

**ARQUITETURAS
COGNITIVAS DISTRIBUÍDAS
PARA SISTEMAS
AUTÔNOMOS
INTELIGENTES:
INTEGRAÇÃO ENTRE
COMPUTAÇÃO DE BORDA,
APRENDIZADO FEDERADO
E TOMADA DE DECISÃO
ADAPTATIVA EM
AMBIENTES URBANOS
COMPLEXOS**

**DISTRIBUTED COGNITIVE ARCHITECTURES FOR INTELLIGENT
AUTONOMOUS SYSTEMS: INTEGRATION OF EDGE COMPUTING,
FEDERATED LEARNING, AND ADAPTIVE DECISION-MAKING IN COMPLEX
URBAN ENVIRONMENTS**

Rômulo Ferreira dos Santos¹

RESUMO

A crescente digitalização das cidades tem impulsionado a necessidade de sistemas autônomos capazes de operar em ambientes dinâmicos, caracterizados por elevada variabilidade, grande volume de dados, múltiplas fontes de informação, restrições de latência e exigências de confiabilidade operacional. Sistemas urbanos inteligentes, como redes de mobilidade, monitoramento ambiental, iluminação pública, segurança, drenagem, energia, gestão de resíduos e serviços públicos digitais, dependem cada vez mais de arquiteturas computacionais capazes de perceber o ambiente, aprender com dados distribuídos, adaptar decisões e coordenar respostas em tempo quase real. Este estudo propõe uma arquitetura cognitiva distribuída fundamentada na integração entre computação de borda, aprendizado federado e modelos híbridos de inteligência artificial para suporte à tomada de decisão em sistemas urbanos inteligentes. A pesquisa adota abordagem qualitativa, exploratória, bibliográfica e propositiva, articulando fundamentos de arquiteturas cognitivas, inteligência artificial distribuída, sistemas multiagentes, computação de borda, aprendizado federado, aprendizado por reforço, aprendizado contínuo, sistemas ciberfísicos, gêmeos digitais urbanos e governança algorítmica. Propõe-se o Modelo Integrado de Cognição Distribuída Urbana, denominado MICDU-FedEdge, composto por camadas de sensoriamento, borda cognitiva, aprendizagem federada, memória contextual, raciocínio adaptativo, coordenação multiagente, decisão operacional, segurança e governança. A análise demonstra que a descentralização dos processos cognitivos pode reduzir latência, preservar dados sensíveis no território, aumentar robustez, melhorar escalabilidade e favorecer respostas adaptativas em cenários urbanos complexos. Entretanto, também evidencia desafios relacionados à heterogeneidade dos dispositivos, comunicação

limitada, dados não independentes e não identicamente distribuídos, segurança adversarial, explicabilidade, vieses, interoperabilidade e responsabilidade institucional. Conclui-se que arquiteturas cognitivas distribuídas representam fronteira estratégica para cidades inteligentes resilientes, desde que sejam concebidas como sistemas sociotécnicos orientados por eficiência operacional, segurança, privacidade, transparência, justiça urbana e interesse público.

Palavras-chave: arquiteturas cognitivas; aprendizado federado; computação de borda; sistemas autônomos; cidades inteligentes; tomada de decisão adaptativa; inteligência distribuída; edge AI.

ABSTRACT

The increasing digitalization of cities has driven the need for autonomous systems capable of operating in dynamic environments characterized by high variability, large data volumes, multiple information sources, latency constraints, and operational reliability requirements. Intelligent urban systems, such as mobility networks, environmental monitoring, public lighting, safety, drainage, energy, waste management, and digital public services, increasingly depend on computational architectures capable of perceiving the environment, learning from distributed data, adapting decisions, and coordinating responses in near real time. This study proposes a distributed cognitive architecture based on the integration of edge computing, federated learning, and hybrid artificial intelligence models to support decision-making in intelligent urban systems. The research adopts a qualitative, exploratory, bibliographic, and propositional approach, articulating foundations of cognitive architectures, distributed artificial intelligence, multi-agent systems, edge computing, federated learning, reinforcement learning, continual learning, cyber-physical

systems, urban digital twins, and algorithmic governance. The article proposes the Integrated Model of Urban Distributed Cognition, named MICDU-FedEdge, composed of layers of sensing, cognitive edge, federated learning, contextual memory, adaptive reasoning, multi-agent coordination, operational decision-making, security, and governance. The analysis shows that decentralizing cognitive processes can reduce latency, preserve sensitive data within the territory, increase robustness, improve scalability, and support adaptive responses in complex urban scenarios. However, it also highlights challenges related to device heterogeneity, limited communication, non-independent and non-identically distributed data, adversarial security, explainability, biases, interoperability, and institutional accountability. The article concludes that distributed cognitive architectures represent a strategic frontier for resilient smart cities, provided that they are designed as sociotechnical systems oriented toward operational efficiency, security, privacy, transparency, urban justice, and public interest.

Keywords: cognitive architectures; federated learning; edge computing; autonomous systems; smart cities; adaptive decision-making; distributed intelligence; edge AI.

1. INTRODUÇÃO

A digitalização das cidades tem produzido uma transformação profunda na forma como os sistemas urbanos são monitorados, planejados e geridos. Sensores distribuídos, câmeras inteligentes, dispositivos móveis, veículos conectados, medidores inteligentes, plataformas de dados, sistemas de transporte, redes de energia, iluminação pública, serviços de emergência e infraestruturas ambientais geram fluxos contínuos de informações sobre o funcionamento da cidade. Essa realidade amplia as possibilidades

de tomada de decisão baseada em dados, mas também cria desafios de escala, latência, interoperabilidade, privacidade, segurança e governança (KITCHIN, 2014; BATTY, 2018; ZANELLA et al., 2014).

As cidades são sistemas complexos, abertos, adaptativos e multidimensionais. Elas combinam infraestrutura física, redes digitais, comportamento humano, instituições públicas, empresas, fluxos econômicos, riscos ambientais, desigualdades territoriais e eventos imprevisíveis. Uma decisão sobre mobilidade pode afetar segurança, emissões, tempo de deslocamento, saúde pública e acesso a serviços. Um alagamento pode interromper transporte, energia, escola, atendimento médico e atividades econômicas. Essa interdependência exige arquiteturas inteligentes capazes de operar em cenários distribuídos e dinâmicos (BATTY, 2013; MEEROW; NEWELL; STULTS, 2016; HOLLING, 1973).

O modelo tradicional de gestão urbana, baseado em coleta centralizada de dados, processamento em nuvem e resposta institucional posterior, mostra-se limitado para aplicações que exigem resposta em tempo quase real. Em sistemas de mobilidade inteligente, veículos autônomos, redes de sensores ambientais, semáforos adaptativos, detecção de eventos críticos, segurança urbana, drenagem inteligente e gestão de energia, a latência pode comprometer a qualidade da decisão. Nesses contextos, parte da inteligência precisa estar próxima do ponto de geração dos dados, isto é, na borda da rede (SHI et al., 2016; SATYANARAYANAN, 2017; KHAN et al., 2019).

A computação de borda surge justamente para responder a essa necessidade. Ao posicionar recursos de processamento e

armazenamento próximos a sensores, usuários e dispositivos, a borda reduz latência, diminui tráfego para a nuvem, melhora resiliência local e permite decisões descentralizadas. Em ambientes urbanos, isso significa que um cruzamento inteligente pode processar dados de tráfego localmente; um sistema de drenagem pode emitir alerta antes de sincronizar com a central; e um nó de energia pode ajustar operação com base em demanda local (SHI et al., 2016; SATYANARAYANAN, 2017; VARghESE et al., 2016).

Entretanto, a descentralização do processamento cria novo desafio: como aprender com dados distribuídos sem transferir todos os dados brutos para servidores centrais? O aprendizado federado oferece uma resposta relevante. Proposto em trabalhos como McMahan et al. (2017), o aprendizado federado permite treinar modelos compartilhados a partir de dados mantidos localmente em dispositivos ou nós distribuídos, enviando apenas atualizações de parâmetros ou gradientes para agregação. Essa abordagem reduz exposição de dados sensíveis, economiza largura de banda e respeita melhor restrições de privacidade (MCMAHAN et al., 2017; KONEČNÝ et al., 2016; LI et al., 2020).

Em cidades inteligentes, o aprendizado federado pode apoiar aplicações como previsão de tráfego, detecção de anomalias, monitoramento ambiental, otimização de energia, segurança pública, saúde urbana, transporte coletivo e sensoriamento participativo. Dados urbanos frequentemente são sensíveis, geolocalizados, distribuídos e regulados. Centralizar todos esses dados pode ser tecnicamente caro, eticamente problemático e juridicamente arriscado. O aprendizado federado, portanto, oferece alternativa para aprendizagem coletiva sem concentração integral

dos dados (JIANG et al., 2020; ZHENG et al., 2021; PANDYA et al., 2023).

A noção de arquitetura cognitiva distribuída amplia esse debate. Arquiteturas cognitivas buscam modelar sistemas capazes de perceber, memorizar, raciocinar, aprender, decidir e agir de forma orientada por objetivos. Modelos clássicos, como SOAR e ACT-R, foram desenvolvidos para simular processos cognitivos humanos e resolver problemas complexos (NEWELL, 1990; ANDERSON, 1996; LAIRD, 2012). No contexto urbano contemporâneo, a cognição não está localizada em uma única máquina central, mas distribuída entre sensores, agentes, gateways, veículos, plataformas, operadores humanos e sistemas institucionais (HUTCHINS, 1995; WOOLDRIDGE, 2009).

Assim, uma arquitetura cognitiva distribuída para sistemas urbanos inteligentes deve integrar percepção local, memória contextual, aprendizagem descentralizada, raciocínio adaptativo, coordenação multiagente e ação em tempo real. Essa arquitetura deve operar em ciclos contínuos de monitoramento, análise, planejamento, execução e aprendizagem, dialogando com a tradição da computação autônoma e do ciclo MAPE-K: Monitor, Analyze, Plan, Execute e Knowledge (KEPHART; CHESS, 2003; DOBSON et al., 2010).

