão do CnR, exatamente o núcleo metodológico adotado neste trabalho.

3. Metodologia

A pesquisa caracteriza-se como estudo de modelagem computacional e simulação, estruturado sob o rigor metodológico da pesquisa social aplicada (MINAYO, 2001). O objetivo é desenvolver um SAD voltado ao CnR, de modo a substituir a alocação empírica por predição inteligente dos territórios prioritários. Para viabilizar a arquitetura tecnológica e garantir escalabilidade no âmbito do Sistema Único de Saúde (SUS), a metodologia foi dividida em três etapas interdependentes: (i) estruturação da arquitetura de dados espaciais; (ii) geração de dados sintéticos baseada em parâmetros oficiais; e (iii) aplicação de algoritmos de Inteligência Artificial combinados à Análise Multicritério (AHP) para identificação preditiva de agrupamentos territoriais.

3.1 Arquitetura e engenharia de dados espaciais

Para lidar com a complexidade e a dinamicidade geográfica inerente à PSR, construiu-se uma arquitetura de banco de dados relacional com suporte nativo a operações geoespaciais. O sistema foi implementado no PostgreSQL com a extensão PostGIS, encapsulado em contêineres *Docker*, garantindo portabilidade e reprodutibilidade.

A base atua como "chassi" do SAD, permitindo o armazenamento de coordenadas de vivência (latitude e longitude) por meio do tipo *Geometry*, com SRID 4326 (WGS 84), assegurando precisão cartográfica para consultas espaciais e visualização territorial. A ingestão tabular é realizada por um microserviço em Python (*FastAPI*), responsável pela validação do contrato CSV e pela persistência no PostGIS; a interface de gestão e o mapa preditivo são servidos pelo *backend* Java (*Spring Boot*), que também atua como *gateway* de importação.

3.2 Geração de dados sintéticos e validação de parâmetros (LGPD)

O acesso direto a microdados nominais, como os do e-SUS APS e do Cadastro Único (CadÚnico), esbarra nas diretrizes da Lei Geral de Proteção de Dados Pessoais (LGPD). Para viabilizar o desenvolvimento e os testes de carga sem comprometer o sigilo de pacientes reais, adotou-se a geração de dados sintéticos estruturados (*Mock Data*).

Utilizando Python, simulou-se uma base restrita ao polígono urbano de Bauru-SP, empregado apenas como referência espacial da simulação – os registros não correspondem a pacientes nem a atendimentos reais do município. Os parâmetros categóricos de vulnerabilidade foram inspirados nos dicionários do Índice de Vulnerabilidade das Famílias do Cadastro Único (IVCAD) (Ministério do Desenvolvimento e Assistência Social, Família e Combate à Fome (MDS), 2023) e do Protocolo de Estratificação de Risco e Atenção em Saúde Mental (Secretaria Municipal da Saúde de São Paulo, 2023). Não se trata de calibração estatística com microdados nominais oficiais, mas de um mock espacialmente coerente e metodologicamente auditável. Cada paciente sintético recebeu coordenada espacial válida, turno de referência $t \in \{\text{manhã, tarde, noite}\}$, peso categórico de vulnerabilidade v_i em escala discreta de 1 a 5 (Tabela 1) e nível de periculosidade do local $p_i \in \{1,\ldots,5\}$ (Tabela 2).

A geração espacial utilizou quatro pontos de interesse socioassistencial no mapa: centro comercial/terminal, praça, viaduto/abrigo improvisado e periferia, cujos pesos de amostragem são redistribuídos por turno, deslocando o centro de gravidade da demanda ao longo do dia. A amostra sintética de referência totaliza 885 registros (295 por turno).

Tabela 1 – Estratificação de níveis de vulnerabilidade e risco para a PSR no modelo preditivo

Nível	Classificação geral	Critérios clínicos e socioterritoriais
1	Baixa vulnerabilidade	Situação de rua intermitente, acesso ocasional a abrigos. Demanda acompanhamento ambulatorial primário
2	Vulnerabilidade moderada	Situação de rua contínua com rompimento de vínculos familiares. Sem quadros clínicos graves aparentes
3	Vulnerabilidade elevada	Situação de rua crônica associada ao uso problemático de substâncias, demandando abordagem multidisciplinar
4	Risco grave	Presença de transtornos mentais severos desassistidos ou doenças infectocontagiosas crônicas
5	Risco extremo (emergência)	Intoxicação aguda, heteroagressividade severa ou risco iminente de morte. Necessidade de resgate

Fonte: Elaborado pelos autores (2026).

