

Planejamento de agricultura urbana com GeoAI: proposta de modelo para apoio à gestão pública territorial

Urban agriculture planning with GeoAI: a proposed model to support territorial public management

Planificación de la agricultura urbana con GeoAI: propuesta de modelo para el apoyo a la gestión pública territorial

Grupo temático 04 - Gestão de Cidades Resilientes e Sustentáveis

Cíntia Paese Giacomello – Universidade de Caxias do Sul

Daniel Luis Notari – Universidade de Caxias do Sul

Alexandre Pereira Santos – Ludwig Maximilian University of Munich

Ana Cristina Fachinelli – Universidade de Caxias do Sul

Mateus Panizzon – Universidade de Caxias do Sul

RESUMO

A agricultura urbana tem sido reconhecida como estratégia relevante para promoção da segurança alimentar, sustentabilidade urbana e fortalecimento de comunidades locais. Entretanto, a definição de áreas adequadas para implantação de hortas urbanas envolve múltiplos critérios ambientais, sociais e territoriais. Este estudo propõe um modelo conceitual baseado em inteligência artificial geoespacial (GeoAI) para apoiar a alocação de hortas urbanas em contextos metropolitanos. A pesquisa combina revisão sistemática da literatura com análise de métodos de otimização e análise espacial utilizados no planejamento urbano. O modelo proposto integra dados geográficos, indicadores socioambientais e técnicas de apoio à decisão para identificar áreas prioritárias para implantação de hortas urbanas. Os resultados indicam que abordagens baseadas em GeoAI podem apoiar gestores públicos na formulação de políticas urbanas mais eficientes, contribuindo para planejamento territorial sustentável e promoção da equidade no acesso à infraestrutura verde urbana.

Palavras-chave: Agricultura urbana, Planejamento urbano, GeoAI, Políticas públicas, Infraestrutura verde

ABSTRACT

Urban agriculture has been recognized as a relevant strategy for promoting food security, urban sustainability, and the strengthening of local communities. However, the identification of suitable areas for the implementation of urban gardens involves multiple environmental, social, and territorial criteria. This study proposes a conceptual model based on geospatial artificial intelligence (GeoAI) to support the allocation of urban gardens in metropolitan contexts. The research combines a systematic literature review with an analysis of optimization and spatial analysis methods used in urban planning. The proposed model integrates geographic data, socio-environmental indicators, and decision-support techniques to identify priority areas for the implementation of urban gardens. The results indicate that GeoAI-based approaches can support public managers in the formulation of more efficient urban policies, contributing to sustainable territorial planning and the promotion of equity in access to urban green infrastructure..

Keywords: Urban agriculture; Urban planning; GeoAI; Public policies; Green infrastructure

RESUMEN

La agricultura urbana ha sido reconocida como una estrategia relevante para promover la seguridad alimentaria, la sostenibilidad urbana y el fortalecimiento de las comunidades locales. Sin embargo, la identificación de áreas adecuadas para la implementación de huertos urbanos implica múltiples criterios ambientales, sociales y territoriales. Este estudio propone un modelo conceptual basado en inteligencia artificial geoespacial (GeoAI) para apoyar la asignación de huertos urbanos en contextos metropolitanos. La investigación combina una revisión

sistemática de la literatura con el análisis de métodos de optimización y análisis espacial utilizados en la planificación urbana. El modelo propuesto integra datos geográficos, indicadores socioambientales y técnicas de apoyo a la decisión para identificar áreas prioritarias para la implementación de huertos urbanos. Los resultados indican que los enfoques basados en GeoAI pueden apoyar a los gestores públicos en la formulación de políticas urbanas más eficientes, contribuyendo a la planificación territorial sostenible y a la promoción de la equidad en el acceso a la infraestructura verde urbana.

Palabras clave: Agricultura urbana; Planificación urbana; GeoAI; Políticas públicas; Infraestructura verde

1. Introdução:

A intensificação da urbanização nas últimas décadas tem ampliado simultaneamente as pressões ambientais e as desigualdades socioespaciais nas cidades. A concentração de atividades produtivas e de fluxos veiculares contribui para a deterioração da qualidade do ar, enquanto a expansão urbana tende a aprofundar padrões de segregação territorial e de vulnerabilidade social reforçando a complexidade da gestão da qualidade do ar em grandes centros urbanos (Girotti et al., 2024). Nesse contexto, a agricultura urbana, que inclui hortas comunitárias, fazendas urbanas e sistemas produtivos integrados ao tecido urbano, tem sido reconhecida como instrumento capaz de articular segurança alimentar, regeneração ambiental e fortalecimento comunitário (Russell; Atchison; Guhathakurta, 2023). Contudo, a alocação dessas hortas em ambientes urbanos densos envolve múltiplos objetivos concorrentes, tais como maximizar o acesso de populações vulneráveis, otimizar os benefícios ambientais, assegurar a viabilidade econômica e respeitar restrições territoriais e normativas (Xu et al., 2026; Haloui et al., 2023). Abordagens convencionais de planejamento urbano apresentam limitações na integração simultânea desses critérios, o que pode resultar em distribuições territoriais ineficientes e socialmente assimétricas (El Sayad et al., 2024).

Avanços recentes em inteligência artificial ampliam as possibilidades de enfrentar esses desafios. Métodos baseados em GeoAI (Inteligência Artificial com Georreferenciamento) permitem integrar grandes volumes de dados espaciais, ambientais e socioeconômicos, viabilizando análises preditivas, simulações de cenários e identificação de localizações ótimas sob múltiplos critérios (Adziima et al., 2024). Algoritmos de otimização espacial, estruturas multiobjetivo e técnicas de aprendizado profundo aplicadas à classificação do uso do solo oferecem base técnica para o planejamento orientado por evidências. Paralelamente, estudos recentes sobre GeoAI indicam que a integração entre inteligência artificial e sistemas de informação geográfica amplia a capacidade analítica do planejamento urbano, permitindo identificar padrões complexos, relações não lineares e áreas prioritárias com maior precisão (Janowicz et al., 2022). Apesar desses avanços, observa-se uma lacuna na literatura quanto à construção de modelos conceituais que integrem explicitamente indicadores de qualidade do ar e métricas de vulnerabilidade socioespacial na definição de áreas prioritárias para hortas urbanas.

Diante desse cenário, este artigo busca responder à seguinte questão de pesquisa: como estruturar um modelo conceitual baseado em GeoAI que integre a qualidade do ar e a vulnerabilidade socioespacial para orientar a alocação de hortas urbanas? O objetivo geral consiste em propor um modelo conceitual que articule variáveis ambientais, sociais e territoriais em uma estrutura analítica integrada, capaz de apoiar decisões públicas transparentes e fundamentadas. Como objetivos específicos, pretende-se: (i) identificar as dimensões estruturantes de um modelo viável, (ii) analisar as dificuldades ou entraves à sua aplicação e (iii) explicitar as saídas esperadas em termos de impacto socioambiental. Metodologicamente, o estudo desenvolve uma síntese conceitual da literatura sobre agricultura urbana, poluição atmosférica, planejamento urbano e GeoAI, buscando integrar essas abordagens na construção de um modelo analítico voltado ao apoio à decisão pública. Espera-se que o estudo contribua para o avanço teórico ao integrar dimensões ambientais e de gestão em um único framework conceitual e para a prática de gestão pública, ao oferecer uma base estruturada para a formulação de políticas urbanas orientadas por dados, com foco simultâneo na mitigação de desigualdades e na melhoria da qualidade ambiental urbana.

2. Referencial teórico

2.1 Urbanização, poluição atmosférica e desigualdade socioambiental

A distribuição espacial da poluição atmosférica é fortemente influenciada pelo planejamento urbano e pelo uso da terra. Cidades compactas podem apresentar maior homogeneidade da qualidade do ar, mas tendem a aumentar a exposição populacional devido à maior densidade (Ferreira et al., 2005), enquanto a expansão urbana pode dispersar fontes de emissão e produzir padrões distintos de poluição.