Diante desse cenário, este artigo parte do seguinte problema de pesquisa: **como estruturar uma arquitetura cognitiva distribuída capaz de integrar computação de borda, aprendizado federado e tomada de decisão adaptativa para sistemas autônomos inteligentes em ambientes urbanos complexos?**

O objetivo geral é propor uma arquitetura cognitiva distribuída para sistemas autônomos urbanos, integrando computação de borda, aprendizado federado e modelos adaptativos de decisão. Como objetivos específicos, busca-se: discutir fundamentos de arquiteturas cognitivas e inteligência distribuída; analisar o papel da computação de borda em cidades inteligentes; examinar o aprendizado federado como mecanismo de aprendizagem descentralizada; propor uma arquitetura integrada para tomada de decisão adaptativa; e avaliar desafios de escalabilidade, robustez, segurança, privacidade e governança (RUSSELL; NORVIG, 2021; SHI et al., 2016; MCMAHAN et al., 2017).

Defende-se como tese central que sistemas urbanos inteligentes do futuro dependerão menos de inteligência centralizada e mais de arquiteturas cognitivas distribuídas, nas quais múltiplos agentes computacionais aprendem, cooperam e decidem de forma adaptativa, preservando dados locais, reduzindo latência e ampliando resiliência. Contudo, essa descentralização só será socialmente legítima se acompanhada por segurança, explicabilidade, auditoria, participação pública e alinhamento ao interesse coletivo (KITCHIN, 2014; BATTY, 2018; FLORIDI; COWLS, 2019).

2. METODOLOGIA

Este estudo adota abordagem qualitativa, exploratória, bibliográfica e propositiva. A escolha por esse delineamento justifica-se pela natureza interdisciplinar do tema, que envolve inteligência artificial, sistemas distribuídos, computação de borda, aprendizado federado, cidades inteligentes, sistemas multiagentes, teoria da decisão,

segurança cibernética, governança de dados e infraestrutura urbana (CRESWELL, 2014; TORRACO, 2005).

A pesquisa foi estruturada como revisão narrativa integrativa com proposição de arquitetura conceitual. A revisão narrativa integrativa é adequada quando o fenômeno investigado ainda se encontra em consolidação e exige articulação entre diferentes campos científicos. Arquiteturas cognitivas distribuídas para cidades inteligentes não pertencem a uma única área disciplinar, pois dependem de computação, engenharia urbana, ciência de dados, governança pública e teoria de sistemas complexos (WHITTEMORE; KNAFL, 2005; BATTY, 2013).

A pergunta norteadora foi: **quais componentes técnicos, cognitivos, comunicacionais e institucionais devem compor uma arquitetura distribuída para sistemas autônomos inteligentes em ambientes urbanos complexos?**

Foram considerados como eixos de análise: arquiteturas cognitivas; cognição distribuída; computação de borda; edge AI; aprendizado federado; aprendizado por reforço; aprendizado contínuo; sistemas multiagentes; sistemas ciberfísicos; gêmeos digitais urbanos; tomada de decisão adaptativa; privacidade; segurança; governança algorítmica; interoperabilidade; e resiliência urbana (NEWELL, 1990; HUTCHINS, 1995; RUSSELL; NORVIG, 2021; BATTY, 2018).

Entre os autores e documentos utilizados, destacam-se Newell (1990), Anderson (1996), Laird (2012), Hutchins (1995), Wooldridge (2009), Russell e Norvig (2021), Sutton e Barto (2018), Kephart e Chess (2003), Shi et al. (2016), Satyanarayanan (2017), McMahan et al. (2017), Konečný et al. (2016), Li et al. (2020), Bonawitz et al. (2019), Jiang et al.

(2020), Zheng et al. (2021), Pandya et al. (2023), Khan et al. (2019), Batty (2013, 2018), Kitchin (2014), Zanella et al. (2014), Rajkumar et al. (2010), Grieves (2014), Tao et al. (2019), Yang et al. (2024) e autores de governança ética da IA, como Floridi e Cowls (2019), Mitchell et al. (2019), Rudin (2019) e Bender et al. (2021).

Foram incluídas publicações relacionadas a sistemas autônomos, edge computing, federated learning, smart cities, distributed artificial intelligence, multi-agent systems, reinforcement learning, continual learning, cyber-physical systems, digital twins, AI governance e segurança. Foram excluídos materiais meramente promocionais, textos sem autoria identificável e publicações sem relação direta com arquiteturas distribuídas, cognição artificial ou sistemas urbanos inteligentes.

A análise foi organizada em cinco etapas. A primeira delimitou os fundamentos de arquiteturas cognitivas e cognição distribuída. A segunda examinou a computação de borda como infraestrutura para inteligência urbana descentralizada. A terceira analisou o aprendizado federado como mecanismo de aprendizagem distribuída e preservação de dados locais. A quarta discutiu modelos de tomada de decisão adaptativa, aprendizado por reforço e sistemas multiagentes. A quinta resultou na proposição do **MICDU-FedEdge — Modelo Integrado de Cognição Distribuída Urbana com Aprendizado Federado e Computação de Borda**.

Por se tratar de estudo propositivo, não houve coleta empírica direta. O modelo apresentado tem finalidade conceitual e metodológica, podendo orientar pesquisas aplicadas, simulações computacionais, projetos-piloto municipais, sistemas de mobilidade inteligente,

monitoramento urbano, gestão de recursos públicos e desenvolvimento de plataformas urbanas autônomas.

3. ARQUITETURAS COGNITIVAS E COGNIÇÃO DISTRIBUÍDA

Arquiteturas cognitivas são estruturas computacionais projetadas para representar processos associados à inteligência, como percepção, memória, aprendizagem, raciocínio, resolução de problemas, planejamento e ação. Elas buscam organizar componentes funcionais de um agente inteligente, permitindo que ele interaja com o ambiente de forma orientada por objetivos (NEWELL, 1990; ANDERSON, 1996; LAIRD, 2012).

Modelos clássicos, como SOAR e ACT-R, influenciaram profundamente a pesquisa em cognição computacional. O SOAR, associado a Newell e Laird, foi concebido como arquitetura geral para resolução de problemas, aprendizagem e tomada de decisão baseada em regras e estados. O ACT-R, associado a Anderson, buscou representar processos cognitivos humanos com módulos de memória declarativa, memória procedural, percepção e ação (NEWELL, 1990; ANDERSON, 1996; LAIRD, 2012).

Na inteligência artificial contemporânea, a noção de arquitetura cognitiva precisa ser reinterpretada diante de sistemas distribuídos, aprendizado profundo, dados massivos, sensores, agentes autônomos e ambientes urbanos conectados. A cognição artificial já não pode ser vista apenas como processo interno de um agente isolado. Em cidades inteligentes, a inteligência emerge da interação entre múltiplos agentes, dispositivos, modelos, dados, operadores humanos e instituições (HUTCHINS, 1995; WOOLDRIDGE, 2009; RUSSELL; NORVIG, 2021).

A teoria da cognição distribuída, proposta por Hutchins (1995), sustenta que processos cognitivos podem estar distribuídos entre pessoas, artefatos, ferramentas e ambientes. Essa abordagem é especialmente útil para compreender sistemas urbanos inteligentes, pois decisões sobre tráfego, energia, segurança ou drenagem não são tomadas por um único cérebro artificial, mas por redes sociotécnicas compostas por sensores, algoritmos, operadores, regras institucionais e infraestruturas (HUTCHINS, 1995; KITCHIN, 2014).

Em uma arquitetura cognitiva distribuída, diferentes nós do sistema podem executar funções cognitivas parciais. Sensores percebem; gateways filtram; modelos locais inferem; agregadores federados aprendem; agentes negociam; gêmeos digitais simulam; plataformas centrais coordenam; e humanos supervisionam decisões críticas. Essa divisão de funções reduz dependência de um centro único e permite resposta mais rápida e contextualizada (WOOLDRIDGE, 2009; SHI et al., 2016).

A computação autônoma também contribui para essa visão. Kephart e Chess (2003) propuseram sistemas capazes de autogerenciamento com base em objetivos de alto nível, por meio do ciclo MAPE-K: monitorar, analisar, planejar, executar e utilizar conhecimento. Em ambientes urbanos, esse ciclo pode ser distribuído entre nós de borda e plataformas centrais, permitindo sistemas que se ajustem a variações de demanda, falhas e eventos críticos (KEPHART; CHESS, 2003; DOBSON et al., 2010).

A cognição distribuída urbana exige memória contextual. A cidade não é apenas fluxo instantâneo de dados; ela possui padrões históricos, sazonalidades, eventos recorrentes, vulnerabilidades

territoriais, hábitos de mobilidade, zonas de risco e dinâmicas sociais. Uma arquitetura cognitiva deve combinar dados em tempo real com conhecimento acumulado, mapas, modelos históricos, regras normativas e objetivos públicos (BATTY, 2013; KITCHIN, 2014; MEEROW; NEWELL; STULTS, 2016).

Também exige adaptação. Ambientes urbanos mudam continuamente: acidentes, chuvas, eventos, obras, falhas de energia, congestionamentos, manifestações, sazonalidades e emergências sanitárias alteram condições de operação. Sistemas autônomos inteligentes precisam detectar mudanças de contexto, ajustar políticas e aprender com novos dados sem depender sempre de reprogramação manual (SUTTON; BARTO, 2018; YANG et al., 2024).

Portanto, arquiteturas cognitivas distribuídas para cidades inteligentes devem integrar percepção, memória, aprendizagem, raciocínio, decisão e ação em rede. Seu objetivo não é apenas automatizar tarefas, mas criar sistemas capazes de responder a ambientes complexos com eficiência, robustez, transparência e responsabilidade.

4. COMPUTAÇÃO DE BORDA COMO BASE DA INTELIGÊNCIA URBANA DESCENTRALIZADA

A computação de borda desloca parte do processamento e do armazenamento para pontos próximos aos dispositivos, sensores e usuários. Em vez de enviar todos os dados para centros de nuvem distantes, os dados podem ser filtrados, processados e analisados localmente em gateways, micro data centers, unidades de borda, roteadores inteligentes, veículos, estações de base ou equipamentos urbanos (SHI et al., 2016; SATYANARAYANAN, 2017).