Tabela 2 – Estratificação sintética da periculosidade do local para priorização logística das equipes

Nível	Classificação	Implicação operacional (protótipo)
1	Baixa periculosidade	Área de circulação diurna com presença institucional frequente
2	Periculosidade moderada baixa	Local acessível, risco residual controlável pela equipe de rotina
3	Periculosidade moderada	Exige atenção situacional e possível reforço de protocolo
4	Alta periculosidade	Ambiente hostil ou de conflito; prioriza apoio policial / equipe ampliada
5	Periculosidade extrema	Condições que desaconselham deslocamento imediato sem protocolo reforçado

Fonte: Elaborado pelos autores (2026).

3.3 Modelagem preditiva e índice territorial via AHP

A construção de índices compostos para priorização territorial exige a agregação de dimensões heterogêneas com densidade espacial da demanda, vulnerabilidade sociossanitária e segurança do local de abordagem. Para evitar pesos fixos empíricos não auditáveis, os pesos do índice preditivo foram obtidos pelo *Analytic Hierarchy Process* (AHP) (SAATY, 1980).

Seja $i \in \{1,\ldots,n\}$ o índice de um ponto georreferenciado. Definiram-se três critérios normalizados em [0,1]:

A **densidade espacial** (D_i), estimada por *Kernel Density Estimation* (KDE) gaussiana, seguida de normalização min-max:

$$D_i = (\hat{f}(x_i) - \min_j \hat{f}(x_j)) / (\max_j \hat{f}(x_j) - \min_j \hat{f}(x_j) + \varepsilon)$$

A **vulnerabilidade sociossanitária** (V_i), obtida pela padronização do nível ordinal $v_i \in \{1,2,3,4,5\}$:

$$V_i = v_i / 5$$

E a **segurança territorial** (Seg_i), definida como o complemento da periculosidade normalizada $P_i = p_i/5$, com $p_i \in \{1,\ldots,5\}$:

$$Seg_i = 1 - P_i = 1 - p_i/5$$

Essa formulação preserva pesos AHP não negativos e materializa a regra operacional de que quanto maior a periculosidade do local, menor a prioridade de envio imediato da equipe, não como abandono do cuidado, mas como sinalização de protocolo reforçado com apoio policial, equipe ampliada ou remanejamento temporal.

Na elicitação AHP, a matriz de julgamento de referência (3 × 3) considerou a densidade espacial ligeiramente mais importante que os demais critérios ($a_{1,2} = a_{1,3} = 2$) e a vulnerabilidade igualmente importante à segurança ($a_{2,3} = 1$):

Matriz A de julgamento AHP (critérios D, V e Seg)

	D	V	Seg
D	1	2	2
V	1/2	1	1
Seg	1/2	1	1

Fonte: Elaborado pelos autores (2026).

Adota-se a notação $a_{i,j}$ para o elemento da linha i e da coluna j. As linhas e as colunas de A correspondem, nessa ordem, aos critérios densidade espacial (D), vulnerabilidade sociossanitária (V) e segurança territorial (Seg). Cada $a_{i,j}$ expressa a importância relativa do critério da linha i frente ao da coluna j, na escala de Saaty. Os valores $a_{1,2} = 2$ e $a_{1,3} = 2$ são pares distintos com a mesma intensidade de julgamento: $a_{1,2}$ compara densidade com vulnerabilidade, e $a_{1,3}$ compara densidade com segurança – ambos indicando que a densidade é ligeiramente mais importante. Já $a_{3,1} = 1/2$ é o elemento da linha 3 (segurança) e coluna 1 (densidade), ou seja, o recíproco de $a_{1,3}$ ($a_{j,i} = 1/a_{i,j}$). A diagonal $a_{i,i} = 1$ compara cada critério consigo mesmo.

A resolução do problema de autovalor (A w = λ_max w) forneceu w_D = 0,5, w_V = 0,25, w_Seg = 0,25 e λ_max = 3. O índice de consistência é nulo e a razão de consistência satisfaz o critério de Saaty (CR = 0 < 0,10).

