

Integração de Módulos de *Machine Learning* na plataforma Fiware para Cidades Inteligentes

Pedro Miotto Mujica

Universidade Estadual do Oeste do Paraná

Cascavel, Paraná

pedro.mujica@unioeste.br

Marcio Seiji Oyamada

Universidade Estadual do Oeste do Paraná

Cascavel, Paraná

msoyamada@gmail.com

Abstract—Smart cities aim to provide managers and citizens with relevant information that comes from a variety of sources, from sensors to databases, which are increasingly available as the digital transformation progresses. Such solutions have the potential to achieve several goals proposed in the Sustainable Development Goals, such as health, well-being, and sustainable communities. In this context, various applications are emerging in the context of smart cities. One of the basic requirements for a smart city solution is a platform for data storage, processing and visualization. This work aims to integrate Machine Learning modules into the open source smart city platform Fiware. The focus of this study is on the integration of an air quality station developed with low-cost sensors. All layers of the smart city solution are evaluated in this study, starting from the integration with the LoRaWAN network, the deployment of the solution in containers, and the use of Machine Learning modules to correct the data collected by the monitoring station.

Keywords—Smart Cities; Internet of Things; Machine Learning; Fiware.

Resumo—Cidades Inteligentes tem como objetivo disponibilizar para os seus gestores e habitantes informações relevantes obtidas das mais diferentes fontes, desde sensores até bases de dados que cada vez mais estão disponíveis com o avanço da transformação digital. Tais soluções têm o potencial de atingir vários objetivos propostos pelos Objetivos de Desenvolvimento Sustentável tais como: Saúde, bem-estar e comunidades sustentáveis, com isso diversas aplicações surgem como emergentes neste contexto de *Smart Cities*. Dentre os requisitos fundamentais de uma solução para Cidades Inteligentes está uma plataforma para armazenamento e visualização de dados. Este trabalho tem como objetivo integrar módulos de Aprendizagem de Máquina na plataforma de Cidades Inteligentes de código aberto Fiware. O trabalho tem como foco o uso da plataforma no monitoramento da qualidade do ar utilizando sensores de baixo custo. Neste estudo, será avaliado a integração com redes LoRaWAN, a execução da solução em contêineres e a utilização de módulos de Aprendizado de Máquina para a correção dos dados coletados pela estação de monitoramento.

Palavras-chave—Cidades Inteligentes; Internet das Coisas; Aprendizagem de Máquina; Fiware.

I. INTRODUÇÃO

O conceito de Cidades Inteligentes está frequentemente associado ao conceito da nova fase do desenvolvimento urbano, baseada na utilização de tecnologias de informação integrado com serviços da vida urbana [1]. Dessa forma, sua finalidade é direcionada para a otimização do uso de recursos urbanos, a contribuição para a gestão estratégica eficiente e a promoção da qualidade dos serviços oferecidos à população [2]

Para que a implementação das Cidades Inteligentes seja viável, temos o conceito de Internet das Coisas (*Internet of Things* - IoT). Trata-se de um paradigma no qual diversos objetos físicos do cotidiano são conectados a um ambiente digital. Essa abordagem permite que microcontroladores, sensores, dispositivos móveis e outras ferramentas sejam identificados, possibilitando que interajam e colaborem para atingir objetivos comuns [3].

Além disso, o principal destaque da IoT é o seu impacto em aspectos do cotidiano e do comportamento de seus principais usuários. Do ponto de vista do usuário comum, os efeitos da adoção desse paradigma poderão ser perceptíveis no ambiente residencial quanto no de trabalho. Exemplos de aplicações de automação residencial (domótica), vida assistida, saúde digital (*e-health*) e aprendizado aprimorado são apenas alguns contextos que tendem a ser significativamente impactados pela Internet das Coisas. De forma semelhante, o setor empresarial também pode ser atingido por mudanças consideráveis em diversas áreas seja como por exemplo automação, manufatura industrial, logística, gestão de processos e negócios, além do transporte inteligente de pessoas e mercadorias [4].