Essa estratégia é particularmente relevante para cidades inteligentes porque muitas aplicações urbanas são sensíveis à latência. Semáforos adaptativos, veículos conectados, resposta a acidentes, sistemas de alerta de enchentes, detecção de incêndios, monitoramento de segurança, controle de energia e operação de infraestrutura crítica exigem decisões em segundos ou milissegundos. A nuvem centralizada pode ser insuficiente quando a comunicação é instável ou a resposta precisa ser imediata (KHAN et al., 2019; SHI et al., 2016).

A borda também reduz tráfego de rede. Cidades conectadas podem gerar volumes massivos de dados por câmeras, sensores ambientais, medidores inteligentes, radares, GPS, dispositivos móveis e sistemas IoT. Enviar tudo para a nuvem aumenta custo, consumo de banda e risco de congestionamento. Processar localmente permite filtrar eventos relevantes, agregar dados e transmitir apenas informações úteis (SATYANARAYANAN, 2017; ZANELLA et al., 2014).

Outra vantagem é a privacidade. Dados urbanos podem revelar hábitos de deslocamento, localização, consumo energético, comportamento em espaços públicos e padrões sensíveis de comunidades. Ao manter parte do processamento na borda, reduz-se a necessidade de centralizar dados brutos, favorecendo princípios de minimização e proteção de dados (KITCHIN, 2014; FLORIDI; COWLS, 2019).

A computação de borda também melhora resiliência operacional. Em caso de falha de conexão com a nuvem, um nó de borda pode continuar executando decisões locais. Por exemplo, um cruzamento inteligente pode manter controle semaforico adaptativo; uma estação de drenagem pode acionar bomba; uma rede de energia

pode isolar falhas; e um sistema de transporte pode atualizar rotas locais (SHI et al., 2016; SATYANARAYANAN, 2017).

Entretanto, a borda apresenta limitações. Dispositivos de borda possuem capacidade computacional variável, consumo energético restrito, necessidade de manutenção distribuída, vulnerabilidade física, heterogeneidade de hardware e desafios de segurança. Diferentemente da nuvem, que concentra recursos em ambientes controlados, a borda opera em território aberto, sujeito a falhas, calor, umidade, vandalismo, instabilidade elétrica e conectividade irregular (VARghESE et al., 2016; NIST, 2020).

A borda cognitiva deve, portanto, ser projetada com critérios de robustez. Isso inclui redundância, atualização segura, monitoramento remoto, autenticação, proteção física, logs, orquestração de serviços, balanceamento de carga, isolamento de aplicações e capacidade de operação degradada. Uma arquitetura urbana não pode depender de nós de borda frágeis ou sem governança (SHI et al., 2016; NIST, 2020).

Em cidades tropicais, amazônicas ou periféricas, a borda possui importância ainda maior, pois conectividade e infraestrutura central podem ser desiguais. O processamento descentralizado permite levar inteligência operacional a territórios onde a nuvem ou a comunicação contínua não são garantidas. Isso torna a computação de borda instrumento de resiliência tecnológica e territorial (KITCHIN, 2014; MEEROW; NEWELL; STULTS, 2016).

Assim, a computação de borda constitui a base física e operacional da arquitetura cognitiva distribuída. Sem borda, a autonomia urbana permanece excessivamente dependente de centros remotos. Com

borda, a cidade passa a possuir inteligência situada, contextual e responsiva.

5. APRENDIZADO FEDERADO EM AMBIENTES URBANOS INTELIGENTES

O aprendizado federado é uma abordagem de aprendizado de máquina distribuído na qual múltiplos clientes ou nós treinam modelos localmente em seus próprios dados e compartilham atualizações com um servidor ou mecanismo agregador, sem transferir diretamente os dados brutos. McMahan et al. (2017) consolidaram esse paradigma ao propor o FedAvg, algoritmo baseado na média iterativa de atualizações locais de modelos treinados em dispositivos distribuídos (MCMAHAN et al., 2017).

Essa abordagem é especialmente relevante quando os dados são sensíveis, volumosos ou distribuídos. Em ambientes urbanos, dados de mobilidade, segurança, energia, saúde, consumo, sensores ambientais, dispositivos pessoais e equipamentos públicos podem ser geolocalizados, privados ou regulados. Transferir todos esses dados para uma central pode gerar riscos de privacidade, custos de rede e problemas legais (JIANG et al., 2020; PANDYA et al., 2023).

O aprendizado federado permite construir modelos urbanos compartilhados sem centralizar integralmente os dados. Por exemplo, diferentes cruzamentos podem treinar localmente modelos de fluxo de tráfego; diferentes ônibus podem aprender padrões de ocupação; diferentes bairros podem treinar modelos de consumo energético; sensores ambientais podem colaborar na previsão de poluição; e unidades de saúde podem contribuir para

modelos epidemiológicos sem expor dados individuais (ZHENG et al., 2021; JIANG et al., 2020).

Entretanto, o aprendizado federado urbano enfrenta desafios técnicos importantes. O primeiro é a heterogeneidade dos dados. Dados urbanos são frequentemente não independentes e não identicamente distribuídos. Um bairro central possui padrões de mobilidade diferentes de uma periferia; uma região comercial difere de uma residencial; sensores instalados em áreas alagáveis produzem dados distintos de áreas altas; e dispositivos diferentes possuem qualidade variável (LI et al., 2020; KAIROUZ et al., 2021).

O segundo desafio é a heterogeneidade dos dispositivos. Nós de borda podem ter capacidades distintas de CPU, memória, energia e conectividade. Alguns podem treinar modelos rapidamente; outros podem falhar, desconectar ou participar apenas de forma intermitente. A arquitetura federada deve tolerar participação parcial, atrasos, perdas e assimetria computacional (BONAWITZ et al., 2019; LI et al., 2020).

O terceiro desafio é a comunicação. Em aprendizado federado, os dados não são centralizados, mas atualizações de modelo precisam ser transmitidas. Em redes urbanas de grande escala, comunicação pode ser cara, instável ou limitada. Estratégias como compressão de gradientes, quantização, seleção de clientes, atualização assíncrona e agregação hierárquica tornam-se relevantes (KONEČNÝ et al., 2016; MCMAHAN et al., 2017).

O quarto desafio é a segurança adversarial. Participantes maliciosos podem enviar atualizações corrompidas, envenenar o modelo, realizar ataques de inferência ou tentar reconstruir dados privados a

partir de gradientes. Aprendizado federado melhora privacidade em relação à centralização bruta, mas não elimina riscos. Técnicas como secure aggregation, differential privacy, robust aggregation e detecção de anomalias são necessárias (BONAWITZ et al., 2017; KAIROUZ et al., 2021).

O quinto desafio é a governança. Quem define o objetivo do modelo federado? Quem controla o agregador? Quem audita atualizações? Como lidar com desigualdades entre territórios? Como garantir que modelos treinados com dados de áreas mais conectadas não prejudiquem áreas menos representadas? Essas questões tornam o aprendizado federado urbano um problema sociotécnico, e não apenas algorítmico (KITCHIN, 2014; FLORIDI; COWLS, 2019).

Apesar desses desafios, o aprendizado federado é promissor para cidades inteligentes. Ele permite conciliar colaboração e autonomia, compartilhamento de conhecimento e preservação de dados locais, aprendizagem coletiva e sensibilidade territorial. Em uma arquitetura cognitiva distribuída, o aprendizado federado funciona como mecanismo de memória coletiva sem centralização total da experiência urbana (JIANG et al., 2020; PANDYA et al., 2023).

6. TOMADA DE DECISÃO ADAPTATIVA E SISTEMAS AUTÔNOMOS

A tomada de decisão adaptativa é a capacidade de ajustar ações conforme mudanças no ambiente, nos objetivos, nas restrições e nos resultados observados. Em sistemas urbanos inteligentes, decisões adaptativas podem envolver alteração de tempos semafóricos, redistribuição de veículos, acionamento de alertas, priorização de manutenção, gestão de energia, resposta a

emergências, controle de iluminação e alocação de recursos públicos (SUTTON; BARTO, 2018; RUSSELL; NORVIG, 2021).

O aprendizado por reforço constitui uma das principais abordagens para decisão adaptativa. Nesse paradigma, um agente aprende políticas de ação por interação com o ambiente, recebendo recompensas ou penalidades conforme os resultados. Em cidades inteligentes, aprendizado por reforço pode ser aplicado ao controle de tráfego, otimização energética, roteamento, gestão de semáforos, veículos autônomos e alocação de recursos (SUTTON; BARTO, 2018; MNIH et al., 2015).

Entretanto, sistemas urbanos são ambientes de alto risco, nos quais explorar ações aleatórias pode gerar danos. Por isso, aprendizado por reforço em cidades deve ser combinado com simulações, gêmeos digitais, restrições de segurança, aprendizagem offline, supervisão humana e validação progressiva. Não é aceitável que um sistema urbano aprenda por tentativa e erro diretamente em situações críticas sem salvaguardas (RUSSELL; NORVIG, 2021; BATTY, 2018).

Sistemas multiagentes também são relevantes. Em uma cidade, múltiplos agentes tomam decisões simultâneas: semáforos, veículos, drones, sensores, operadores, aplicativos, redes de energia e sistemas públicos. Esses agentes podem cooperar, competir, negociar ou coordenar. A inteligência urbana emerge da interação entre eles, e não apenas da decisão isolada de um controlador central (WOOLDRIDGE, 2009; RUSSELL; NORVIG, 2021).

A tomada de decisão adaptativa deve considerar objetivos múltiplos. Por exemplo, otimizar tráfego apenas por velocidade pode aumentar risco a pedestres ou emissões em bairros vulneráveis.

Otimizar energia apenas por custo pode prejudicar conforto térmico em escolas ou hospitais. Portanto, decisões urbanas exigem funções de recompensa multicritério, incorporando eficiência, segurança, equidade, sustentabilidade e prioridade social (MEEROW; NEWELL; STULTS, 2016; FLORIDI; COWLS, 2019).