Entre os principais poluentes urbanos destacam-se o PM_{2,5} (material particulado fino, formado por partículas oriundas da combustão veicular, de atividades industriais e da queima de biomassa), NO₂ (dióxido de nitrogênio, que resulta principalmente da queima de combustíveis fósseis) e o SO₂ (dióxido de enxofre, relacionado à combustão de combustíveis com enxofre e à formação de chuva ácida e aerossóis sulfatos). Em conjunto, esses poluentes atmosféricos são relevantes para a degradação ambiental urbana, com impactos diretos e indiretos na qualidade do ar, nos ecossistemas e na sustentabilidade das cidades. A distribuição desses poluentes é influenciada por fatores como a estrutura urbana, os padrões de tráfego e as condições climáticas, que, por sua vez, afetam os níveis de exposição das populações urbanas.

Evidências empíricas identificam relações entre PM_{2,5}, NO₂ e benzeno com doenças respiratórias e cardiovasculares, incluindo aumento de hospitalizações e maior incidência de bronquite e asma (Sharma et al., 2022). Além disso, a poluição do ar apresenta dimensão de justiça ambiental, pois tende a afetar de forma desproporcional populações socialmente vulneráveis. Na Filadélfia, concentrações mais elevadas de PM_{2,5} foram associadas a áreas com maior proporção de população não branca e maior prevalência de asma (Scolio et al., 2024).

A dispersão desses poluentes também é influenciada por fatores climáticos e pela presença de áreas verdes. Em Acra (Gana), níveis elevados de PM_{2,5} foram registrados durante a estação seca (Doe et al., 2025). No Rio de Janeiro, áreas com maior cobertura vegetal apresentaram menores concentrações de material particulado (Moreira Júnior et al., 2022).

2.2 Hortas urbanas como instrumento de política pública verde

As hortas comunitárias ou hortas urbanas, como componentes da política pública verde, oferecem uma infinidade de benefícios socioeconômicos e ambientais nas áreas urbanas. Esses benefícios são cada vez mais reconhecidos no desenvolvimento urbano sustentável, contribuindo para a melhoria da qualidade de vida, da sustentabilidade ambiental e da coesão social. As hortas urbanas não apenas fornecem produtos frescos e aumentam a segurança alimentar, mas também promovem o envolvimento da comunidade e a melhoria da saúde física e mental.

Quanto à segurança alimentar e nutricional, em Bangalore, 96,67% dos jardineiros urbanos relataram a disponibilidade de alimentos frescos como o principal benefício, o que levou ao aumento da economia e à redução dos gastos com frutas e vegetais (Prem Kishor et al., 2024). Isso se alinha com as descobertas de outros estudos que destacam o papel da jardinagem urbana no aumento da segurança alimentar e na redução dos custos de alimentação das famílias (Gómez-Villarino e Briz, 2022). Também incentivam a atividade física e proporcionam um ambiente terapêutico que melhora o bem-estar emocional, atuando na saúde mental e na redução dos níveis de estresse (Otieno e Namiripo, 2019).

A proximidade de espaços verdes bem cuidados, como jardins urbanos, pode aumentar o valor das propriedades e impulsionar os negócios locais. Essa elevação econômica resulta do valor estético e recreativo que esses espaços verdes agregam aos bairros urbanos (Dhumketu et al., 2025). Também aumentam a biodiversidade urbana, fornecendo habitats para várias espécies de plantas e polinizadores, contribuindo para os serviços ecossistêmicos, como o sequestro de carbono, a regulação do microclima e a redução dos efeitos das ilhas de calor urbanas (Dhumketu et al., 2025; Otieno e Namiripo, 2019), o que, de certa forma, também contribui para o entorno. Outro benefício local é que o uso de lixo doméstico nas práticas de jardinagem urbana promove a redução de resíduos e a utilização sustentável de recursos. Isso não só beneficia o meio ambiente, mas também apoia a gestão sustentável dos espaços urbanos (Prem Kishor et al., 2024).

As hortas urbanas criam oportunidades de emprego na gestão de infraestrutura verde e promovem um sentimento de orgulho e engajamento da comunidade. Eles servem como centros sociais que incentivam o envolvimento cívico e a inclusão, fortalecendo, assim, os laços comunitários (Dhumketu et al., 2025; Otieno e Namiripo, 2019). Ainda, como plataformas de interação social e de construção de comunidades. Eles promovem a inclusão ao reunir diversos grupos de pessoas, gerando um sentimento de pertença e de propriedade comunitária (Perdigones et al., 2023; Sia et al., 2023). A distribuição espacial da poluição atmosférica é fortemente influenciada pelo planejamento urbano

2.3. Sistemas de informação geográfica (GIS) e GeoAI na gestão pública

A integração entre Sistemas de Informação Geográfica (GIS) e Inteligência Artificial Geoespacial (GeoAI) tem sido apontada como estratégia promissora para qualificar o gerenciamento público, ao combinar a capacidade de processamento espacial com técnicas avançadas de análise preditiva e de suporte à decisão. Essa convergência amplia a precisão na análise de dados territoriais, aprimora os processos decisórios e favorece o desenvolvimento de sistemas capazes de se adaptar à dinâmica urbana.

Algoritmos de aprendizado de máquina desempenham um papel central nesse processo. Qian et al. (2023) destacam que esses algoritmos identificam padrões complexos em bases urbanas, permitem prever tendências e oferecem soluções otimizadas para problemas de planejamento. No campo da análise espacial automatizada, técnicas de aprendizado profundo, especialmente redes neurais convolucionais, viabilizam a interpretação de imagens de satélite e fotografias em nível de rua para a classificação do uso do solo, a identificação de áreas adequadas e o monitoramento de espaços verdes urbanos (Adziima et al., 2024; Dong et al., 2024).

No âmbito específico da GeoAI, métodos de aprendizado de máquina e de aprendizado profundo são aplicados a tarefas como agrupamento geográfico, classificação espacial e regressão espacial, permitindo a análise de conjuntos de dados geoespaciais complexos (Ahmed, 2024; Ouchra et al., 2023). O uso de imagens aéreas e orbitais, combinado com técnicas de reconhecimento automático de padrões, fortalece aplicações voltadas ao planejamento urbano e ao monitoramento ambiental (Ouchra et al., 2023).

Abordagens baseadas em aprendizado por reforço acrescentam uma dimensão estratégica ao planejamento urbano ao modelá-lo como um processo sequencial de tomada de decisão. Nessa perspectiva, agentes de IA podem aprender estratégias por meio da interação com ambientes simulados, ajustando suas decisões conforme os resultados observados (Márquez-Vera et al., 2023). Complementarmente, a IA generativa e os modelos de linguagem de grande porte (LLM) ampliam as possibilidades de planejamento participativo ao permitir que diferentes atores explorem cenários alternativos e compreendam *trade-offs* de forma acessível (Xu et al., 2026).

A incorporação dessas técnicas ao ambiente GIS potencializa suas aplicações na gestão pública. Sistemas integrados podem combinar dados ambientais, infraestrutura urbana e indicadores sociais para apoiar estratégias sustentáveis de gestão (Kouziokas & Perakis, 2017). Evidências indicam que essa integração contribui para maior eficiência na prestação de serviços públicos, incluindo a resposta a emergências, o planejamento de infraestrutura e o monitoramento territorial (Attah et al., 2024; Nesterenko & Musiienko, 2025).

2.4. Modelagem computacional na gestão e alocação de hortas urbanas

O uso da computação para alocações evoluiu de modelos estatísticos simples para algoritmos avançados de otimização e aprendizado, especialmente em contextos que envolvem múltiplos critérios ambientais e sociais. As principais classes de ferramentas utilizadas nesse contexto são apresentadas a seguir

a) Algoritmos de otimização espacial

A otimização espacial constitui uma das abordagens mais utilizadas para a alocação de hortas urbanas. Algoritmos evolutivos e técnicas metaheurísticas, como algoritmos genéticos (AG), simulam processos de evolução natural para identificar configurações ótimas entre grandes conjuntos de alternativas.