O escore preditivo final, Índice de Prioridade Territorial (S_i), é a combinação linear convexa:

$$S_i = 0{,}5\, D_i + 0{,}25\, V_i + 0{,}25\, Seg_i$$

Sob a ótica da saúde pública, a priorização da densidade espacial no AHP refere-se à eficiência macro-logística em definir o ponto ótimo de ancoragem da equipe móvel para maximizar a cobertura populacional, sem substituir a triagem clínica individual realizada *in loco*. A inclusão da segurança territorial incorpora a proteção das equipes ao planejamento preditivo.

Operacionalmente, o pipeline preditivo implementado em Python (*Scikit-learn*) e registrado como KMEANS_KDE_AHP_TEMPORAL procede, para cada turno t: (i) agrupamento espacial por *K-Means*; (ii) estimação de densidade por KDE e cálculo de S_i com pesos AHP; (iii) agregação da intensidade de cada zona como a média de S_i no respectivo cluster. Assim, o *K-Means* delimita as zonas territoriais, enquanto o índice AHP prioriza a vulnerabilidade relativa e a segurança operacional dentro e entre essas zonas.

Para evitar arbitrariedade na escolha do número de zonas (K), avaliou-se $K \in \{2,\ldots,8\}$ pela inércia intra-cluster (método do cotovelo) e pelo Índice de Silhueta Médio (ROUSSEEUW, 1987), sobre o turno de referência (manhã). A varredura inicia em K = 2 porque K = 1 corresponde a um único agrupamento trivial – sem partição territorial –, situação em que o Índice de Silhueta não se aplica de forma significativa para comparar alternativas de agrupamento. O valor K = 1 foi excluído *a priori*, pois inviabiliza a formação de múltiplas zonas e o cálculo do Índice de Silhueta. O K* resultante foi aplicado de forma homogênea aos demais turnos, assegurando comparabilidade temporal.

A inércia, ou *Within-Cluster Sum of Squares* (WCSS), mensura a compactação espacial dos grupos:

$$WCSS(K) = \Sigma_{k=1}^{K} \Sigma_{x_i \in C_k} \|x_i - \mu_k\|^2$$

em que C_k é o cluster k e μ_k o respectivo centroide. O Índice de Silhueta $s(i) \in [-1,1]$ avalia coesão interna e separação espacial:

$$s(i) = (b(i) - a(i)) / \max\{a(i), b(i)\}$$

sendo a(i) a distância média para os demais pontos do mesmo cluster e b(i) a menor distância média para o cluster vizinho mais próximo.

Selecionou-se K = *3, valor que maximizou o Índice de Silhueta Médio no cenário de referência (silhueta ≈ 0,840). Na ausência de rótulos do mundo real (*ground truth*), a validação apoia-se na coerência geométrica dos agrupamentos, na reprodutibilidade do pipeline e na aderência operacional da interface.

Por fim, introduziu-se a variável de turno t ∈ {manhã, tarde, noite} na geração sintética e na estimação das zonas de calor, redistribuindo os pesos dos epicentros territoriais, como por exemplo, enfatizando o centro comercial no período matutino e o viaduto no pernoite, de modo que a densidade por KDE e o agrupamento reflitam os deslocamentos do centro de gravidade da demanda. O resultado é exportado para a interface visual em Java (*Spring Boot*) com a biblioteca *Leaflet*, disponibilizando mapas interativos, centroides das zonas e APIs (*GeoJSON* e *Leaflet.heat*) consumíveis por gestores municipais (CATTARUZZA et al., 2017; ALKAABNEH; SUTHARSON, 2024).

4. Resultados e discussão

Os resultados concentram-se na validação da arquitetura de software e na demonstração operacional do modelo preditivo espacial. A construção do SAD supera a escassez de ferramentas de gestão territorial no SUS, entregando uma plataforma em que gestores municipais importam dados estruturados (CSV) para análise dinâmica imediata.

Para a validação operacional, o *backend* Java (*Spring Boot*), em conjunto com o microserviço de importação, processou com sucesso a amostra sintética de 885 registros restrita ao polígono urbano de Bauru-SP (295 por turno). Por meio do *endpoint* de ingestão, o sistema converteu microdados tabulares em coordenadas geográficas nativas, armazenando-as no PostgreSQL/PostGIS (SRID 4326). Essa etapa confirma a aderência do contrato de dados ao fluxo operacional esperado em secretarias municipais de saúde, reduzindo a dependência de planilhas manuais e de mapas estáticos.