A adaptabilidade também envolve aprendizado contínuo. Cidades mudam ao longo do tempo, e modelos treinados em dados passados podem perder desempenho diante de novas obras, mudanças de comportamento, eventos climáticos, crises sanitárias, alterações econômicas ou expansão urbana. O aprendizado contínuo busca atualizar modelos sem esquecer conhecimentos anteriores, enfrentando o problema do esquecimento catastrófico (PARISI et al., 2019; YANG et al., 2024).

Em arquiteturas distribuídas, a decisão adaptativa pode ocorrer em diferentes níveis. O nó de borda toma decisões imediatas; o agregador federado atualiza modelos globais; a plataforma central define políticas; o gêmeo digital simula cenários; e operadores humanos supervisionam eventos de alto impacto. Essa hierarquia reduz latência sem eliminar coordenação estratégica (SHI et al., 2016; BATTY, 2018).

Portanto, a tomada de decisão adaptativa em ambientes urbanos exige integração entre aprendizagem, simulação, governança e segurança. Sistemas autônomos urbanos não devem ser apenas reativos; devem ser capazes de aprender, antecipar, justificar e respeitar limites normativos.

7. SISTEMAS MULTIAGENTES, COOPERAÇÃO E COORDENAÇÃO URBANA

Sistemas multiagentes são compostos por múltiplos agentes autônomos que interagem em um ambiente compartilhado. Cada agente possui objetivos, informações, capacidades e políticas de ação próprias. Em cidades inteligentes, essa abordagem é particularmente adequada porque o urbano é distribuído por natureza: diferentes equipamentos, veículos, sensores, serviços e instituições operam simultaneamente e precisam coordenar decisões (WOOLDRIDGE, 2009; RUSSELL; NORVIG, 2021).

Um sistema de mobilidade inteligente pode ser modelado como rede de agentes: semáforos, veículos, ônibus, pedestres, centrais de controle, aplicativos de rota, sensores viários e equipes de campo. Cada agente percebe parte do ambiente e pode tomar ações locais. A coordenação entre eles é necessária para evitar decisões conflitantes, como priorizar um corredor de ônibus e, ao mesmo tempo, bloquear vias de emergência (WOOLDRIDGE, 2009; CATS; JENELIUS, 2014).

Na gestão energética, medidores inteligentes, painéis solares, baterias, cargas flexíveis, estações de recarga e operadores de rede podem atuar como agentes coordenados. A decisão adaptativa pode equilibrar demanda, geração distribuída, preço, emissões e estabilidade da rede. Esse tipo de coordenação é essencial para cidades com eletrificação crescente e recursos energéticos distribuídos (FANG et al., 2012; SIANO, 2014).

Em drenagem urbana, sensores de nível, comportas, bombas, estações meteorológicas, equipes de manutenção e sistemas de alerta podem atuar como agentes em uma rede cognitiva. O objetivo é antecipar alagamentos, redistribuir fluxos quando possível, emitir alertas e proteger áreas vulneráveis. A coordenação é

crítica porque uma ação em uma bacia pode afetar outra (TUCCI, 2008; BATTY, 2018).

A cooperação entre agentes pode ser definida por regras, contratos, aprendizagem ou mecanismos de negociação. Em sistemas urbanos críticos, a cooperação não deve depender apenas de aprendizagem autônoma opaca. É necessário incorporar regras de segurança, prioridades públicas, limites de atuação e supervisão humana (RUSSELL; NORVIG, 2021; FLORIDI; COWLS, 2019).

O aprendizado multiagente por reforço permite que agentes aprendam políticas de cooperação em ambientes compartilhados. Contudo, problemas como instabilidade, não estacionaridade, escalabilidade e explicabilidade tornam sua aplicação urbana desafiadora. O comportamento de um agente altera o ambiente dos demais, tornando o processo de aprendizagem mais complexo (BUSONI; BABUSKA; DE SCHUTTER, 2008; SUTTON; BARTO, 2018).

Arquiteturas híbridas podem combinar regras simbólicas, modelos probabilísticos e aprendizado profundo. Essa combinação é útil em cidades porque algumas decisões precisam obedecer normas explícitas, enquanto outras dependem de padrões aprendidos. Por exemplo, o sistema pode aprender a prever congestionamentos, mas regras normativas devem garantir prioridade a ambulâncias, pedestres e rotas de evacuação (RUSSELL; NORVIG, 2021; MARCUS; DAVIS, 2019).

Assim, sistemas multiagentes fornecem a gramática operacional da cognição distribuída urbana. Eles permitem transformar dispositivos isolados em coletivos inteligentes, desde que haja coordenação, interoperabilidade, segurança e objetivos públicos claros.

8. GÊMEOS DIGITAIS URBANOS, SIMULAÇÃO E APRENDIZAGEM SEGURA

Gêmeos digitais urbanos são representações virtuais dinâmicas de sistemas urbanos físicos, alimentadas por dados em tempo real, modelos analíticos e simulações. Eles permitem testar cenários, prever impactos, validar decisões e integrar múltiplas camadas da cidade, como mobilidade, energia, drenagem, uso do solo, infraestrutura e vulnerabilidade social (GRIEVES, 2014; BATTY, 2018; TAO et al., 2019).

Em arquiteturas cognitivas distribuídas, gêmeos digitais cumprem papel de ambiente de simulação e memória operacional. Antes de aplicar uma política adaptativa no mundo real, o sistema pode testá-la no gêmeo digital. Isso é especialmente importante para aprendizado por reforço, pois permite treinamento e validação de políticas em ambiente simulado, reduzindo risco de danos reais (BATTY, 2018; RUSSELL; NORVIG, 2021).

Um gêmeo digital de mobilidade pode simular alterações de fluxo, bloqueios, acidentes, eventos e mudanças semafóricas. Um gêmeo digital de drenagem pode simular chuvas extremas, saturação de bacias, falha de bombas e efeitos de obras de retenção. Um gêmeo digital energético pode avaliar carga, geração distribuída, armazenamento e resposta à demanda (BATTY, 2018; TAO et al., 2019).

O gêmeo digital também pode apoiar aprendizado federado. Nós de borda podem treinar modelos locais e enviar atualizações; a plataforma central pode avaliar impacto dessas atualizações em cenários simulados antes de redistribuir um modelo global. Isso

reduz risco de aplicar modelos instáveis ou enviesados diretamente em operações críticas (MCMAHAN et al., 2017; BONAWITZ et al., 2019).

A simulação, entretanto, não substitui a realidade. Gêmeos digitais são aproximações, dependem de qualidade dos dados, calibração e atualização contínua. Modelos urbanos podem falhar quando fenômenos sociais, eventos raros, informalidade territorial ou infraestrutura não mapeada não são representados adequadamente. O risco de uma cidade digital invisibilizar territórios vulneráveis é real (KITCHIN, 2014; SHELTON; ZOOK; WIIG, 2015).

A aprendizagem segura exige validação em múltiplos níveis. Uma política pode ser testada em simulação, depois em ambiente controlado, depois em piloto limitado e apenas posteriormente em escala. Essa progressão é indispensável quando decisões afetam segurança, mobilidade, energia, saúde e recursos públicos (RUDIN, 2019; FLORIDI; COWLS, 2019).

Gêmeos digitais também favorecem explicabilidade operacional. Ao simular cenários alternativos, o sistema pode justificar por que determinada decisão foi tomada: reduzir alagamento, manter rota de emergência, minimizar tempo de deslocamento ou preservar fornecimento energético. Essa capacidade de comparação contrafactual é importante para auditoria e confiança pública (BATTY, 2018; RUDIN, 2019).

Portanto, gêmeos digitais urbanos são componentes estratégicos da arquitetura cognitiva distribuída, funcionando como laboratório virtual, integrador de dados e suporte à decisão adaptativa. Contudo, precisam ser inclusivos, calibrados, transparentes e conectados à realidade territorial.

9. SEGURANÇA, PRIVACIDADE E RESILIÊNCIA EM ARQUITETURAS DISTRIBUÍDAS

A descentralização da inteligência urbana aumenta autonomia e resiliência, mas também amplia a superfície de ataque. Cada sensor, gateway, nó de borda, agente autônomo, modelo local e canal federado pode se tornar ponto de vulnerabilidade. Portanto, segurança deve ser princípio de projeto, e não camada adicionada posteriormente (NIST, 2020; SICARI et al., 2015).

No aprendizado federado, há riscos específicos. Ataques de envenenamento de dados podem manipular modelos locais; ataques de envenenamento de modelo podem enviar atualizações maliciosas ao agregador; ataques de inferência podem tentar reconstruir informações sensíveis a partir de gradientes; e participantes maliciosos podem criar backdoors no modelo global (KAIROUZ et al., 2021; BONAWITZ et al., 2017).

A agregação segura é uma das respostas. Bonawitz et al. (2017) propuseram protocolos que permitem ao servidor agregar atualizações sem inspecionar individualmente cada contribuição. Essa abordagem melhora privacidade, embora não resolva todos os problemas de segurança adversarial. Em ambientes urbanos, agregação segura deve ser combinada com autenticação, reputação, detecção de anomalias e auditoria (BONAWITZ et al., 2017; KAIROUZ et al., 2021).

A privacidade diferencial também pode ser aplicada para reduzir risco de vazamento de informações individuais. Entretanto, há trade-off entre privacidade e desempenho do modelo. Em sistemas urbanos críticos, esse equilíbrio deve ser avaliado com cuidado, pois

modelos excessivamente ruidosos podem prejudicar decisões operacionais (DWORK; ROTH, 2014; KAIROUZ et al., 2021).

A segurança dos nós de borda é igualmente importante. Gateways urbanos podem estar fisicamente expostos em postes, vias, escolas, estações ou equipamentos públicos. Ataques físicos, adulteração, roubo, falha elétrica ou vandalismo podem comprometer dados e decisões. A arquitetura deve prever inicialização segura, criptografia, módulos de confiança, monitoramento e revogação remota (NIST, 2020; SHI et al., 2016).

A resiliência também exige tolerância a falhas. Em redes distribuídas, alguns nós inevitavelmente falharão. O sistema precisa continuar operando com dados incompletos, atrasos ou desconexões. Modelos assíncronos, agregação hierárquica, redundância, fallback local e operação degradada são estratégias importantes (SATYANARAYANAN, 2017; LI et al., 2020).