Aosaf et al. (2025) propuseram o modelo CR+DES (Chaotic Randomization associado à Differential Evolution Strategy) para alocação do uso do solo urbano, apresentando desempenho superior aos métodos tradicionais em cenários com múltiplas restrições espaciais. Russell, Atchison e Guhathakurta (2023) aplicaram o modelo Maximal Covering Location Problem (MCLP) para otimizar a implantação de agricultura urbana em Glasgow, elevando a cobertura populacional de 36% para 49% em um raio de 10 minutos a pé. Diversos fatores territoriais são considerados nesses modelos, como declividade, elevação, proximidade de assentamentos, acessibilidade e disponibilidade hídrica (Zaki et al., 2023).

Estruturas de otimização multiobjetivo ampliam essas abordagens ao permitir a consideração simultânea de critérios ambientais, sociais e econômicos. Haloui et al. (2023) propuseram um modelo multicritério baseado no método VIKOR para localização sustentável de fazendas urbanas, enquanto Dong et al. (2024) desenvolveram um sistema integrado de decisão para agricultura urbana em áreas de regeneração urbana. Complementarmente, sistemas baseados em conhecimento podem ser utilizados para identificar automaticamente espaços verdes urbanos a partir de regras espaciais estruturadas (Ismayilova & Timpf, 2024).

b) Aprendizado de máquina e aprendizado profundo

Técnicas de aprendizado de máquina têm sido amplamente empregadas para identificar áreas adequadas à implantação de hortas urbanas por meio da integração de dados ambientais, territoriais e socioeconômicos. Adziima et al. (2024) utilizaram imagens do Google Street View combinadas com algoritmos de visão computacional para avaliar exposição solar, disponibilidade de espaço e uso do solo no entorno urbano, reduzindo custos e tempo em comparação com levantamentos de campo.

Redes neurais convolucionais (CNN) e técnicas de segmentação semântica são utilizadas para mapear padrões de uso do solo, identificar vazios urbanos e detectar áreas potencialmente aptas à agricultura urbana. Zhao et al. (2023) demonstraram que essas técnicas permitem automatizar a detecção de espaços verdes urbanos, enquanto El Sayad et al. (2024) destacam que a integração entre dados geográficos e socioeconômicos melhora a identificação de áreas prioritárias. Sannaki (2025) reporta taxas superiores a 90% na detecção de áreas verdes.

Outras arquiteturas de IA também têm sido exploradas para problemas de alocação territorial. Zhu et al. (2024) combinaram redes neurais gráficas com recozimento simulado para otimizar a distribuição de recursos urbanos, enquanto Zong et al. (2024) integraram modelos de previsão de demanda com análise de acessibilidade espacial para identificar áreas prioritárias.

Ismayilova e Timpf (2024) registraram acurácia próxima de 78% na identificação de espaços verdes urbanos utilizando Random Forest, que se destaca pela robustez em dados geoespaciais multivariados. No campo do sensoriamento remoto, Wagner e Egerer (2022) utilizaram veículos aéreos não tripulados (UAV) combinados a aprendizado de máquina para mapear o uso do solo urbano com alta precisão espacial.

A integração entre Internet das Coisas (IoT) e algoritmos de IA também amplia a dimensão operacional da gestão de hortas urbanas. Dănilă et al. (2024), no projeto U-GARDEN, desenvolveram um sistema baseado em sensores ambientais e algoritmos de decisão para monitoramento e gestão de jardins urbanos.

Além dessas aplicações, abordagens emergentes como aprendizado por reforço e sistemas multiagentes permitem simular interações entre diferentes atores urbanos e avaliar impactos de políticas públicas ao longo do tempo (Qian et al., 2023). Técnicas de IA generativa também têm sido utilizadas para gerar cenários alternativos de planejamento urbano e mapas de equidade territorial, ampliando a comunicação e a participação social nos processos decisórios (Xu et al., 2026).

c) Sistemas de apoio multicritério à decisão

Modelos de decisão multicritério constituem base analítica relevante para problemas de alocação territorial que envolvem múltiplos objetivos e restrições. Algoritmos de otimização multiobjetivo, como NSGA-II, MOPSO e MOEA/D, permitem considerar simultaneamente compatibilidade territorial, adequação do uso do solo e restrições espaciais (Masoumi & van Genderen, 2023).

Aosaf et al. (2025) demonstram o potencial desses métodos como ferramentas de apoio à decisão para planejadores urbanos. Variantes de algoritmos evolutivos, como CR+DES e MSBX+MO, foram desenvolvidas para aprimorar simultaneamente compatibilidade territorial e desempenho econômico. Karpova et al. (2025) propuseram um modelo multiobjetivo integrado a sistemas de informação geográfica que incorpora critérios ambientais, sociais e econômicos em uma estrutura unificada. De forma semelhante, El Sayad et al. (2024) desenvolveram uma abordagem baseada na integração de algoritmos de otimização, modelos preditivos e sistemas de suporte à decisão para agricultura urbana.

Haloui et al. (2024) avançam ao propor uma abordagem em duas fases que combina otimização multiobjetivo com métodos de decisão multicritério, como MARCOS, VIKOR e Possibility Degree, para selecionar soluções de compromisso a partir do conjunto de soluções de Pareto. Esses métodos reduzem o conjunto de alternativas ótimas a opções operacionalizáveis, facilitando sua aplicação no planejamento urbano.

Assim, os modelos de otimização multiobjetivo e as técnicas de decisão multicritério configuram um framework metodológico robusto para alocação de hortas urbanas, especialmente quando se busca equilibrar simultaneamente critérios ambientais, sociais, econômicos e espaciais em políticas públicas orientadas por dados.

3 Dimensões estruturantes de um modelo viável de implantação de hortas urbanas

A implantação de hortas urbanas, sob a perspectiva de políticas públicas, exige a consideração de requisitos que condicionam tanto a viabilidade técnica quanto a sustentabilidade de longo prazo das iniciativas, bem como os retornos esperados. A literatura recente demonstra que tais requisitos devem ser incorporados desde a fase de planejamento territorial, sendo utilizados como entradas nos modelos de análise espacial e de multicritério.

Quanto às **características físicas e ambientais**, o primeiro conjunto de requisitos refere-se às condições do terreno e à seleção do sítio. A disponibilidade de áreas adequadas constitui uma condição estruturante para a implantação de hortas urbanas. Estudos indicam parâmetros mínimos de área que variam conforme a tipologia da horta e o contexto urbano (Mack et al., 2017; Eanes et al., 2015). Inclinações de até 20% são consideradas adequadas para garantir acessibilidade, facilitar o manejo e reduzir problemas relacionados ao escoamento superficial (Eanes et al., 2015; Zaki et al., 2023).

Outro requisito fundamental refere-se à qualidade do solo e à avaliação de possíveis contaminações. Em áreas urbanas, os solos frequentemente apresentam presença de metais pesados ou resíduos industriais, tornando necessária a realização de análises prévias antes da implantação das hortas (Moore et al., 2013; Anushi et al., 2024). As características edáficas influenciam diretamente a adequação do sítio, podendo inclusive ser incorporadas a modelos de suporte à decisão baseados em dados espaciais (Sonneveld et al., 2021). Nesse contexto, variáveis como fertilidade do solo, histórico de uso da terra e presença de contaminantes são frequentemente consideradas em análises de adequação territorial (Sonneveld et al., 2021; Zaki et al., 2023).