Sobre essa base, o pipeline *K-Means* + KDE + AHP, executado independentemente por turno com K* = 3, mostrou-se eficaz na conversão de dados brutos em inteligência territorial. O algoritmo correlacionou a dispersão geográfica com os pesos categóricos de vulnerabilidade e de periculosidade (escalas de 1 a 5) e produziu nove zonas de calor no total (três por turno). Locais de alta densidade e vulnerabilidade, porém com elevada periculosidade, tiveram o índice S_i atenuado via Seg_i, priorizando deslocamentos em que a relação benefício clínico/risco operacional é mais favorável. Ressalta-se que a mancha de calor no mapa expressa densidade espacial e não, isoladamente, ordem de envio da equipe. A identificação probabilística dessas zonas responde à lacuna apontada por Lo Et Al. et al. (2022), fornecendo direcionamento para que as equipes priorizem sujeitos com demandas clínicas e psiquiátricas mais agudas, com resguardo à segurança da equipe.

Do ponto de vista da discussão com a literatura, o achado dialoga com a crítica de que o *outreach* frequentemente não alcança os casos de maior gravidade clínica (LO et al., 2022) e com as dificuldades logísticas descritas para o CnR brasileiro (BORYSOW; CONILL; FURTADO, 2017; MEDEIROS; CAVALCANTE, 2018). Ao explicitar epicentros dinâmicos por turno, o SAD oferece um mecanismo concreto de priorização territorial que a gestão empírica tradicional não dispõe.

A matriz de predição foi disponibilizada via API (*GeoJSON* e pontos no formato *Leaflet.heat*), consumida pela interface *web*. A Figura 1 ilustra a interface de gestão desenvolvida para a prefeitura, e a Figura 2 apresenta a renderização dos *heatmaps* sobre a cartografia do município, evidenciando a transição geográfica da demanda entre os turnos diurno e noturno.

Figura 1 – Interface de ingestão de dados: módulo de importação de atendimentos para gestão municipal