A confiança pública depende de transparência. Sistemas urbanos autônomos podem afetar mobilidade, segurança, acesso a serviços e distribuição de recursos. A população precisa saber quais dados são coletados, para quais finalidades, por quanto tempo, por quem, com quais salvaguardas e como contestar decisões automatizadas. A governança deve ser pública, auditável e compatível com direitos fundamentais (FLORIDI; COWLS, 2019; KITCHIN, 2014).

Assim, segurança, privacidade e resiliência não são requisitos periféricos. São condições para que arquiteturas cognitivas distribuídas sejam tecnicamente confiáveis e socialmente legítimas.

10. MODELO MICDU-FEDEDGE: ARQUITETURA PROPOSTA

Este artigo propõe o **MICDU-FedEdge — Modelo Integrado de Cognição Distribuída Urbana com Aprendizado Federado e Computação de Borda**. O modelo busca estruturar sistemas autônomos inteligentes em ambientes urbanos complexos, integrando percepção distribuída, processamento de borda, aprendizagem federada, memória contextual, raciocínio adaptativo, coordenação multiagente, decisão operacional e governança.

O MICDU-FedEdge é composto por nove camadas: camada físico-sensorial, camada de conectividade, camada de borda cognitiva, camada de aprendizagem federada, camada de memória contextual, camada de raciocínio adaptativo, camada de coordenação multiagente, camada de decisão operacional e camada de governança, segurança e auditoria.

A primeira camada, físico-sensorial, corresponde aos dispositivos e ativos urbanos que percebem ou atuam no ambiente. Inclui câmeras, sensores de tráfego, pluviômetros, sensores de nível, medidores de energia, sensores ambientais, veículos conectados, semáforos, bombas, luminárias, drones, estações meteorológicas e dispositivos móveis. Essa camada é a base perceptiva da cidade cognitiva (ZANELLA et al., 2014; GUBBI et al., 2013).

A segunda camada, conectividade, integra tecnologias como 5G, Wi-Fi, LoRaWAN, fibra óptica, redes mesh, NB-IoT, Ethernet, V2X e protocolos IoT. Sua função é garantir comunicação adequada conforme requisitos de latência, alcance, energia e confiabilidade. Redes urbanas heterogêneas exigem interoperabilidade e redundância (AL-FUQAHA et al., 2015; KHAN et al., 2019).

A terceira camada, borda cognitiva, realiza processamento local. Ela filtra dados, detecta eventos, executa inferências, armazena informações temporárias, aciona respostas imediatas e reduz dependência da nuvem. Essa camada permite inteligência situada, essencial para sistemas sensíveis à latência (SHI et al., 2016; SATYANARAYANAN, 2017).

A quarta camada, aprendizagem federada, coordena o treinamento distribuído de modelos. Nós locais treinam com dados próprios e enviam atualizações para agregadores regionais ou centrais. O modelo pode ser hierárquico, com agregação por bairro, distrito, região e cidade. Essa organização reduz comunicação e respeita a heterogeneidade territorial (MCMAHAN et al., 2017; LI et al., 2020).

A quinta camada, memória contextual, armazena conhecimento histórico e situacional. Inclui mapas, séries temporais, padrões sazonais, eventos anteriores, vulnerabilidades, perfis de infraestrutura, regras de operação, indicadores sociais e dados de gêmeos digitais. Essa memória evita que o sistema decida apenas com base no instante presente (BATTY, 2013; KITCHIN, 2014).

A sexta camada, raciocínio adaptativo, combina modelos de aprendizado de máquina, regras simbólicas, inferência probabilística, aprendizado por reforço e análise multicritério. Essa camada avalia alternativas, riscos, incertezas e objetivos. Em aplicações críticas, deve preservar explicabilidade e limites normativos (SUTTON; BARTO, 2018; RUSSELL; NORVIG, 2021; RUDIN, 2019).

A sétima camada, coordenação multiagente, organiza interação entre diferentes agentes urbanos. Agentes podem negociar

prioridades, compartilhar estados, resolver conflitos e coordenar ações. Essa camada é essencial para evitar decisões locais que produzam efeitos negativos sistêmicos (WOOLDRIDGE, 2009; BUSONI; BABUSKA; DE SCHUTTER, 2008).

A oitava camada, decisão operacional, transforma inferência em ação. Pode ajustar semáforos, emitir alertas, redirecionar rotas, acionar equipes, modificar iluminação, priorizar manutenção, controlar bombas ou recomendar intervenção humana. Essa camada deve operar com níveis de autonomia graduais, conforme risco e criticidade (KEPHART; CHESS, 2003; FLORIDI; COWLS, 2019).

A nona camada, governança, segurança e auditoria, estabelece políticas de dados, autenticação, autorização, privacidade, explicabilidade, registro de decisões, avaliação de impacto, auditoria de modelos, gestão de riscos e supervisão humana. Essa camada garante legitimidade institucional e proteção contra danos (NIST, 2020; MITCHELL et al., 2019; FLORIDI; COWLS, 2019).

O MICDU-FedEdge opera em ciclos cognitivos. Primeiro, percebe o ambiente por sensores. Segundo, processa dados na borda. Terceiro, atualiza modelos por aprendizado federado. Quarto, consulta memória contextual. Quinto, simula cenários quando necessário. Sexto, seleciona ações adaptativas. Sétimo, coordena agentes. Oitavo, executa decisões. Nono, registra resultados e aprende com o feedback.

Essa arquitetura combina descentralização e coordenação. A borda garante velocidade e contextualização; o aprendizado federado garante aprendizagem coletiva; a camada central garante visão sistêmica; e a governança garante segurança e alinhamento público.

O modelo não elimina a nuvem, mas distribui a inteligência entre nuvem, borda, dispositivos e instituições.

11. APLICAÇÕES EM MOBILIDADE INTELIGENTE

A mobilidade urbana é uma das aplicações mais relevantes para arquiteturas cognitivas distribuídas. Redes de transporte são dinâmicas, sensíveis à latência e dependentes de múltiplas fontes de dados, como sensores viários, GPS de ônibus, aplicativos, câmeras, semáforos, dados meteorológicos, eventos, acidentes e padrões de deslocamento (GONZÁLEZ; HIDALGO; BARABÁSI, 2008; CATS; JENELIUS, 2014).

Em um sistema baseado no MICDU-FedEdge, cada cruzamento pode operar como nó de borda cognitiva. Esse nó processa fluxo local de veículos, pedestres e transporte coletivo, ajustando tempos semaforicos em tempo quase real. Ao mesmo tempo, atualizações de aprendizado federado permitem que diferentes cruzamentos compartilhem conhecimento sobre padrões de tráfego sem centralizar todos os vídeos ou trajetórias individuais (JIANG et al., 2020; PANDYA et al., 2023).

O aprendizado federado pode ser utilizado para prever congestionamentos, estimar demanda por transporte coletivo, identificar padrões de acidentes, otimizar rotas e melhorar resposta a eventos. Cada região da cidade aprende com seus próprios dados, enquanto o modelo global incorpora regularidades urbanas mais amplas. Essa abordagem é útil porque padrões de mobilidade são territorialmente heterogêneos (ZHENG et al., 2021; KHAN et al., 2019).

A tomada de decisão adaptativa permite responder a eventos inesperados. Em caso de acidente, chuva forte, bloqueio viário ou

evento público, agentes locais podem ajustar rotas e sinalização. A coordenação multiagente evita que decisões locais simplesmente desloquem congestionamento para ruas vizinhas. A arquitetura deve otimizar não apenas velocidade média, mas segurança, prioridade ao transporte público, pedestres, ciclistas e veículos de emergência (WOOLDRIDGE, 2009; SUTTON; BARTO, 2018).

Gêmeos digitais de mobilidade podem simular políticas antes de aplicá-las. Um algoritmo de controle semafórico pode ser testado virtualmente com diferentes cenários de chuva, pico, eventos e falhas. Essa validação reduz risco de impactos negativos em operação real (BATTY, 2018; TAO et al., 2019).

A privacidade é requisito central. Dados de mobilidade são altamente sensíveis, pois revelam rotinas, locais de trabalho, saúde, religião, consumo e relações sociais. O aprendizado federado e o processamento na borda reduzem exposição, mas devem ser acompanhados de anonimização, minimização, segurança e governança (KITCHIN, 2014; FLORIDI; COWLS, 2019).

Assim, a mobilidade inteligente demonstra claramente o valor da cognição distribuída: decisões locais rápidas, aprendizagem coletiva, coordenação sistêmica e respeito à privacidade.

12. APLICAÇÕES EM MONITORAMENTO URBANO, AMBIENTAL E GESTÃO DE RECURSOS

Além da mobilidade, arquiteturas cognitivas distribuídas podem apoiar monitoramento urbano, ambiental e gestão integrada de recursos públicos. Sensores ambientais podem medir qualidade do ar, ruído, temperatura, umidade, níveis de água, precipitação, iluminação, resíduos, consumo energético e ocupação de espaços

públicos. Esses dados são essenciais para políticas urbanas baseadas em evidências (ZANELLA et al., 2014; KITCHIN, 2014).

Em monitoramento ambiental, nós de borda podem detectar anomalias locais, como aumento de poluição, calor extremo, alagamento iminente ou ruído excessivo. Em vez de transmitir todos os dados brutos, a borda envia eventos contextualizados. Isso reduz tráfego, melhora resposta e permite atuação em áreas com conectividade limitada (SHI et al., 2016; SATYANARAYANAN, 2017).

O aprendizado federado pode treinar modelos ambientais distribuídos sem centralizar dados sensíveis de localização. Diferentes bairros podem contribuir para modelos de previsão de ilhas de calor, poluição, alagamentos ou consumo energético. Essa abordagem respeita diferenças territoriais e permite adaptação local (JIANG et al., 2020; PANDYA et al., 2023).