A proximidade de infraestrutura hídrica (disponibilidade e a gestão da água) é frequentemente incorporada como variável em modelos de adequação espacial, uma vez que influencia diretamente a viabilidade e os custos operacionais das hortas urbanas (Eanes et al., 2015; Zaki et al., 2023; Sonneveld et al., 2021). Sauter (2014) observa que a proximidade a pontos de abastecimento de água aumenta significativamente a probabilidade de manutenção das hortas ao longo do tempo. Além disso, políticas municipais de acesso gratuito ou subsidiado à água podem ser determinantes para a sustentabilidade econômica de iniciativas comunitárias de agricultura urbana (Ward, 2015).

No campo das condições microclimáticas e a exposição solar, a disponibilidade de radiação solar influencia diretamente a produtividade agrícola, sendo recomendada a presença de pelo menos oito horas diárias de insolação plena para a maioria das culturas alimentares (Eanes et al., 2015). Tecnologias como LiDAR e modelos digitais de superfície podem auxiliar na análise de sombreamento urbano e na identificação de áreas adequadas à produção agrícola. Além disso, o monitoramento em tempo real de

variáveis ambientais, como temperatura, umidade e qualidade do ar, pode contribuir para a gestão adaptativa das hortas e para a prevenção de doenças em plantas (Dănilă et al., 2024; Streche et al., 2024).

Nesse contexto, a qualidade do ar também emerge como variável relevante para o planejamento territorial das hortas urbanas. A concentração de poluentes atmosféricos, frequentemente associada a padrões de segregação socioespacial, pode produzir situações de injustiça ambiental que afetam de maneira mais intensa populações de baixa renda (UN-Habitat, 2022; WHO, 2023). Indicadores como a concentração de NO₂, SO₂ e material particulado fino (PM_{2.5}), bem como a densidade de fontes emissoras, permitem identificar áreas com maior exposição populacional a poluentes atmosféricos, contribuindo para orientar decisões de planejamento urbano mais equitativas.

Por fim, a acessibilidade espacial e a inserção territorial também devem ser consideradas na definição de áreas prioritárias para hortas urbanas. A proximidade a áreas residenciais aumenta a probabilidade de uso efetivo desses espaços, favorecendo a participação comunitária e o acesso a alimentos frescos (Senes et al., 2016). Estudos indicam que análises baseadas em acessibilidade pedonal, especialmente em raios de até 15 minutos de caminhada, podem orientar políticas distributivas mais equitativas na implantação de equipamentos urbanos e espaços verdes (Limerick et al., 2023).

Outro conjunto de requisitos refere-se às **características sociais e comunitárias**, que influenciam diretamente a viabilidade e a continuidade das hortas urbanas. Um primeiro elemento central é o engajamento comunitário desde as etapas iniciais de planejamento. Moore et al. (2013) destacam a importância da realização de diagnósticos participativos e de consultas à comunidade para alinhar o projeto às necessidades locais. De forma semelhante, Codato et al. (2021) demonstram que a incorporação de critérios definidos pelos próprios moradores em modelos participativos de decisão multicritério amplia a legitimidade das decisões espaciais e fortalece o compromisso coletivo com a gestão da horta.

O interesse sustentado pela população, com estrutura de governança e estrutura local (Milburn e Vail, 2010) e a presença de atores-chave, em geral, voluntários engajados (Lu, 2022), são importantes sobretudo na fase de manutenção e consolidação das hortas. Além disso, a capacidade organizacional e institucional da comunidade (Carrad et al., 2023), através do apoio de governos locais que pode assumir diferentes formas, incluindo assessoramento técnico, mediação institucional e disponibilização de recursos constitui outro fator relevante. Entretanto, a efetividade desse suporte depende da existência de estruturas comunitárias capazes de dialogar com o poder público como afirmam Egerer et al. (2024) ao concluir que hortas comunitárias podem tornar-se vulneráveis quando ocorre descontinuidade do envolvimento comunitário ou quando há ausência de reconhecimento institucional.

Nesse sentido, a formalização de associações ou grupos gestores tende a facilitar a celebração de termos de cooperação, o acesso a programas públicos e a captação de recursos.

A literatura também destaca a importância da inclusão social e da equidade territorial na definição de áreas prioritárias para hortas urbanas. Codato et al. (2021) argumentam que a localização desses espaços deve considerar indicadores demográficos e socioeconômicos, buscando atender populações em situação de maior vulnerabilidade. Estudos baseados em análises de acessibilidade indicam que a distribuição espacial das hortas pode reproduzir desigualdades urbanas quando não são considerados critérios distributivos (Limerick et al., 2023). Nesse sentido, Sonneveld et al. (2021), ao desenvolverem um modelo de adequação territorial para cidades do Benin, incorporam variáveis sociais específicas, incluindo aspectos relacionados à segurança das mulheres.

Outro aspecto frequentemente destacado é o papel das hortas urbanas na formação de capital social. Twiss et al. (2003) demonstram que hortas comunitárias funcionam como espaços de organização social, aprendizagem coletiva e fortalecimento da coesão comunitária. De forma convergente, Janowska et al. (2022) observam que esses espaços favorecem a integração intergeracional e intercultural, ampliando o potencial das hortas como infraestruturas sociais urbanas voltadas à participação cívica e à construção de redes comunitárias.

A educação e o desenvolvimento de competências também aparecem como elementos relevantes para a sustentabilidade das iniciativas. Programas de capacitação em agricultura urbana contribuem para ampliar o conhecimento técnico dos participantes e fortalecer o empoderamento comunitário (Awang et al., 2024; Khan et al., 2024).

O terceiro grupo de requisitos, denominado **requisitos regulatórios e institucionais**, são os que garantem a segurança jurídica, a previsibilidade administrativa e a continuidade das iniciativas. O primeiro requisito refere-se à segurança da posse e ao regime de uso da terra, estruturante para o sucesso das hortas comunitárias segundo Milburn e Vail (2010). Egerer et al. (2024) argumentam que a vulnerabilidade das hortas decorre frequentemente de contratos precários ou do uso temporário de áreas sujeitas à pressão imobiliária, e Carrad et al. (2023) demonstram que governos locais atuam como “*gatekeepers*”, sendo responsáveis por formalizar termos de cessão, licenças ou acordos de uso.

O segundo requisito envolve a compatibilidade com o zoneamento urbano e com as normas de uso do solo (Senes et al., 2016). Twiss et al. (2003) relatam experiências em que políticas municipais criaram dispositivos de uso temporário de terrenos vagos, reduzindo barreiras regulatórias. Ward (2015) evidencia que políticas de água e regulamentações locais podem tanto favorecer quanto dificultar a implantação de hortas.

A clareza procedimental e a redução da burocracia podem colaborar. Carrad et al. (2023) apontam que a ausência de procedimentos padronizados dificulta a interação entre as comunidades e o poder público. Moore et al. (2013) ressaltam a importância de orientação institucional clara sobre autorizações, responsabilidades e requisitos técnicos.

Outro requisito diz respeito ao apoio institucional contínuo através de programas governamentais estruturados e permanentes que oferecem suporte técnico e material à agricultura urbana (Awang et al., 2024) em programas permanentes. Carrad et al. (2023) observam que o suporte governamental pode abranger cessão de água, assistência técnica, capacitação e financiamento. Destaca-se que a implantação de hortas envolve múltiplas áreas da administração pública, como planejamento urbano, meio ambiente, saúde, assistência social e educação, portanto a integração intersetorial existe a articulação entre diferentes políticas setoriais (Khan et al., 2024). Na mesma linha, a proteção normativa contra remoções arbitrárias constitui uma dimensão a ser consideradas no arcabouço regulatório. Em contextos de valorização imobiliária, hortas comunitárias podem ser deslocadas sem mecanismos compensatórios. A incorporação dessas áreas em instrumentos urbanísticos específicos, como zonas de interesse ambiental ou alimentar, pode mitigar esse risco.