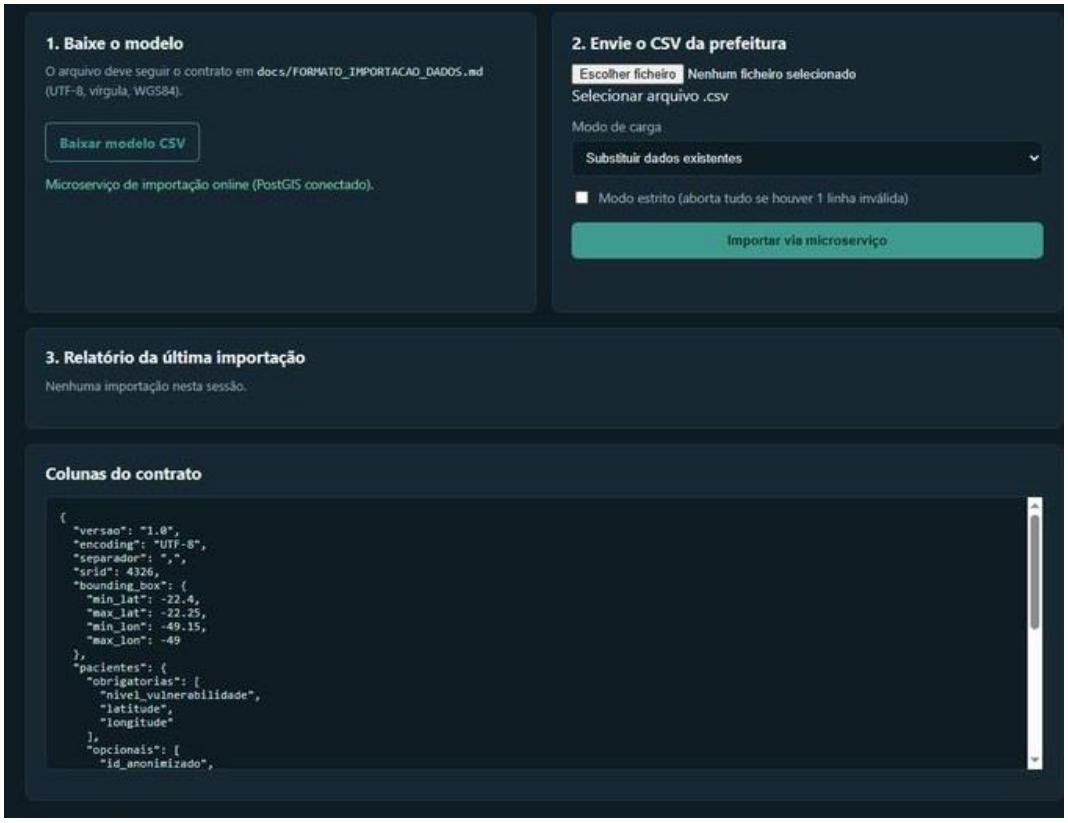

Fonte: Elaborado pelos autores (2026).

Figura 2 – Dinâmica temporal das zonas de calor probabilísticas simuladas sobre Bauru-SP: manhã (esquerda) e noite (direita)

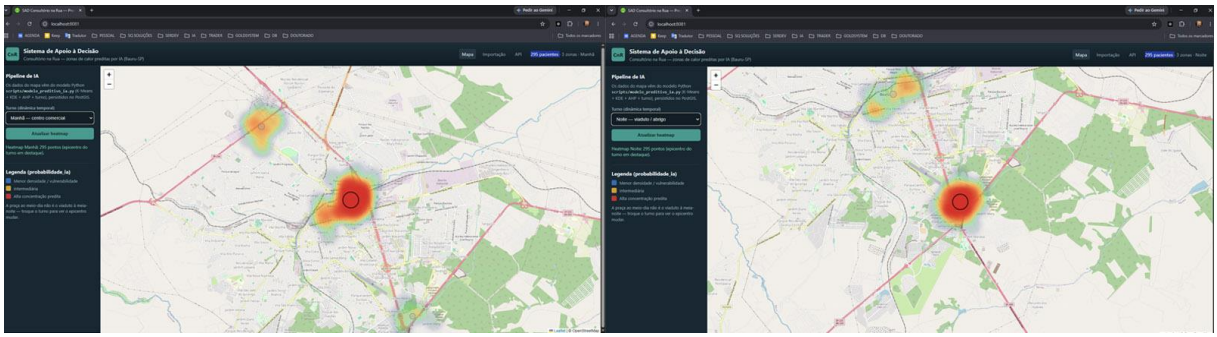

Fonte: Elaborado pelos autores (2026).

A renderização das manchas de calor comprova a viabilidade da transição de um modelo de gestão reativo para um modelo analítico e proativo (CHEN et al., 2017), oferecendo panorama imediato para a articulação de recursos escassos (BORYSOW; CONILL; FURTADO, 2017). A incorporação da variável temporal mostrou-se diferencial expressivo da solução: a interface filtra e atualiza as predições conforme o turno (manhã, tarde ou noite), evidenciando a transição dos epicentros do centro comercial e áreas de circulação no período diurno para viadutos e áreas de pernoite no período noturno. Essa transição descreve o *onde* e o *quando* da demanda. O índice S_i, contudo, não coincide automaticamente com a mancha de densidade: locais noturnos de alta concentração e alta periculosidade têm Seg_i reduzido, o que atenua a prioridade de deslocamento imediato e

sinaliza protocolo reforçado (apoio policial, equipe ampliada ou remanejamento temporal), sem equivaler a abandono do cuidado. Assim, o SAD distingue densidade territorial de prioridade operacional.

Sob a ótica da Engenharia de Produção, os centros de densidade identificados estruturam a demanda territorial de forma quantificável e dinâmica, superando mapas estáticos e planilhas manuais (FIKAR; HIRSCH, 2017; ALKAABNEH; SUTHARSON, 2024). Em conjunto, os achados reforçam a literatura que aponta a necessidade de inovação logística no cuidado itinerante e demonstram que a predição espacial multicritério constitui, por si só, instrumento de apoio à decisão com valor operacional para o CnR.

Reconhece-se que os resultados baseiam-se em dados sintéticos, restrição deliberada imposta pela Lei Geral de Proteção de Dados Pessoais (LGPD) neste estudo – não se utilizam microdados nominais do SUS, do CadÚnico nem de atendimentos reais do município. A silhueta elevada (K = *3) indica boa separação geométrica no mock utilizado, cujo enquadramento cartográfico toma o polígono urbano de Bauru-SP apenas como referência espacial da simulação. Ainda assim, a entrega já é completa em termos arquitetural, metodológico e operacional: pipeline auditável (KDE* + K-Means + *AHP), índice territorial com três critérios, importação municipal via CSV e interface* web* capaz de traduzir dados brutos em mapa preditivo por turno.