Considerando a cidade como um centro dinâmico de atividades sociais, econômicas e políticas é fundamental que seu crescimento seja acompanhado de uma gestão eficiente. Caso contrário, efeitos negativos tendem a superar potenciais benefícios, pois a medida que o crescimento populacional intensifica, gestões de recursos ineficientes corroboram para

diversos desafios que se não forem devidamente gerenciados, podem comprometer a sustentabilidade e a funcionalidade dos centros urbanos [5].

Esta tendência do crescimento populacional ocasionou a expansão da infraestrutura urbana que necessita ampliação [2]. Além disso, problemas ambientais e de transporte emergem como questões urgentes, demandando soluções eficazes e imediatas [6]. Diante disso, as Cidades Inteligentes são propostas para mitigar estas dificuldades, por meio do desenvolvimento de uma infraestrutura básica apoiada por sensores, tecnologias de suporte e ambientes inteligentes.

As Cidades Inteligentes podem assumir diversas representações, contudo, de forma geral, sua arquitetura pode ser representada em quatro camadas, como mostrado na Figura 1, adaptada de Ullah et al [7]. A camada de percepção compreende objetos do mundo real — como sensores, drones, câmeras e veículos — que interagem diretamente com o ambiente urbano. Esses dispositivos conectam-se com a camada de rede que garante a transmissão destes dados por meio de variados protocolos de comunicação. Após a obtenção dos dados, estes são tratados na camada de processamento, em que ocorre o armazenamento, análise e tratamento de dados podendo ser possivelmente integrados com modelos de *Machine Learning*. Por último, tais informações são disponibilizadas na camada de aplicação, por meio de *dashboards* e sistemas de visualização que auxiliam no processo de tomada de decisões para a gestão de recursos urbanos.

Neste artigo, apresenta-se um estudo de caso sobre a utilização da plataforma de Cidades Inteligentes Fiware [8] como suporte no monitoramento da qualidade do ar – um parâmetro crítico para a saúde pública e a sustentabilidade urbana. A plataforma visa dar suporte aos dados coletados por uma estação utilizando sensores de baixo custo. Dessa forma, o estudo visa integrar os dados enviados via rede *Long Range Wide Area Network* (LoRaWAN) para armazenamento e visualização na plataforma Fiware e utilizar algoritmos de *Machine Learning* para o tratamento de dados.

A utilização da plataforma, aliada à disponibilização online das informações coletadas, possibilita que gestores públicos e a população em geral tenham acesso a uma visão mais clara e atualizada sobre a qualidade do ar, favorecendo a tomada de decisões e o desenvolvimento de estratégias voltadas à melhoria das condições ambientais.

Este artigo está organizado da seguinte maneira: Seção II discute a fundamentação teórica das Cidades Inteligentes e seus exemplos práticos além de abordar o conceito de *Machine Learning* e trabalhos relacionados; Seção III traz as metodologia e ferramentas utilizadas; Seção IV detalha a visualização dos dados coletados; Seção V apresenta as conclusões e os




Figura 1. Arquitetura em camadas de uma Cidade Inteligente, adaptado de Ullah et al [7].

trabalhos futuros.

II. FUNDAMENTAÇÃO TEÓRICA

A. Plataformas de Cidades Inteligentes

Os projetos de Cidades Inteligentes são orientados a princípios que norteiam as diferentes ideias e políticas aplicadas no contexto urbano. Entre estes pilares estão: Governança, Economia, Ambiental, Mobilidade e Pessoas [9]. Assim, a adoção destes elementos visa o desenvolvimento de soluções eficazes para o gerenciamento urbano, promovendo o uso sustentável dos recursos disponíveis [10].