Por fim, a produção e sistematização de dados institucionais fortalecem a formulação de políticas baseadas em evidências pois a ausência de dados dificulta a avaliação dos resultados e a consolidação normativa, com citado por Egerer et al. (2024) que defendem a necessidade de reconhecimento formal das hortas como infraestrutura urbana, com monitoramento sistemático de seus impactos sociais e ambientais.

O Quadro 1 sintetiza os principais requisitos identificados na literatura e suas implicações para políticas públicas, destacando a necessidade de integração entre o planejamento territorial, a governança comunitária e o arcabouço institucional.




Quadro 1 – Requisitos para implantação de hortas urbanas e implicações para a gestão pública

Dimensão	Requisito	Fontes	Demandas para a gestão pública
Física e ambiental	Área mínima adequada	Mack et al. (2017); Eanes et al. (2015)	Mapear áreas públicas subutilizadas; estabelecer parâmetros mínimos em normativas municipais
	Declividade $\leq 20\%$	Eanes et al. (2015); Zaki et al. (2023)	Incorporar análise topográfica em SIG no planejamento urbano
	Qualidade e segurança do solo	Moore et al. (2013); Sonneveld et al. (2021); Anushi et al. (2024);	Instituir protocolos obrigatórios de análise de solo e programas de remediação
	Acesso à água	Eanes et al. (2015); Ward (2015); Zaki et al. (2023)	Integrar política hídrica à agricultura urbana; incentivar captação de água da chuva
	Insolação mínima ($\approx 8h/dia$) Condições microclimáticas	Eanes et al. (2015) Dănilă et al., 2024 (Streche et al., 2024)	Utilizar dados de radiação solar e sombreamento em análises territoriais. Avaliar condições microclimáticas
	Qualidade do ar	UN-Habitat, 2022; WHO, 2023	Analisar a concentração de poluentes atmosféricos
Social e comunitária	Engajamento comunitário	Moore et al. (2013); Codato et al. (2021)	Realizar consultas públicas e oficinas participativas
	Liderança local estruturada	Milburn & Vail (2010); Lu (2022)	Oferecer capacitação e definir estruturas de governança
	Inclusão e equidade territorial	Codato et al. (2021); Limerick et al. (2023); Sonneveld et al. (2021)	Priorizar áreas vulneráveis e incorporar critérios socioeconômicos na seleção
	Formação de capital social	Twiss et al. (2003); Janowska et al. (2022)	Integrar hortas a programas de saúde, educação e assistência social
Regulatória e institucional	Segurança da posse da terra	Milburn & Vail (2010); Egerer et al. (2024); Carrad et al. (2023)	Formalizar termos de cessão ou concessão administrativa de longo prazo
	Compatibilidade com zoneamento	Senes et al. (2016); Twiss et al. (2003)	Revisar plano diretor e códigos de uso do solo para incluir agricultura urbana
	Simplificação burocrática	Carrad et al. (2023); Moore et al. (2013)	Criar fluxos administrativos simplificados e guias normativos
	Apoio governamental estruturado	Awang et al. (2024); Hodgson et al. (2011)	Instituir programas municipais permanentes de agricultura urbana
	Integração intersetorial	Khan et al. (2024); Carrad et al. (2023)	Criar comissões intersetoriais envolvendo planejamento, meio ambiente e saúde

A integração dessas categorias em ambiente SIG associado à Análise Multicritério de Decisão possibilita a geração de mapas de adequação territorial e a simulação de cenários alternativos de implantação. Tal abordagem fortalece a racionalidade técnica da política pública, tornando explícitos os critérios adotados e permitindo maior transparência e replicabilidade no planejamento de hortas urbanas.

Com base nas dimensões discutidas, física-ambiental, social-comunitária, regulatória-institucional e analítica, propõe-se um framework integrador que relaciona entradas (inputs), processos decisórios e saídas (outputs) no contexto da formulação de políticas públicas para hortas urbanas, apresentado na Figura 1.

Figura 1: Framework integrador



O framework proposto estrutura o processo de alocação de hortas urbanas como um fluxo integrado entre entradas multidimensionais, mecanismos de processamento técnico-institucional e saídas territoriais e socioambientais, articulando evidências empíricas e instrumentos de política pública.

Na dimensão das entradas, o modelo incorpora variáveis ambientais (como área disponível, declividade, qualidade e contaminação do solo, insolação e disponibilidade hídrica) que condicionam a viabilidade biofísica da implantação (Eanes et al., 2015; Zaki et al., 2023; Moore et al., 2013; Sonneveld et al., 2021; Ward, 2015). Integra, ainda, variáveis territoriais e regulatórias, incluindo zoneamento, titularidade e instrumentos legais de cessão, assegurando a compatibilidade normativa e a segurança jurídica (Senes et al., 2016; Milburn & Vail, 2010; Egerer et al., 2024; Carrad et al., 2023). A essas dimensões somam-se variáveis socioeconômicas (densidade populacional, indicadores de vulnerabilidade, acesso a alimentos e critérios de equidade territorial) que orientam a priorização distributiva (Limerick et al., 2023; Codato et al., 2021), bem como elementos de infraestrutura urbana e governança, tais como proximidade a redes viárias, acesso à água, equipamentos públicos, participação comunitária, liderança local e pesos atribuídos aos critérios (Eanes et al., 2015; Moore et al., 2013; Lu, 2022; Smith et al., 2021).

Essas entradas são processadas por ferramentas analíticas e mecanismos institucionais (notadamente SIG, Análise Multicritério de Decisão, modelos estatísticos de adequação espacial e processos participativos de deliberação) que permitem estruturar trade-offs, simular cenários e explicitar critérios decisórios (Sonneveld et al., 2021; Codato et al., 2021).

O resultado desse processamento se materializa em dois níveis de saídas: (i) espaciais, por meio de mapas de adequação, priorização de áreas e cenários alternativos de implantação; e (ii) institucionais, com a formalização jurídica da posse, a inclusão da agricultura urbana no plano diretor e a estruturação de programas municipais. Os impactos do uso do modelo se dão na dimensão socioambiental, refletidos na ampliação do acesso a alimentos, na redução das desigualdades territoriais, no fortalecimento do capital social e na geração de benefícios ambientais locais. Assim, o framework organiza a tomada de decisão pública de forma transparente e replicável, convertendo dados ambientais e sociais em intervenções territoriais orientadas por critérios explícitos de sustentabilidade e equidade.

4. Empecilhos na constituição de um sistema para alocação de hortas urbanas com base em GeoAI e ferramentas avançadas de inteligência artificial

Embora o potencial analítico das tecnologias seja amplamente reconhecido, a literatura aponta limitações que podem comprometer tanto a viabilidade operacional quanto a legitimidade pública das decisões automatizadas.

Um primeiro obstáculo refere-se à qualidade e consistência dos dados. Modelos de IA dependem fortemente de bases georreferenciadas atualizadas, padronizadas e confiáveis. Problemas como dados incompletos, desatualizados, de baixa resolução espacial ou inconsistências entre bases distintas podem gerar inferências equivocadas e mapas de adequação territorial imprecisos. Attah et al. (2024) destacam que falhas na qualidade dos dados comprometem a robustez dos resultados, enquanto Hosen et al. (2023) enfatizam a necessidade de uma infraestrutura tecnológica capaz de integrar grandes volumes de dados heterogêneos. A ausência de padronização dos formatos também afeta a confiabilidade do processo decisório.

Além das limitações técnicas, emergem riscos associados ao viés algorítmico. Sistemas de IA treinados com dados históricos podem reproduzir e amplificar desigualdades pré-existentes, especialmente quando utilizam indicadores socioeconômicos ou padrões territoriais que refletem segregações estruturais. Hsu (2025) alerta que decisões automatizadas no planejamento urbano podem reforçar padrões de exclusão se não houver mecanismos explícitos de controle e auditoria. Marasinghe et al. (2024) ressaltam que a ausência de avaliação distributiva nos modelos pode gerar impactos desproporcionais sobre grupos vulneráveis. No contexto da alocação de hortas urbanas, isso poderia resultar na priorização de áreas com maior visibilidade política ou melhor infraestrutura, em detrimento de territórios mais vulneráveis socioambientalmente.