Na gestão de energia, a arquitetura pode coordenar medidores inteligentes, geração distribuída, baterias, iluminação pública, estações de recarga e edifícios públicos. Agentes de borda podem ajustar consumo, detectar falhas e otimizar uso conforme demanda local. Aprendizado federado pode melhorar previsão de carga sem expor perfis individuais de consumo (FANG et al., 2012; SIANO, 2014).

Na gestão de resíduos, sensores em contêineres, rotas de coleta, veículos e estações de triagem podem alimentar modelos de otimização logística. A borda pode detectar enchimento crítico; o sistema federado pode aprender padrões por região; e a decisão adaptativa pode redirecionar rotas de coleta. Isso reduz custo, emissões e falhas operacionais (GUBBI et al., 2013; ZANELLA et al., 2014).

Em drenagem urbana, sensores de chuva e nível podem operar em rede federada para prever alagamentos por microbacia. Cada nó aprende padrões locais, enquanto o sistema global integra conhecimento hidrológico urbano. A decisão adaptativa pode acionar alertas, bombas, bloqueios viários e equipes de manutenção (TUCCI, 2008; BATTY, 2018).

Essas aplicações mostram que a arquitetura cognitiva distribuída não é restrita a um setor. Ela pode funcionar como infraestrutura transversal de inteligência urbana, apoiando múltiplas políticas públicas com dados distribuídos, autonomia local e coordenação institucional.

13. SIMULAÇÕES EM CENÁRIOS URBANOS COMPLEXOS: CRITÉRIOS DE AVALIAÇÃO

Embora este artigo seja propositivo, a validação futura do MICDU-FedEdge pode ocorrer por meio de simulações computacionais em cenários urbanos complexos. Simulações permitem avaliar desempenho, robustez, escalabilidade e adaptação antes da implantação real, especialmente em sistemas críticos (BATTY, 2018; SUTTON; BARTO, 2018).

O primeiro critério de avaliação é latência. A arquitetura deve demonstrar que decisões na borda reduzem tempo de resposta em comparação com processamento exclusivamente centralizado. Esse critério é essencial para aplicações como semáforos, alertas de enchente, veículos conectados e segurança pública (SHI et al., 2016; SATYANARAYANAN, 2017).

O segundo critério é comunicação. Deve-se medir volume de dados transmitidos, número de mensagens, custo de atualização federada

e economia de largura de banda. A hipótese é que o processamento local e o envio de atualizações de modelo podem reduzir transmissão de dados brutos (MCMAHAN et al., 2017; KONEČNÝ et al., 2016).

O terceiro critério é acurácia dos modelos. É necessário comparar modelos federados com modelos locais isolados e modelos centralizados. Em cenários urbanos heterogêneos, o modelo federado pode equilibrar conhecimento global e adaptação local, mas pode sofrer com dados não IID (LI et al., 2020; KAIROUZ et al., 2021).

O quarto critério é robustez a falhas. Simulações devem introduzir desconexões, falhas de sensores, nós maliciosos, atrasos, perda de pacotes e indisponibilidade parcial da rede. Um sistema distribuído deve manter operação aceitável mesmo com falhas parciais (TANENBAUM; VAN STEEN, 2017; SATYANARAYANAN, 2017).

O quinto critério é adaptação a mudanças. Cenários devem incluir eventos inesperados, como chuva extrema, acidentes, bloqueios, eventos esportivos, falhas elétricas ou alterações de demanda. A arquitetura deve ajustar políticas sem depender de reprogramação completa (SUTTON; BARTO, 2018; YANG et al., 2024).

O sexto critério é equidade territorial. Modelos urbanos podem apresentar bom desempenho médio e ainda prejudicar regiões periféricas, pouco sensoriadas ou com dados de menor qualidade. A avaliação deve medir desempenho por território, classe de vulnerabilidade e tipo de infraestrutura (CUTTER; BORUFF; SHIRLEY, 2003; KITCHIN, 2014).

O sétimo critério é segurança. A simulação deve avaliar ataques de envenenamento, atualizações maliciosas, falhas de autenticação e tentativas de inferência. Modelos federados urbanos precisam ser testados contra adversários, pois suas decisões podem afetar infraestrutura crítica (BONAWITZ et al., 2017; KAIROUZ et al., 2021).

O oitavo critério é explicabilidade. Decisões adaptativas devem ser rastreáveis. O sistema deve registrar quais dados, modelos, regras e objetivos orientaram cada ação. Isso é indispensável para auditoria pública e responsabilização institucional (RUDIN, 2019; MITCHELL et al., 2019).

Assim, a validação por simulação deve ser multidimensional. Não basta demonstrar maior acurácia; é preciso avaliar latência, comunicação, robustez, segurança, equidade, adaptação e governança.

14. RESULTADOS DA ANÁLISE

A análise da literatura permite identificar dez resultados principais.

O primeiro resultado é que sistemas urbanos inteligentes exigem arquiteturas distribuídas, pois a centralização integral de dados e decisões tende a ser limitada por latência, custo de comunicação, privacidade e vulnerabilidade operacional (SHI et al., 2016; SATYANARAYANAN, 2017).

O segundo resultado é que arquiteturas cognitivas clássicas oferecem fundamentos úteis, como percepção, memória, raciocínio, aprendizagem e ação, mas precisam ser reinterpretadas para ambientes urbanos distribuídos, multiagentes e ciberfísicos (NEWELL, 1990; ANDERSON, 1996; LAIRD, 2012).

O terceiro resultado é que a computação de borda fornece a infraestrutura operacional para inteligência situada, permitindo decisões locais rápidas, filtragem de dados, redução de tráfego e maior resiliência em caso de falhas de conectividade (SHI et al., 2016; KHAN et al., 2019).

O quarto resultado é que o aprendizado federado é mecanismo promissor para aprendizagem urbana distribuída, pois permite colaboração entre nós sem centralização dos dados brutos, favorecendo privacidade e economia de banda (MCMAHAN et al., 2017; JIANG et al., 2020; PANDYA et al., 2023).

O quinto resultado é que a heterogeneidade dos dados urbanos, especialmente dados não IID, constitui desafio central para aprendizado federado, exigindo agregação robusta, personalização local, seleção de clientes e avaliação por território (LI et al., 2020; KAIROUZ et al., 2021).

O sexto resultado é que a tomada de decisão adaptativa deve combinar aprendizado por reforço, regras explícitas, simulações, análise multicritério e supervisão humana em aplicações críticas (SUTTON; BARTO, 2018; RUSSELL; NORVIG, 2021).

O sétimo resultado é que sistemas multiagentes são adequados para coordenação urbana, pois permitem representar múltiplos dispositivos, serviços e agentes institucionais interagindo em ambiente compartilhado (WOOLDRIDGE, 2009; BUSONI; BABUSKA; DE SCHUTTER, 2008).

O oitavo resultado é que gêmeos digitais urbanos podem funcionar como ambiente de simulação, validação e memória contextual,

reduzindo riscos de implantação direta de políticas adaptativas no mundo real (BATTY, 2018; TAO et al., 2019).

O nono resultado é que segurança, privacidade e governança são componentes estruturais, pois arquiteturas distribuídas ampliam superfície de ataque e podem afetar direitos urbanos se não forem auditáveis (NIST, 2020; FLORIDI; COWLS, 2019).

O décimo resultado é que o MICDU-FedEdge oferece uma estrutura conceitual capaz de integrar borda, federação, cognição, decisão adaptativa, coordenação multiagente e governança em um modelo coerente para cidades inteligentes.

15. DISCUSSÃO

A discussão central deste artigo é que a inteligência urbana do futuro não será puramente centralizada. Cidades inteligentes dependem de sistemas capazes de operar em tempo real, em território distribuído, sob condições variáveis e com múltiplos objetivos. A centralização total pode facilitar controle e padronização, mas tende a produzir latência, alto custo de comunicação, concentração de risco e desafios de privacidade (SHI et al., 2016; KITCHIN, 2014).

O primeiro ponto de discussão refere-se à mudança de paradigma da nuvem central para a cognição distribuída. A nuvem continuará relevante para armazenamento histórico, treinamento pesado, coordenação estratégica e análise de longo prazo. Contudo, decisões urbanas imediatas exigem inteligência próxima ao evento. A arquitetura ideal não substitui nuvem por borda, mas combina nuvem, borda e dispositivos em uma hierarquia cognitiva (SATYANARAYANAN, 2017; KHAN et al., 2019).

O segundo ponto é que o aprendizado federado oferece uma resposta parcial ao dilema entre aprendizagem coletiva e privacidade. A cidade precisa aprender com múltiplos territórios, mas não deve centralizar todos os dados brutos. A federação permite construir modelos compartilhados com menor exposição de dados. Entretanto, não é solução mágica: ainda há riscos de inferência, ataques, vieses e desigualdades entre nós (MCMAHAN et al., 2017; KAIROUZ et al., 2021).

O terceiro ponto refere-se ao caráter não homogêneo da cidade. Dados urbanos são profundamente desiguais. Áreas ricas tendem a ter mais sensores, conectividade e qualidade de dados. Áreas vulneráveis podem ser sub-representadas, justamente onde políticas públicas mais precisam de inteligência. Se a arquitetura federada não considerar equidade territorial, pode reproduzir desigualdades informacionais (KITCHIN, 2014; CUTTER; BORUFF; SHIRLEY, 2003).

O quarto ponto envolve tomada de decisão adaptativa. Sistemas urbanos não podem ser otimizados por uma única métrica. Aumentar velocidade do tráfego pode prejudicar pedestres. Reduzir custo energético pode afetar conforto térmico de escolas. Aumentar vigilância pode reduzir privacidade. Por isso, funções de decisão devem incorporar objetivos públicos múltiplos, transparência e supervisão humana (FLORIDI; COWLS, 2019; RUSSELL; NORVIG, 2021).

O quinto ponto é a necessidade de arquiteturas híbridas. Modelos puramente baseados em aprendizado profundo podem ser poderosos, mas pouco explicáveis. Regras simbólicas são transparentes, mas menos adaptativas. A integração entre aprendizado estatístico, regras, simulação, conhecimento de

domínio e raciocínio simbólico pode produzir sistemas mais seguros e interpretáveis (MARCUS; DAVIS, 2019; RUDIN, 2019).