Diversas iniciativas de Cidades Inteligentes têm direcionado esforços significativos para as áreas ambiental e energética, alinhando-se às metas definidas pela União Europeia para 2050 [10]. A principal iniciativa ocorreu na cidade de Viena, na Áustria, cuja estratégia urbana inclui a meta de reduzir o consumo per capita de energia elétrica em 40% até 2050, tomando como base o ano de 2005. Além disso, pretende-se que, nesse mesmo horizonte, ao menos 50% da energia consumida na cidade seja proveniente de fontes renováveis [10].

Outros projetos focam no desenvolvimento do setor de transportes [11], na assistência médica para idosos e Pessoas com Deficiência (PCD) [12] e no monitoramento de poluição do ar [13]. No entanto, tais soluções inovadoras operam isoladamente

com baixa interoperabilidade entre sistemas causando trabalho duplicado, soluções incompatíveis e uso não otimizado de recursos de aplicações [14].

Ademais as implementações IoT também apresentam desafios relacionados ao desempenho no gerenciamento de dispositivos como sensores, veículos, máquinas automáticas que demandam processamento e análise de dados em tempo real. Além disso, a diversidade de protocolos de comunicação intensifica a heterogeneidade tecnológica, comprometendo a interoperabilidade entre dispositivos e sistemas [15].

Neste contexto, as plataformas unificadas surgem para viabilizar a convergência destes dados e facilitar o processo de integração, gerenciamento e desenvolvimento de aplicações para Cidades Inteligentes [14]. As plataformas também permitem comunicação entre diferentes protocolos e a integração com aplicações de *Machine Learning*, Segurança e *Big Data*, tornando o ecossistema mais completo e integrado.

Neste artigo, adotamos a plataforma *open-source* Fiware como o ecossistema central para o estudo de caso voltado ao monitoramento de qualidade do ar. A plataforma surgiu a partir da parceria entre a iniciativa pública e privada *Future Internet Public-Private Partnership* (FI-PPP), com o objetivo de acelerar o desenvolvimento e a adoção de tecnologias como IoT, Cloud e *Big Data* no contexto Europeu. Atualmente, a gerência do projeto é feita pela *Fiware Foundation*, organização sem fins lucrativos que realiza a manutenção e o desenvolvimento de novas ferramentas [16].

A plataforma possui padrões de coleta, armazenamento e publicação de dados, tendo como exemplo os dados de contexto que representam o estado atual de entidades como sensores, aplicações de tempo real e outros. Além disso, a plataforma também oferece ferramentas de comunicação multiprotocolo e diversidade entre linguagens e protocolos IoT possibilitando a integração facilitada com outros sistemas e soluções em múltiplas redes.

Dentre o vasto catálogo das ferramentas do Fiware, a classificação ocorre de acordo com 5 principais categorias: ferramentas de *Deployment*, gerenciamento de contexto, processamento, análise e monitoramento de Contexto, Interface para IoT e Robótica, como apresentado na Figura 2.

B. Machine Learning

De maneira complementar aos componentes do Fiware, outro conceito importante é o aprendizado de máquina (*Machine Learning* - ML), campo de estudo que está relacionado ao desenvolvimento e projeto de algoritmos que permitem sistemas computacionais de aprender padrões ou realizar tarefas sem serem explicitamente programados [17]. Devido ao fato de ser uma área bastante ampla, diferentes métodos para a Aprendi-




Figura 2. Classificação dos componentes [15].

zagem de Máquina são usados em diversos cenários do mundo real.

De maneira geral, problemas de aprendizado de máquina são divididos em dois grupos principais. Quando o objetivo é associar variáveis de entrada com um conjunto finito de categorias, temos um problema de classificação. Como exemplo, a análise de sentimentos em textos, no qual dado um conjunto de entrada contendo vários textos, no qual um conjunto de entradas é classificado em categorias, como textos felizes ou tristes. Por outro lado, no caso da saída corresponder a uma ou mais variáveis contínuas, trata-se de um problema de regressão [17], como exemplo podemos citar a previsão do valor de uma moeda a partir de indicadores econômicos. Na aplicação desenvolvida foi utilizado o Método *Random Forest Regressor* para o estudo de caso do monitoramento de qualidade do ar, visto que a resposta de sensores de baixo custo pode variar conforme ocorre variações em condições ambientais como temperatura e umidade.