Outro desafio relevante é a opacidade decisória. Modelos complexos de aprendizado profundo e de otimização multiobjetivo podem operar como “caixas pretas”, dificultando a compreensão pública dos critérios efetivamente utilizados. Xu et al. (2026) indicam que limitações relacionadas à geração de informações incorretas e à baixa transparência podem comprometer a accountability institucional. Em ambientes de gestão pública, em que a legitimidade depende de clareza e justificabilidade, decisões baseadas em modelos pouco interpretáveis podem gerar resistência social e questionamentos jurídicos.

A infraestrutura computacional e a capacidade técnica institucional também constituem barreiras importantes. Projetos de GeoAI exigem servidores adequados, capacidade de processamento, softwares especializados e equipes qualificadas. Attah et al. (2024) destacam que restrições financeiras e técnicas frequentemente limitam a adoção dessas tecnologias, especialmente em municípios de médio e pequeno porte. A ausência de profissionais capacitados em ciência de dados e geoprocessamento pode comprometer tanto a implementação quanto a manutenção dos sistemas.

Questões relacionadas à privacidade e proteção de dados constituem outro entrave. A integração de dados demográficos, socioeconômicos e ambientais pode envolver informações sensíveis, o que exige conformidade com as legislações de proteção de dados. Attah et al. (2024) alertam que falhas na governança de dados podem acarretar riscos legais e reputacionais para a administração pública. Em projetos que utilizam dados de vulnerabilidade social, a anonimização e o uso ético das informações tornam-se requisitos indispensáveis.

Do ponto de vista institucional, a resistência burocrática à inovação pode comprometer a adoção de soluções baseadas em IA. Sistemas administrativos tradicionais tendem a operar com procedimentos consolidados e estruturas hierárquicas rígidas. A introdução de modelos analíticos avançados pode ser percebida como uma ameaça às práticas estabelecidas ou à autonomia decisória dos gestores. Attah et al. (2024) argumentam que a superação dessas barreiras requer modelos de governança colaborativa e maior engajamento das partes interessadas. Na mesma linha, a excessiva dependência tecnológica pode reduzir a dimensão participativa do planejamento urbano. Embora a IA ofereça suporte analítico relevante, decisões sobre alocação de hortas urbanas envolvem valores normativos e prioridades sociais

que não podem ser plenamente capturados por algoritmos. A ausência de processos participativos pode enfraquecer a legitimidade da política pública, ainda que tecnicamente fundamentada.

Por fim, há desafios relacionados à sustentabilidade de longo prazo do sistema. Projetos de IA exigem atualização constante de dados, recalibração de modelos e manutenção de infraestrutura. A falta de recursos contínuos pode levar à obsolescência do sistema, tornando investimentos iniciais em soluções subutilizadas.

Considerando a relação entre dificuldades, superá-las demanda não apenas avanços tecnológicos, mas também marcos regulatórios claros, mecanismos de auditoria algorítmica, capacitação técnica, participação social estruturada e modelos colaborativos de governança. Somente com essa abordagem integrada será possível assegurar que a IA contribua efetivamente para políticas urbanas mais equitativas, transparentes e ambientalmente sustentáveis.

5. Conclusão

Este artigo teve como objetivo geral propor um modelo conceitual para o uso de GeoAI na alocação de hortas urbanas, integrando indicadores de qualidade do ar e de vulnerabilidade socioespacial como base para decisões públicas orientadas por evidências. Em resposta à questão de pesquisa, o estudo estruturou um *framework* que organiza a tomada de decisão a partir de entradas multidimensionais, de mecanismos de processamento técnico-institucional e de saídas territorialmente explícitas, com impactos socioambientais esperados.

O primeiro objetivo específico, de identificar as dimensões estruturantes de um modelo viável, foi atendido ao sistematizar cinco blocos de entradas: variáveis ambientais (solo, declividade, insolação, água e poluição do ar), variáveis territoriais e regulatórias (zoneamento, titularidade e instrumentos de cessão), variáveis socioeconômicas (vulnerabilidade, densidade e acesso a alimentos), infraestrutura urbana e governança participativa.

O segundo objetivo específico, relativo à análise de dificuldades e entraves, foi contemplado ao discutir limitações relacionadas à qualidade e à padronização de dados, viés algorítmico, opacidade decisória, restrições de infraestrutura e de capacidade técnica institucional, além de desafios de privacidade, resistência burocrática e sustentabilidade de longo prazo do sistema.

O terceiro objetivo específico, de explicitar as saídas esperadas, foi atendido ao caracterizar saídas espaciais (mapas de adequação, priorização e cenários), institucionais (formalização jurídica, incorporação no plano diretor e programas municipais) e impactos socioambientais (segurança alimentar, redução de desigualdades, fortalecimento do capital social e benefícios ambientais locais), evidenciando como o modelo pode transformar decisões oportunistas em políticas estruturadas.

As contribuições teóricas do estudo concentram-se em três aspectos principais. Primeiro, ao integrar explicitamente a qualidade do ar e a vulnerabilidade socioespacial a um modelo conceitual de alocação de hortas, o artigo aproxima o debate de GeoAI do campo da justiça ambiental, inserindo a dimensão distributiva como componente estrutural do planejamento. Segundo, ao organizar requisitos físicos, sociais e regulatórios como “entradas” formalizadas, o trabalho contribui para a sistematização de um vocabulário analítico aplicável a modelos GIS-MCDA e a abordagens híbridas de IA, favorecendo a replicabilidade e a comparabilidade entre estudos. Terceiro, ao incluir a discussão dos entraves como parte constitutiva do modelo conceitual, o artigo reforça uma agenda de pesquisa que articula desempenho técnico com governança, transparência e accountability em sistemas públicos baseados em IA.

Do ponto de vista prático e gerencial, o *framework* oferece um roteiro para que gestores públicos estruturem programas municipais de agricultura urbana com maior racionalidade técnica e legitimidade social. A principal contribuição aplicada consiste em explicitar como diferentes conjuntos de dados e critérios podem ser organizados em um fluxo decisório transparente, apoiado por SIG, MCDA e processos participativos, resultando em mapas e cenários auditáveis. Além disso, o estudo indica demandas concretas para a gestão pública, como padronização e governança de dados, protocolos de

análise de solo e água, inclusão normativa da agricultura urbana no planejamento urbano, instrumentos jurídicos que assegurem a posse e a continuidade das hortas, e mecanismos de participação social para definição de pesos e prioridades. Em paralelo, a discussão dos riscos reforça a necessidade de auditoria algorítmica, mitigação de vieses, proteção de dados e capacitação técnica institucional como condições para adoção responsável de GeoAI.

Como implicação final, argumenta-se que o uso de GeoAI na alocação de hortas urbanas é mais promissor quando concebido como política pública integrada, e não como solução tecnológica isolada. O modelo proposto sugere que a efetividade depende da articulação entre critérios ambientais (incluindo poluição atmosférica), metas de equidade socioespacial, viabilidade regulatória e mecanismos participativos. Estudos futuros podem avançar na operacionalização empírica do framework, testando sua aplicação em cidades específicas, comparando diferentes estratégias de ponderação e avaliando, de forma longitudinal, os efeitos das hortas sobre indicadores ambientais e sociais.

Agradecimentos

Os autores agradecem ao CNPq – Conselho Nacional de Desenvolvimento Científico e Tecnológico pelo apoio financeiro a esta pesquisa (Processo nº 444773/2024-0).