5. Considerações finais

Este estudo visa auxiliar o atendimento da População em Situação de Rua, sendo este um dos desafios mais complexos e urgentes para a saúde pública e a assistência social. Este é um tipo de serviço que envolve pessoas em situação de pobreza extrema, violência estrutural, entre outras fragilidades. Diante do esgotamento profissional e da ineficiência gerados por abordagens territoriais puramente reativas (CARVALHO; CONCEIÇÃO; SANTOS, 2025; BORYSOW; CONILL; FURTADO, 2017), propomos neste trabalho um SAD (Sistema de Apoio à Decisão) voltado ao apoio territorial do Consultório na Rua, o qual mostrou que a integração de infraestrutura geoespacial (PostgreSQL/PostGIS) com algoritmos de Inteligência Artificial transforma o planejamento em saúde pública. A ferramenta viabiliza a antecipação de demandas e o mapeamento dinâmico da vulnerabilidade da PSR, devolvendo precisão ao cuidado itinerante (REIS; AZEVÊDO, 2023).

Sob a ótica da Engenharia de Software e da modelagem computacional, a geração de dados sintéticos inspirados nos dicionários oficiais do IVCAD (Ministério do Desenvolvimento e Assistência Social, Família e Combate à Fome (MDS), 2023), projetados sobre o mapa de Bauru-SP apenas como referência espacial – sem uso de dados reais de pacientes ou de atendimentos locais –, mostrou-se estratégia metodológica eficaz para contornar restrições da LGPD e validar a arquitetura. O *backend* em Java (*Spring Boot*), o microserviço de importação e o modelo preditivo encontram-se homologados, processando 885 registros sintéticos e produzindo nove zonas de calor dinâmicas por turno.

Como limitação do estudo, ressalta-se que as “zonas de calor” preditas foram validadas com dados sintéticos, sem avaliação externa com microdados nominais do SUS ou avaliação qualitativa junto às equipes do CnR. Essa restrição não diminui o valor da entrega: o SAD já disponibiliza diagnóstico territorial preditivo, índice multicritério auditável e interface operacional pronta para uso municipal.

Em síntese, o trabalho contribui ao: (i) formalizar um índice territorial auditável via AHP com três critérios (densidade, vulnerabilidade e segurança); (ii) demonstrar a viabilidade técnica e operacional de um SAD geoespacial para o CnR; e (iii) entregar uma solução integrada

com banco espacial, pipeline de IA, importação CSV e mapa interativo que traduz dados brutos em inteligência socioterritorial imediata para a gestão do cuidado itinerante.

Referências

ALKAABNEH, F.; SUTHARSON, S. J. Routing mobile health clinics: An integrated routing and resupply plan based on synchronization. **arXiv**, v. 40, p. 100415, 2024. Disponível em: <https://arxiv.org/abs/2412.17299>.

ALVES, A. C. O. et al. Intersecção entre psicologia institucional e as práticas do consultório na rua. **Revista Humanidades e Inovação**, v. 8, n. 59, p. 210–218, 2021.

BAUMAN, Z. **Vidas desperdiçadas**. Rio de Janeiro: Jorge Zahar, 2005.

BORYSOW, I. D. C.; CONILL, E. M.; FURTADO, J. P. Atenção à saúde de pessoas em situação de rua: estudo comparado de unidades móveis em Portugal, Estados Unidos e Brasil. **Ciência & Saúde Coletiva**, v. 22, n. 3, p. 879–890, mar. 2017. ISSN 1413-8123. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1413-81232017002300879&lng=pt&tlng=pt>.

CARVALHO, R. M. F. d.; CONCEIÇÃO, P. W. R. d.; SANTOS, K. S. Psicologia e população em situação de rua: interfaces com a política pública e o cuidado em saúde mental. **Contribuciones a las Ciencias Sociales**, v. 18, n. 8, p. 1–16, ago. 2025. Disponível em: <https://doi.org/10.55905/revconv.18n.8-198>.