C. Trabalhos relacionados

A utilização da plataforma Fiware para impulsionar o desenvolvimento de Cidades Inteligentes não é recente na literatura. Devido à sua natureza *open-source* e arquitetura abrangente, o Fiware tem sido amplamente adotado em iniciativas para Cidades Inteligentes em diversos contextos, seja para agricultura, transporte ou gerenciamento de dispositivos. Mesmo com limitações, a plataforma contribuiu na integração de dados heterogêneos de diversas fontes, servindo como base para aplicações de Cidades Inteligentes que utilizam seus componentes de segurança e gerenciamento de dados através do uso de *Application Programming Interface* (API) [18].

A plataforma Fiware também tem sido explorada em conjunto com técnicas de Aprendizagem de Máquina (AM), ampliando suas possibilidades de aprimoramento de serviços

oferecidos em Cidades Inteligentes. Um exemplo relevante é o trabalho de Conde et al [19], que propõem uma arquitetura Fiware estendida para dar suporte a operações de *Tiny Machine Learning* (*TinyML*) que envolve o uso de dispositivos de borda, com foco especial em soluções para mobilidade urbana inteligente. O autor descreve todas as etapas do ciclo de vida de um modelo de Inteligência Artificial — desde o treinamento e a implantação até a inferência local — em uma arquitetura compatível com os componentes e funcionalidades disponíveis no catálogo da Fiware.

III. METODOLOGIA

A. Estudo de caso

O monitoramento ambiental, em especial a qualidade do ar, é de extrema relevância no contexto de Cidades Inteligentes. Segundo Martina Otto, do Programa Ambiental das Nações Unidas (*United Nations Environment Program* - UNEP), a poluição do ar representa uma emergência tanto em termos de saúde pública quanto para o clima global [20]. Recentemente, a Organização Mundial da Saúde, estimou que os efeitos da poluição do ar em ambientes internos e externos são associados a 6,7 milhões de mortes prematuras por ano no mundo [21].

No Brasil há um número reduzido de estações de monitoramento [22], que estão concentradas em grandes centros urbanos. No estado do Paraná, o Instituto Água e Terra (IAT) possui oito estações automáticas de amostragem do ar na Região Metropolitana de Curitiba e seis estações distribuídas pelas cidades de Ponta Grossa, Paranaguá, Londrina, Maringá, Foz do Iguaçu e Cascavel. Contudo, nem todas essas estações monitoram integralmente os parâmetros definidos pelo Conselho Nacional do Meio Ambiente (CONAMA) [23]. A baixa cobertura e a distribuição esparsa desses pontos de coleta refletem, em grande parte, o alto custo associado à aquisição, instalação e manutenção dos equipamentos tradicionais.

Diante desse cenário, o presente trabalho foi desenvolvido com foco no contexto do monitoramento da qualidade do ar, tema de relevância para Cidades Inteligentes. Esse estudo faz parte do desenvolvimento do projeto EnvCity, cujo objetivo é estabelecer uma rede de monitoramento da qualidade do ar e da água por meio do uso de sensores de baixo custo e transmissão de dados em tempo real, tornando essas informações acessíveis à sociedade [24].

No entanto, o projeto EnvCity contempla somente o processo de coleta dos dados, sem dispor de mecanismos padronizados para o gerenciamento de informações relacionadas a qualidade do ar, limitando o uso prático da estação no cotidiano de gestores da cidade. Assim, com o objetivo de superar esta limitação foi realizada a integração ao ecossistema Fiware, possibilitando a coleta, o processamento e a visualização de dados ambientais em tempo real.

O projeto EnvCity também inclui avanços significativos na calibração de sensores para detecção de material particulado (MP) utilizando técnicas de aprendizado de máquina, além de estudos voltados à análise da qualidade da água e à detecção de odores em ambientes urbanos [25] [26] [27].