Referências:

- Adziima, A., et al. (2024). Assessing urban agriculture potential using street-level imagery and computer vision techniques. *Urban Forestry & Urban Greening*, 93, 128046. <https://doi.org/10.1016/j.ufug.2024.128046>
- Ahmed, S. (2024). GeoAI applications for urban spatial analysis and planning. *ISPRS International Journal of Geo-Information*, 13 (2), 58. <https://doi.org/10.3390/ijgi13020058>
- Anushi, S., et al. (2024). Soil contamination assessment for urban agriculture: Environmental risks and planning implications. *Environmental Monitoring and Assessment*, 196 (4), 301. <https://doi.org/10.1007/s10661-024-12501-4>
- Aosaf, S., Nayeem, M. A., Haque, A., & Rahman, M. S. (2025). Computational Intelligence based Land-use Allocation Approaches for Mixed Use Areas. *arXiv.Org*, *abs/2508.15240*. <https://doi.org/10.48550/arxiv.2508.15240>
- Attah, R. U., Garba, B. M. P., Gil-Ozoudeh, I., & Iwuanyanwu, O. (2024). Leveraging geographic information systems and data analytics for enhanced public sector decision-making and urban planning. *Magna Scientia Advanced Research and Reviews*, 12 (2), 152–163. <https://doi.org/10.30574/msarr.2024.12.2.0191>
- Awang, A., et al. (2024). Urban agriculture development and community empowerment through local government initiatives. *Sustainability*, 16 (5), 2017. <https://doi.org/10.3390/su16052017>
- Carrad, N., Hand, M., McIntyre, B., & Friel, S. (2023). Local government roles in supporting urban agriculture and food system transformation. *Urban Agriculture & Regional Food Systems*, 8 (1), e20199. <https://doi.org/10.1002/uar2.20199>
- Codato, D., Fregonese, A., & Giupponi, C. (2021). Participatory multicriteria decision analysis for urban green infrastructure planning. *Sustainable Cities and Society*, 66, 102680. <https://doi.org/10.1016/j.scs.2020.102680>
- Dănilă, A., Streche, R., Orza, O., Dobre, C., & Suci, G. (2024). Advanced solution for urban gardens based on IoT systems, prediction algorithms and multi-criteria application. *Romanian Journal of Ecology & Environmental Chemistry*, 6 (2), 101–108. <https://doi.org/10.21698/rjeec.2024.210>
- Dhumketu, R., Baghel, Y., Dixit, A., Krishan, N., & Khare, P. B. (2025). A Review on Urban Green Space Ecological and Socioeconomic Benefits: A Comprehensive Analysis. *International Journal of Environment and Climate Change*, 15 (9), 211–220. <https://doi.org/10.9734/ijecc/2025/v15i95007>
- Doe, E. K., Houteta, D. K., Amekugbe, M. A. S., Kong'ani, L. N. S., Bbuye, M., Egyir, S., Schandorf, P. N. O., Lartey, D. L., Puoyang Dordaa, S. D. D., Boahen, E., Fosu-Mensah, B. Y., Jack, C., & Gordon, C. (2025). Predicting the Geospatial Distribution of Urban Population Health Risks Based on Air Pollutants, Climate, and Health Facilities in African Cities. <https://doi.org/10.5194/egusphere-egu25-9363>
- Dong, J., et al. (2024). Integrated decision-making of urban agriculture within the greyfield regeneration environments (UAGR). *Buildings*, 14 (5), 1415. <https://doi.org/10.3390/buildings14051415>

- Eanes, F. R., Clarke, L. W., & Wang, X. (2015). Integrating urban agriculture into urban planning: A GIS-based analysis of community garden site suitability. *Landscape and Urban Planning*, 139, 19–28. <https://doi.org/10.1016/j.landurbplan.2015.02.009>
- Egerer, M., Lin, B. B., Kingsley, J., Marsh, P., Diekmann, L., Ossola, A., & Locke, D. H. (2024). Urban gardens as social-ecological systems: Governance, resilience, and sustainability. *Urban Forestry & Urban Greening*, 87, 127925. <https://doi.org/10.1016/j.ufug.2023.127925>
- El Sayad, I., Sidhu, H. S., Kundan, M., Glaros, A., & Pizzirani, S. (2024). *AI-Driven Optimization for Urban and Vertical Agriculture Planning: A Multi-Model Approach*. 1–6. <https://doi.org/10.1109/icecce63537.2024.10823499>
- Ferreira, J., Martins, H., Miranda, A. I., & Borrego, C. (2005). *Population Exposure To Atmospheric Pollutants: The Influence Of Urban Structure*. 85. <https://doi.org/10.2495/EEH050021>
- Girotti, C., Oliveira, M. C. Q. D., Sato, A. E., Chiquetto, J. B., Santos, A. P., de Miranda, R. M., ... & Lopez, J. M. R. (2024). Urban mobility and air pollution at the neighbourhood scale in the Megacity of São Paulo, Brazil. *Discover Cities*, 1(1), 13.
- Gómez-Villarino, M. T., & Briz, T. (2022). With sustainable use of local inputs, urban agriculture delivers community benefits beyond food. *California Agriculture*, 1–10. <https://doi.org/10.3733/ca.2022a0013>
- Haloui, I., et al. (2023). A multi-criteria decision-making approach for the sustainable location of urban farms: Towards farming 4.0. *Proceedings of the International Conference on Control, Decision and Information Technologies (CoDIT)*. <https://doi.org/10.1109/codit58514.2023.10284336>
- Haloui, I., et al. (2024). Sustainable urban farming using a two-phase multi-objective and multi-criteria decision-making approach. *International Transactions in Operational Research*. <https://doi.org/10.1111/itor.13460>
- Hosen, B., Rahaman, M., Kumar, S., Sagar, L., & Akhtar, Md. N. (2023). *Leveraging artificial intelligence and big data for advanced spatial analytics and decision support systems in geography*. <https://doi.org/10.26480/magg.02.2023.62.67>
- Hsu, A. (2025). From pixels to progress: Advancing urban environmental justice in the AI era. <https://doi.org/10.1093/9780198945215.003.0023>
- Ismayilova, I., & Timpf, S. (2024). Knowledge-Based Identification of Urban Green Spaces: Allotments. *AGILE: GIScience Series*, 5, 1–8. <https://doi.org/10.5194/agile-giss-5-8-2024>
- Janowicz, K., Gao, S., McKenzie, G., Hu, Y., & Bhaduri, B. (2022). GeoAI: Spatially explicit artificial intelligence techniques for geographic knowledge discovery and spatial reasoning. *International Journal of Geographical Information Science*, 36 (2), 213–221. <https://doi.org/10.1080/13658816.2021.1965415>
- Janowska, M., Borysiak, J., & Kaczmarek, T. (2022). Community gardens as spaces of social inclusion and environmental learning in urban areas. *Sustainability*, 14 (9), 5216. <https://doi.org/10.3390/su14095216>
- Moreira Junior, D.P., Bueno, C. & da Silva, C.M. The Effect of Urban Green Spaces on Reduction of Particulate Matter Concentration. *Bull Environ Contam Toxicol* 108, 1104–1110 (2022). <https://doi.org/10.1007/s00128-022-03460-3>
- Karpova, Y., Villa, F., Vallada, E., & Pan, W. A. (2025). A Multi-Objective Model in Combination with Geographic Information System Tools for the Location of Urban Green Areas. *Mathematics*, 13 (12), 2006. <https://doi.org/10.3390/math13122006>
- Khan, M., Ahmad, S., & Rahman, M. (2024). Urban agriculture, food security and sustainability: Policy perspectives from rapidly urbanizing cities. *Journal of Urban Affairs*, 46 (2), 298–314. <https://doi.org/10.1080/07352166.2023.2197854>
- Kouziokas, G. N., & Perakis, K. (2017). Decision Support System Based on Artificial Intelligence, GIS and Remote Sensing for Sustainable Public and Judicial Management. *European Journal of Sustainable Development*, 6 (3), 397–404. <https://doi.org/10.14207/EJSD.2017.V6N3P397>
- Limerick, K., Heidkamp, C. P., & Ross, C. (2023). Accessibility analysis of community gardens in urban environments: A GIS-based approach. *Landscape and Urban Planning*, 233, 104703. <https://doi.org/10.1016/j.landurbplan.2023.104703>
- Lu, Y. (2022). Community gardens and civic participation in urban China: Evidence from Beijing and Shanghai. *Cities*, 124, 103620. <https://doi.org/10.1016/j.cities.2022.103620>
- Mack, E. A., Tong, D., & Credit, K. (2017). Gardening in the city: The spatial distribution of community gardens and their relationship with socioeconomic characteristics. *Urban Forestry & Urban Greening*, 24, 72–80. <https://doi.org/10.1016/j.ufug.2017.03.006>