O sexto ponto refere-se ao papel dos gêmeos digitais. Eles permitem testar políticas antes da implantação, avaliar cenários extremos e reduzir risco de aprendizagem direta em ambiente real. Contudo, gêmeos digitais podem invisibilizar áreas não mapeadas ou dados informais. A qualidade do gêmeo digital depende de inclusão territorial e atualização contínua (BATTY, 2018; KITCHIN, 2014).

O sétimo ponto é a segurança adversarial. Arquiteturas distribuídas podem ser mais resilientes a falhas centralizadas, mas também possuem muitos pontos de entrada. Ataques a nós de borda, envenenamento de modelos federados e manipulação de sensores podem gerar decisões erradas. Segurança precisa ser incorporada em todas as camadas (NIST, 2020; BONAWITZ et al., 2017).

O oitavo ponto é a governança institucional. Sistemas autônomos urbanos não podem operar apenas por critérios técnicos. Eles precisam responder a leis, políticas públicas, direitos fundamentais, prioridades sociais e mecanismos de responsabilização. Quem responde por uma decisão automatizada que prejudica um bairro? Quem audita o modelo? Quem define as métricas de sucesso? Essas perguntas são centrais (FLORIDI; COWLS, 2019; MITCHELL et al., 2019).

O nono ponto é que a descentralização deve ser acompanhada de coordenação. Se cada nó de borda otimizar apenas sua realidade local, pode gerar efeitos sistêmicos negativos. Um semáforo que reduz fila em uma via pode aumentar congestionamento em outra. Uma bomba que drena uma área pode sobrecarregar outra bacia. A

coordenação multiagente e a visão sistêmica são indispensáveis (WOOLDRIDGE, 2009; BATTY, 2013).

O décimo ponto é que arquiteturas cognitivas distribuídas representam oportunidade para cidades mais resilientes. Ao combinar percepção local, aprendizagem federada, simulação, decisão adaptativa e governança, as cidades podem responder melhor a eventos extremos, congestionamentos, falhas de infraestrutura e demandas públicas. Porém, essa oportunidade depende de planejamento, ética e investimento contínuo (MEEROW; NEWELL; STULTS, 2016; YANG et al., 2024).

Assim, o MICDU-FedEdge propõe uma resposta sistêmica à complexidade urbana. Ele reconhece que a inteligência da cidade não deve ficar concentrada em um único centro de comando, mas distribuída entre agentes, bordas, modelos federados, plataformas e instituições. A cidade cognitiva é, portanto, uma rede de inteligência situada, coordenada e governada.

16. DIRETRIZES PARA IMPLEMENTAÇÃO DE ARQUITETURAS COGNITIVAS DISTRIBUÍDAS

A partir da análise realizada, propõem-se diretrizes para implementação de arquiteturas cognitivas distribuídas em cidades inteligentes.

Primeiro, iniciar por problemas urbanos concretos, como mobilidade, alagamentos, iluminação, energia, resíduos ou segurança operacional, evitando projetos genéricos de inteligência artificial sem finalidade pública clara (KITCHIN, 2014; BATTY, 2018).

Segundo, mapear fontes de dados, sensores, sistemas legados, conectividade, atores institucionais, riscos, restrições legais e capacidades técnicas antes da implantação (ZANELLA et al., 2014; NIST, 2020).

Terceiro, adotar computação de borda para aplicações sensíveis à latência, priorizando eventos críticos, filtragem local e autonomia operacional em caso de falha da nuvem (SHI et al., 2016; SATYANARAYANAN, 2017).

Quarto, utilizar aprendizado federado quando dados forem sensíveis, distribuídos ou volumosos, evitando centralização desnecessária de dados brutos (MCMAHAN et al., 2017; PANDYA et al., 2023).

Quinto, considerar heterogeneidade territorial e dados não IID, aplicando personalização local, agregação hierárquica e avaliação por região (LI et al., 2020; KAIROUZ et al., 2021).

Sexto, integrar regras explícitas, modelos estatísticos, aprendizado por reforço, simulação e supervisão humana em decisões críticas (SUTTON; BARTO, 2018; RUSSELL; NORVIG, 2021).

Sétimo, usar gêmeos digitais como ambiente de teste e validação antes da implantação operacional de políticas adaptativas (BATTY, 2018; TAO et al., 2019).

Oitavo, implementar segurança por projeto, incluindo autenticação, criptografia, agregação segura, atualização remota, detecção de anomalias e proteção física de nós de borda (BONAWITZ et al., 2017; NIST, 2020).

Nono, garantir explicabilidade, registros de decisão, auditoria e mecanismos de contestação em decisões automatizadas que afetem cidadãos (RUDIN, 2019; MITCHELL et al., 2019).

Décimo, incorporar indicadores de equidade urbana, avaliando se o sistema melhora ou piora desigualdades territoriais (CUTTER; BORUFF; SHIRLEY, 2003; KITCHIN, 2014).

Décimo primeiro, manter humanos no ciclo decisório para situações de alto risco, emergências, conflitos de interesse ou decisões com impacto social significativo (FLORIDI; COWLS, 2019).

Décimo segundo, adotar interoperabilidade aberta, evitando dependência excessiva de fornecedores e silos tecnológicos (ALFUQAHA et al., 2015; ZANELLA et al., 2014).

Décimo terceiro, planejar manutenção, atualização, monitoramento e sustentabilidade financeira dos nós de borda e sistemas federados (SHI et al., 2016; NIST, 2020).

Décimo quarto, documentar modelos, dados, limitações e métricas por meio de práticas como model cards e datasheets for datasets (MITCHELL et al., 2019; GEBRU et al., 2021).

Décimo quinto, compreender a arquitetura cognitiva distribuída como infraestrutura pública crítica, orientada por eficiência, privacidade, segurança, transparência e justiça urbana.

17. CONSIDERAÇÕES FINAIS

As cidades contemporâneas estão se tornando ambientes computacionais complexos, nos quais sensores, dispositivos, redes,

plataformas, algoritmos, serviços públicos e cidadãos interagem continuamente. Essa realidade exige sistemas autônomos inteligentes capazes de operar em ambientes dinâmicos, distribuídos e sujeitos a incertezas. A centralização integral dos dados e decisões mostra-se insuficiente diante de requisitos de latência, privacidade, escalabilidade e resiliência.

O estudo demonstrou que a computação de borda constitui base operacional para inteligência urbana descentralizada, permitindo processamento próximo aos sensores e usuários. Essa proximidade reduz latência, economiza banda, melhora privacidade e permite resposta local mesmo em situações de falha de conectividade.

O aprendizado federado, por sua vez, oferece mecanismo de aprendizagem coletiva sem centralização integral dos dados brutos. Em cidades inteligentes, essa abordagem pode apoiar modelos de mobilidade, energia, drenagem, monitoramento ambiental, segurança e gestão de recursos, preservando dados locais e permitindo adaptação territorial.

A tomada de decisão adaptativa completa essa arquitetura ao permitir que sistemas urbanos ajustem ações conforme mudanças no ambiente. Aprendizado por reforço, sistemas multiagentes, regras explícitas, simulações e gêmeos digitais podem ser integrados para construir políticas urbanas mais responsivas. Entretanto, aplicações críticas exigem validação, explicabilidade, supervisão humana e limites normativos.

A proposta do MICDU-FedEdge organiza essa integração em nove camadas: físico-sensorial, conectividade, borda cognitiva, aprendizagem federada, memória contextual, raciocínio adaptativo,

coordenação multiagente, decisão operacional e governança. Essa estrutura permite compreender a inteligência urbana como processo distribuído, cooperativo e governado.

Conclui-se que arquiteturas cognitivas distribuídas representam uma fronteira estratégica para sistemas autônomos urbanos. Elas podem ampliar eficiência operacional, reduzir latências, fortalecer privacidade, aumentar robustez, melhorar resposta a eventos críticos e apoiar gestão integrada de recursos públicos. Contudo, sua implantação deve evitar determinismo tecnológico. A cidade inteligente não deve ser apenas cidade automatizada, mas cidade mais segura, justa, resiliente, transparente e orientada ao interesse público.

O futuro dos sistemas urbanos inteligentes dependerá da capacidade de distribuir inteligência sem fragmentar responsabilidade; automatizar decisões sem eliminar controle democrático; aprender com dados sem violar privacidade; e otimizar recursos sem aprofundar desigualdades territoriais. Esse é o desafio central das arquiteturas cognitivas distribuídas aplicadas às cidades do século XXI.

REFERÊNCIAS BIBLIOGRÁFICAS

AL-FUQAHA, Ala; GUIZANI, Mohsen; MOHAMMADI, Mehdi; ALEDHARI, Mohammed; AYYASH, Moussa. Internet of Things: a survey on enabling technologies, protocols, and applications. **IEEE Communications Surveys & Tutorials**, v. 17, n. 4, p. 2347-2376, 2015.

ANDERSON, John R. **ACT: a simple theory of complex cognition**. American Psychologist, v. 51, n. 4, p. 355-365, 1996.

BARROSO, Luiz André; HÖLZLE, Urs; RANGANATHAN, Parthasarathy. **The datacenter as a computer: designing warehouse-scale machines**. 3. ed. Cham: Springer, 2018.

BATTY, Michael. Digital twins. **Environment and Planning B: Urban Analytics and City Science**, v. 45, n. 5, p. 817-820, 2018.

BATTY, Michael. **The new science of cities**. Cambridge: MIT Press, 2013.

BENDER, Emily M.; GEBRU, Timnit; MCMILLAN-MAJOR, Angelina; SHMITCHELL, Shmargaret. On the dangers of stochastic parrots: can language models be too big? In: **Proceedings of the ACM Conference on Fairness, Accountability, and Transparency**. New York: ACM, 2021. p. 610-623.

BONAWITZ, Keith et al. Practical secure aggregation for privacy-preserving machine learning. In: **Proceedings of the 2017 ACM SIGSAC Conference on Computer and Communications Security**. New York: ACM, 2017. p. 1175-1191.

BONAWITZ, Keith et al. Towards federated learning at scale: system design. In: **Proceedings of Machine Learning and Systems**, v. 1, p. 374-388, 2019.