A base de dados utilizada neste trabalho possui a coleta de informações sobre a qualidade do ar, utilizando sensores de baixo custo para o monóxido de carbono, dióxido de nitrogênio, dióxido de enxofre e ozônio, realizada ao lado de uma estação de referência [28]. Foi realizado o treinamento de um modelo de ML baseado no método *Random Forest* (RF). Esse algoritmo é construído a partir geração de conjuntos de árvores de decisões que formam uma floresta de modelos combinados a fim de solucionar o mesmo problema. O uso conjunto dessas árvores tende a produzir previsões mais robustas do que uma única árvore [29]. Embora amplamente usado para problemas de classificação, o *Random Forest* tem sua versão adaptada para problemas de regressão em que a saída é dada pela média de previsões feitas por várias árvores [30].

Neste modelo ML treinado usando *Random Forest*, a predição da concentração de monóxido de carbono (CO) obtida pelos sensores de baixo custo foi corrigida considerando a temperatura e umidade, a partir de valores obtidos por uma estação de referência instalada na cidade de São Paulo. Após a etapa de pré-processamento e limpeza da base de dados, o modelo apresentou os resultados apresentados na Figura 3, onde *iag_co* são os dados da estação de referência.




Figura 3. Comparação entre valores preditos e observados de monóxido de carbono utilizando *Random Forest*

No gráfico, os coeficientes de determinação (R^2) expressam a qualidade do ajuste do modelo. Esse índice varia de zero a

um e indica a proporção da variabilidade dos dados de saída do modelo. Como os valores obtidos estão próximos de um, o modelo demonstra alta precisão e boa capacidade de aprender a relação entre as variáveis.

B. Arquitetura do projeto

Visando a integração da plataforma para a coleta de dados provenientes da estação EnvCity, várias ferramentas foram empregadas. No gerenciamento das informações de contexto em tempo real foi utilizado o Orion Context Broker [31], a principal ferramenta Fiware que utiliza a interface de API NGSI v2 [32]. O Orion permite que diferentes sistemas acessem e monitorem o estado de entidades em um ambiente conectado.

A arquitetura de comunicação utilizado no Orion segue o modelo *Publish/Subscribe* em que entidades publicam informações para o *Broker* central e somente assinantes inscritos em determinado tópico recebem as notificações do tópico correspondente. Dessa maneira, o *Context Broker* atua como intermediário para troca de dados entre editores e assinantes. As informações referentes às entidades, inscrições e registros do Broker são armazenadas no Banco de Dados *NoSQL* MongoDB [33].

Para conectar o Context Broker ao servidor The Things Stack [34], servidor LoRaWAN responsável por receber dados referentes a qualidade do ar, foi utilizado o LoRaWAN IoT Agent [35]. Esse componente serve como ponte de comunicação entre a interface NGSI e o conjunto de protocolos LoRaWAN em que a integração entre os dados oriundos do servidor ocorre a partir de um cliente do protocolo *Message Queue Telemetry Transport* (MQTT) [36].

No entanto, como o Orion não é ideal para a persistência de grande quantidade de dados devido a limitações de armazenamento, o conector *Cygnus Connector* [37] é utilizado para coletar dados históricos do Orion e armazenar estes dados no Banco de Dados PostgreSQL [38]. Por fim, a visualização dos dados é realizada pelo Grafana que tem o PostgreSQL configurado como fonte de dados.

Com o modelo *Random Forest* treinado na Figura 3, a integração do modelo com a arquitetura Fiware, foi incorporada por meio do desenvolvimento de uma API, com a finalidade de realizar a correção do Monóxido de Carbono utilizando o modelo RF treinado anteriormente. O modelo cliente-servidor *Representational State Transfer* (REST) utiliza o protocolo *Hypertext Transfer Protocol* (HTTP) que estabelece um acordo de comunicação para adquirir recursos de hipertexto, após o pedido de acesso os dados são retornados em um tipo específico de arquivo, podendo ser *JavaScript Object Notation* (JSON) ou *Extensible Markup Language* (XML) dentre outros.