CATTARUZZA, D. et al. Vehicle routing problems for city logistics. **EURO Journal on Transportation and Logistics**, v. 6, n. 1, p. 51–79, 2017. Disponível em: <https://doi.org/10.1007/s13676-014-0074-0>.

CHEN, M. et al. Disease prediction by machine learning over big data from healthcare communities. **IEEE Access**, v. 5, p. 8869–8879, 2017. Disponível em: <https://doi.org/10.1109/access.2017.2694446>.

FIKAR, C.; HIRSCH, P. Home health care routing and scheduling: A review. **Computers & Operations Research**, v. 77, p. 86–95, 2017. Disponível em: <https://doi.org/10.1016/j.cor.2016.07.019>.

KOH, K. A.; MONTGOMERY, A. E.; O'BRIEN, R. W. Predicting Homelessness Among U.S. Army Soldiers No Longer on Active Duty. **American Journal of Preventive Medicine**, v. 63, n. 5, p. 736–745, 2022. Disponível em: <https://doi.org/10.1016/j.amepre.2021.12.028>.

LO, E. et al. Does Street Outreach Engage Its Intended Target Population? Clinical Experience in the Veteran's Health Administration Homeless Service Programs. **Psychiatric Quarterly**, v. 93, n. 4, p. 1003–1016, dez. 2022. ISSN 0033-2720, 1573-6709. Disponível em: <https://link.springer.com/10.1007/s11126-022-10004-9>.

MEDEIROS, C. R. S.; CAVALCANTE, P. A implementação do programa de saúde específico para a população em situação de rua - Consultório na Rua: barreiras e facilitadores. **Saúde e Sociedade**, v. 27, n. 3, p. 754–768, 2018. Disponível em: <https://doi.org/10.1590/s0104-12902018170946>.

MINAYO, M. C. S. **Pesquisa Social: Teoria, método e criatividade**. 18. ed. Petrópolis: Vozes, 2001.

Ministério do Desenvolvimento e Assistência Social, Família e Combate à Fome (MDS). **Índice de Vulnerabilidade das Famílias do Cadastro Único (IVCAD)**. Brasília, 2023. Disponível em: <https://www.gov.br/mds/pt-br/orgaos/SAGICAD/dados-e-ferramentas-informacionais/ivcad>.

OLIVEIRA, G. B. et al. Pessoas em situação de rua: revisão sistemática. **Estudos Interdisciplinares em Psicologia**, v. 11, n. 2, p. 58, ago. 2020. ISSN 2236-6407. Disponível em: <http://www.uel.br/revistas/uel/index.php/eip/article/view/40>.

REIS, T. C. M.; AZEVÊDO, A. V. D. S. Pessoas em situação de rua: inclusão/exclusão social, políticas públicas, atuação do psicólogo. **PSI UNISC**, v. 7, n. 1, p. 50–74, jan. 2023. ISSN 2527-1288. Disponível em: <https://online.unisc.br/seer/index.php/psi/article/view/17691>.

ROUSSEEUW, P. J. Silhouettes: a graphical aid to the interpretation and validation of cluster analysis. **Journal of Computational and Applied Mathematics**, v. 20, p. 53–65, 1987. ISSN 0377-0427. Disponível em: <https://www.sciencedirect.com/science/article/pii/0377042787901257>.

SAATY, T. L. **The Analytic Hierarchy Process: Planning, priority setting, resource allocation**. New York: McGraw-Hill, 1980.

SANTOS, V. C. C. et al. Psicólogos nos serviços socioassistenciais para pessoas em situação de rua. **Diaphora**, v. 10, n. 3, p. 45–51, dez. 2021. ISSN 2238-9709, 1806-1133. Disponível em: <http://www.sprgs.org.br:80/diaphora/ojs/index.php/diaphora/article/view/281>.

Secretaria Municipal da Saúde de São Paulo. **Protocolo de Estratificação de Risco e Atenção às Crises em Saúde Mental na RAPS**. São Paulo, 2023. Disponível em: <https://prefeitura.sp.gov.br/documents/d/saude/protocolo_class_risco_s_mental_mar25_2-pdf>.

SICARI, A. A.; ZANELLA, A. V. Pessoas em Situação de Rua no Brasil: Revisão Sistemática. **Psicologia: Ciência e Profissão**, v. 38, n. 4, p. 662–679, out. 2018. ISSN 1982-3703, 1414-9893. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1414-98932018000500662&tlng=pt>.