- Marasinghe, A., et al. (2024). Towards responsible urban geospatial AI: Insights from the white and grey literatures. *Journal of Geovisualization and Spatial Analysis*. <https://doi.org/10.1007/s41651-024-00184-2>
- Masoumi, Z., & van Genderen, J. L. (2023). Artificial intelligence for sustainable development of smart cities and urban land-use management. *Geo-Spatial Information Science*, 1–25. <https://doi.org/10.1080/10095020.2023.2184729>
- Milburn, L. S., & Vail, B. (2010). Sowing the seeds of success: Cultivating a future for community gardens. *Landscape Journal*, 29 (1), 71–89. <https://doi.org/10.3368/lj.29.1.71>
- Moore, S., et al. (2013). Community gardens as health interventions: A systematic review. *Health Promotion International*, 28 (3), 403–412. <https://doi.org/10.1093/heapro/das038>
- Nesterenko, S., & Musiienko, K. (2025). *Methods of neural network modeling and artificial intelligence in the development and operation of municipal geographic information systems*. <https://doi.org/10.46299/979-8-89814-216-2>
- Otieno, B. A., & Namiripo, D. B. (2019). The multifaceted impact of urban gardening for enhancing environment, health, and community. *Australian Herbal Insight*, 2 (1), 1–5. <https://doi.org/10.25163/ahi.219907>
- Ouchra, H., et al. (2023). Machine learning methods for geospatial data analysis in urban environments. *ISPRS International Journal of Geo-Information*, 12 (7), 270. <https://doi.org/10.3390/ijgi12070270>
- Perdigones, A., Mazarrón, F. R., & García, J. L. (2023). Green areas to introduce sustainability and social responsibility: Training on Agenda 2030. In *Considerations on Education for Economic, Social, and Environmental Sustainability* (pp. 20). IGI Global. <https://doi.org/10.4018/978-1-6684-8356-5.ch008>
- Prem Kishor, S., et al. (2024). Growing green: A comprehensive study on the diverse benefits of urban nutri-gardens in sustainable urban development. *International Journal of Advanced Biochemistry Research*. <https://doi.org/10.33545/26174693.2024.v8.i1f.492>
- Qian, C., et al. (2023). AI agent as urban planner: Steering stakeholder dynamics in urban planning via consensus-based multi-agent reinforcement learning. *arXiv*. <https://doi.org/10.48550/arxiv.2310.16772>
- Russell, S. E., Atchison, C. L., & Guhathakurta, S. (2023). Equalizing urban agriculture access in Glasgow: A spatial optimization approach. *International Journal of Applied Earth Observation and Geoinformation*. <https://doi.org/10.1016/j.jag.2023.103525>
- Sannaki, M. (2025). AI-Powered Urban Green Space Detection and Analysis Using Deep Learning and GIS. *International Scientific Journal of Engineering and Management*, 04 (06), 1–9. <https://doi.org/10.55041/isjem04664>
- Sauter, M. (2014). Urban agriculture and water management: Challenges and policy implications. *Urban Water Journal*, 11 (7), 553–565. <https://doi.org/10.1080/1573062X.2013.826237>
- Scolio, M., Borha, C., Kremer, P., & Shakya, K. M. (2024). Spatial Analysis of Intra-Urban Air Pollution Disparities through an Environmental Justice Lens: A Case Study of Philadelphia, PA. *Atmosphere*, 15 (7), 755. <https://doi.org/10.3390/atmos15070755>
- Senes, G., Fumagalli, N., & Toccolini, A. (2016). Planning urban agriculture through spatial analysis and GIS tools: A case study in Milan. *Land Use Policy*, 56, 197–206. <https://doi.org/10.1016/j.landusepol.2016.04.020>
- Sharma, A. K., Mane, M., Shekhar, S., & Chandra, P. P. (2022). Assessing the Impact of Air Pollution on Respiratory Health: A Longitudinal Study in Urban Areas. *Health Leadership and Quality of Life*, 1, 48.
- Sia, A., Tan, P. Y., & Er, K. B. H. (2023). The contributions of urban horticulture to cities' liveability and resilience: Insights from Singapore. *Plants, People, Planet*. <https://doi.org/10.1002/ppp3.10377>
- Smith, C., Thompson, S., & McDonald, J. (2021). Urban agriculture governance frameworks and planning integration in metropolitan regions. *Sustainability*, 13 (11), 6231. <https://doi.org/10.3390/su13116231>
- Sonneveld, B. G. J. S., Merbis, M., Alfara, A., Ünver, O., & Arnal, M. A. (2021). Nature-based solutions for urban agriculture and water management: A spatial decision support approach. *Computers and Electronics in Agriculture*, 180, 105916. <https://doi.org/10.1016/j.compag.2020.105916>
- Streche, R., Dănilă, A.-B., Sterea, A., & Orza, O. (2024). *Urban Garden Management Through the Use of IOT Monitoring Systems and Multi-Criteria Application*. https://doi.org/10.24193/awc2024_18
- Twiss, J., Dickinson, J., Duma, S., Kleinman, T., Paulsen, H., & Rilveria, L. (2003). Community gardens: Lessons learned from California Healthy Cities and Communities. *American Journal of Public Health*, 93 (9), 1435–1438. <https://doi.org/10.2105/AJPH.93.9.1435>



ARTIGO

- UN-Habitat. (2022). *World cities report 2022: Envisaging the future of cities*. United Nations Human Settlements Programme. <https://unhabitat.org>
- Wagner, B. L., & Egerer, M. (2022). Application of UAV remote sensing and machine learning to model and map land use in urban gardens. *Journal of Urban Ecology*, 8 (1). <https://doi.org/10.1093/jue/juac008>
- Ward, J. (2015). Water governance and sustainability challenges in urban agriculture systems. *Urban Water Journal*, 12 (7), 531–543. <https://doi.org/10.1080/1573062X.2014.991319>
- Xu, T., Aini, A. M., Nordin, N. A., Shen, Q., Huang, L., & Xu, W. (2026). Symbiotic Intelligence for Sustainable Cities: A Decadal Review of Generative AI, Ethical Algorithms, and Global South Innovations in Urban Green Space Research. *Buildings*, 16(1), 231.
- Zaki, Z. A., Yusup, M., Abdullah, I., Abdullah, Y. A., & Shah, A. R. (2023). Land suitability analysis for urban gardening using gis-based multi-criteria decision-making approach. *PLANNING MALAYSIA JOURNAL*, 21. <https://doi.org/10.21837/pm.v21i29.1379>
- Zhao, J., Zhang, X., & Zhang, S. (2023). *Design of Decision Algorithm for Urban Land Functional Allocation Planning Based on Artificial Neural Network*. <https://doi.org/10.1109/ictci60496.2023.00047>
- Zhu, W., He, W., & Li, Q. (2024). Hybrid AI and Big Data Solutions for Dynamic Urban Planning and Smart City Optimization. *IEEE Access*, 1. <https://doi.org/10.1109/access.2024.3516544>
- Zong, S., et al. (2024). An innovative approach for equitable urban green space allocation through population demand and accessibility modeling. *Ecological Indicators*. <https://doi.org/10.1016/j.ecolind.2024.111861>