BUSONI, Lucian; BABUSKA, Robert; DE SCHUTTER, Bart. A comprehensive survey of multiagent reinforcement learning. **IEEE Transactions on Systems, Man, and Cybernetics, Part C**, v. 38, n. 2, p. 156-172, 2008.

CATS, Oded; JENELIUS, Erik. Dynamic vulnerability analysis of public transport networks: mitigation effects of real-time information.

Networks and Spatial Economics, v. 14, p. 435-463, 2014.

CRESWELL, John W. **Research design: qualitative, quantitative, and mixed methods approaches**. 4. ed. Thousand Oaks: SAGE, 2014.

CUTTER, Susan L.; BORUFF, Bryan J.; SHIRLEY, W. Lynn. Social vulnerability to environmental hazards. **Social Science Quarterly**, v. 84, n. 2, p. 242-261, 2003.

DOBSON, Simon et al. Fulfilling the vision of autonomic computing. **Computer**, v. 43, n. 1, p. 35-41, 2010.

DWORK, Cynthia; ROTH, Aaron. **The algorithmic foundations of differential privacy**. Hanover: Now Publishers, 2014.

FANG, Xi; MISRA, Satyajayant; XUE, Guoliang; YANG, Dejun. Smart grid: the new and improved power grid: a survey. **IEEE Communications Surveys & Tutorials**, v. 14, n. 4, p. 944-980, 2012.

FLORIDI, Luciano; COWLS, Josh. A unified framework of five principles for AI in society. **Harvard Data Science Review**, v. 1, n. 1, 2019.

GEBRU, Timnit; MORGENSTERN, Jamie; VECCHIONE, Briana; VAUGHAN, Jennifer Wortman; WALLACH, Hanna; DAUMÉ III, Hal; CRAWFORD, Kate. Datasheets for datasets. **Communications of the ACM**, v. 64, n. 12, p. 86-92, 2021.

GONZÁLEZ, Marta C.; HIDALGO, César A.; BARABÁSI, Albert-László. Understanding individual human mobility patterns. **Nature**, v. 453, p. 779-782, 2008.

GRIEVES, Michael. Digital twin: manufacturing excellence through virtual factory replication. Melbourne: Florida Institute of Technology, 2014.

GUBBI, Jayavardhana; BUYYA, Rajkumar; MARUSIC, Slaven; PALANISWAMI, Marimuthu. Internet of Things: a vision, architectural elements, and future directions. **Future Generation Computer Systems**, v. 29, n. 7, p. 1645-1660, 2013.

HOLLING, Crawford S. Resilience and stability of ecological systems. **Annual Review of Ecology and Systematics**, v. 4, p. 1-23, 1973.

HUTCHINS, Edwin. **Cognition in the wild**. Cambridge: MIT Press, 1995.

JIANG, Jiachen; HU, Yuzheng; TYAGI, Nirupam; CHEN, Ran; FLETCHER, George; WU, Zhi. Federated learning in smart city sensing: challenges and opportunities. **Sensors**, v. 20, n. 21, 6230, 2020.

KAIROUZ, Peter et al. Advances and open problems in federated learning. **Foundations and Trends in Machine Learning**, v. 14, n. 1-2, p. 1-210, 2021.

KEPHART, Jeffrey O.; CHESS, David M. The vision of autonomic computing. **Computer**, v. 36, n. 1, p. 41-50, 2003.

KHAN, Latif U.; YAQOOB, Ibrar; TRAN, Nguyen H.; KAZMI, S. M. Ahsan; DANG, Tri Nguyen; HONG, Choong Seon. Edge-computing-enabled smart cities: a comprehensive survey. **IEEE Internet of Things Journal**, v. 7, n. 10, p. 10200-10232, 2020.

KITCHIN, Rob. The real-time city? Big data and smart urbanism. **GeoJournal**, v. 79, p. 1-14, 2014.

KONEČNÝ, Jakub; MCMAHAN, H. Brendan; YU, Felix X.; RICHTÁRIK, Peter; SURESH, Ananda Theertha; BACON, Dave. Federated learning: strategies for improving communication efficiency. **arXiv preprint arXiv:1610.05492**, 2016.

LAIRD, John E. **The Soar cognitive architecture**. Cambridge: MIT Press, 2012.

LEE, Jay; BAGHERI, Behrad; KAO, Hung-An. A cyber-physical systems architecture for Industry 4.0-based manufacturing systems. **Manufacturing Letters**, v. 3, p. 18-23, 2015.

LI, Tian; SAHU, Anit Kumar; TALWALKAR, Ameet; SMITH, Virginia. Federated learning: challenges, methods, and future directions. **IEEE Signal Processing Magazine**, v. 37, n. 3, p. 50-60, 2020.

MARCUS, Gary; DAVIS, Ernest. **Rebooting AI: building artificial intelligence we can trust**. New York: Pantheon Books, 2019.

MCMAHAN, H. Brendan; MOORE, Eider; RAMAGE, Daniel; HAMPSON, Seth; AGÜERA Y ARCAS, Blaise. Communication-efficient learning of deep networks from decentralized data. In: **Proceedings of the 20th International Conference on Artificial Intelligence and Statistics**. PMLR, v. 54, p. 1273-1282, 2017.

MEEROW, Sara; NEWELL, Joshua P.; STULTS, Melissa. Defining urban resilience: a review. **Landscape and Urban Planning**, v. 147, p. 38-49, 2016.

MITCHELL, Margaret et al. Model cards for model reporting. In: **Proceedings of the Conference on Fairness, Accountability, and Transparency**. New York: ACM, 2019. p. 220-229.

MNIH, Volodymyr et al. Human-level control through deep reinforcement learning. **Nature**, v. 518, p. 529-533, 2015.

NEWELL, Allen. **Unified theories of cognition**. Cambridge: Harvard University Press, 1990.

NIST. **NISTIR 8259A: IoT Device Cybersecurity Capability Core Baseline**. Gaithersburg: National Institute of Standards and Technology, 2020.

PANDYA, Sharnil; BHATT, Deep; KOTACHA, Ketan; et al. Federated learning for smart cities: a comprehensive survey. **Sustainable Cities and Society**, v. 94, 104577, 2023.

PARISI, German I.; KEMKER, Ronald; PART, Jose L.; KANAN, Christopher; WERMTER, Stefan. Continual lifelong learning with neural networks: a review. **Neural Networks**, v. 113, p. 54-71, 2019.

RAJKUMAR, Ragunathan; LEE, Insup; SHA, Lui; STANKOVIC, John. Cyber-physical systems: the next computing revolution. In: **Proceedings of the 47th Design Automation Conference**. New York: ACM, 2010. p. 731-736.

RUDIN, Cynthia. Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. **Nature Machine Intelligence**, v. 1, p. 206-215, 2019.

RUSSELL, Stuart; NORVIG, Peter. **Artificial intelligence: a modern approach**. 4. ed. Hoboken: Pearson, 2021.

SATYANARAYANAN, Mahadev. The emergence of edge computing. **Computer**, v. 50, n. 1, p. 30-39, 2017.

SHI, Weisong; CAO, Jie; ZHANG, Quan; LI, Youhuizi; XU, Lanyu. Edge computing: vision and challenges. **IEEE Internet of Things Journal**, v. 3, n. 5, p. 637-646, 2016.

SIANO, Pierluigi. Demand response and smart grids: a survey. **Renewable and Sustainable Energy Reviews**, v. 30, p. 461-478, 2014.

SICARI, Sabrina; RIZZARDI, Alessandra; GRIECO, Luigi Alfredo; COEN-PORISINI, Alberto. Security, privacy and trust in Internet of Things: the road ahead. **Computer Networks**, v. 76, p. 146-164, 2015.

SUTTON, Richard S.; BARTO, Andrew G. **Reinforcement learning: an introduction**. 2. ed. Cambridge: MIT Press, 2018.

TANENBAUM, Andrew S.; VAN STEEN, Maarten. **Distributed systems: principles and paradigms**. 3. ed. Amsterdam: Maarten van Steen, 2017.

TAO, Fei; ZHANG, He; LIU, Ang; NEE, Andrew Y. C. Digital twin in industry: state-of-the-art. **IEEE Transactions on Industrial Informatics**, v. 15, n. 4, p. 2405-2415, 2019.

TORRACO, Richard J. Writing integrative literature reviews. **Human Resource Development Review**, v. 4, n. 3, p. 356-367, 2005.

TUCCI, Carlos E. M. Águas urbanas. **Estudos Avançados**, v. 22, n. 63, p. 97-112, 2008.

VARGHESE, Blesson; WANG, Nan; BARBHUIYA, Sakil; KILPATRICK, Peter; NIKOLOPOULOS, Dimitrios S. Challenges and opportunities in edge computing. **IEEE International Conference on Smart Cloud**, p. 20-26, 2016.

WHITTEMORE, Robin; KNAFL, Kathleen. The integrative review: updated methodology. **Journal of Advanced Nursing**, v. 52, n. 5, p. 546-553, 2005.

WOOLDRIDGE, Michael. **An introduction to multiagent systems**. 2. ed. Chichester: Wiley, 2009.

YANG, Li; LUO, Zhipeng; ZHANG, Shiming; TENG, Fei; LI, Tianrui. Continual learning for smart city: a survey. **arXiv preprint arXiv:2404.00983**, 2024.

ZANELLA, Andrea; BUI, Nicola; CASTELLANI, Angelo; VANGELISTA, Lorenzo; ZORZI, Michele. Internet of Things for smart cities. **IEEE Internet of Things Journal**, v. 1, n. 1, p. 22-32, 2014.

ZHENG, Zhaohua; ZHOU, Yize; SUN, Yilong; WANG, Zhang; LIU, Boyi; LI, Keqiu. Applications of federated learning in smart cities: recent advances, taxonomy, and open challenges. **arXiv preprint arXiv:2102.01375**, 2021.

¹ Doutor em Gestão de Projetos de Tecnologia da Informação e
Doutorando em Engenharia Elétrica pela Universidade de Brasília
(UnB). E-mail: [acesse o artigo original para visualizar o e-mail](#)