Com essa abordagem, qualquer cliente pode realizar uma requisição por meio de um *Uniform Resource Locator* (URL) e assim, receber os dados solicitados de forma estruturada.

Assim, processos internos permanecem abstraídos de forma que o usuário não precisa conhecer os detalhes da lógica de processamento por trás da obtenção dos dados.

No contexto do artigo, a API apresenta uma URL que retorna os dados corrigidos pelo modelo ML para Orion toda vez que um sensor envia um novo *payload*. Após o recebimento, o atributo correspondente é atualizado com o novo valor gerado pelo modelo de Aprendizagem de Máquina, previamente carregado no código da API. Na Figura 4 podemos visualizar o processo de maneira mais clara.




Figura 4. Diagrama de etapas realizadas pela API de *Machine Learning*

O desenvolvimento da ferramenta foi realizado utilizando o *framework* Python [39] FastAPI [40] que permite rapidez e simplicidade na implementação de requisições HTTP, além de oferecer suporte a operações assíncronas.

Por último para a configuração e comunicação de todos componentes da arquitetura a fim de garantir um ambiente flexível, escalável com fácil implantação, os serviços foram executados em containers Docker [41], que permitem que cada serviço opere de maneira isolada, evitando conflitos de dependências e simplificando a montagem. Além disso, com o uso do Docker-Compose [42], é possível gerenciar a implantação de todos os serviços por meio de um único arquivo de configuração, garantindo que o sistema funcione de maneira consistente em qualquer ambiente. A Figura 5 apresenta a organização dos diferentes componentes juntamente com a Tabela I que resume suas funcionalidades.

IV. VISUALIZAÇÃO

Além da integração bem-sucedida, os dados estão podem ser visualizados utilizando um *dashboard* interativo no Grafana, permitindo que qualquer período de dados armazenado no banco de dados. Para organização dos atributos, foram desenvolvidos três painéis de gráficos. Foram coletados dados referentes a concentração dos gases monóxido de carbono (CO), óxidos de nitrogênio (NO₂), óxidos de enxofre (SO₂) e ozônio (OX), além da temperatura e da umidade, fornecendo uma visão geral das condições da qualidade do ar. A Figura 6 ilustra um exemplo desses dados registrados no banco de




Figura 5. Arquitetura e componentes do Projeto



Figura 6. Dados coletados referentes ao dióxido de enxofre




Figura 7. Visualização da Umidade e Temperatura no Dashboard Grafana.

Tabela I
PAPEL DOS COMPONENTES FIWARE NA ARQUITETURA PROPOSTA

Componente	Função
Orion Context Broker	Comunicação em tempo real via NGSI-v2
IoT Agent LoRaWAN	Comunicação com dispositivos IoT (protocolo LoRaWAN)
Cygnus	Ingestão de dados históricos
PostgreSQL	Armazenamento de dados históricos
Grafana	Visualização de dados
API Machine Learning	Processamento com <i>Random Forest Regressor</i> para correção de dados
MongoDB	Armazenamento de entidades contextuais
Docker	Containerização e orquestração de serviços

dados PostgreSQL e observados pelo Grafana, obtidos a partir do sensor da estação de baixo custo EnvCity. Na Figura 7 visualizamos os dados referentes ao Dióxido de Enxofre somente.

Além disso, foram coletados com sucesso os dados de umidade e temperatura, também provenientes da mesma estação de baixo custo, integrando-se plenamente ao fluxo de informações do sistema que podem ser visualizados na Figura 7.

V. CONCLUSÃO

Após os testes e ajustes realizados, foi disponibilizado o endereço <https://fiware.unioeste.br/> para garantir o acesso remoto ao *dashboard*. Com isso, usuários podem visualizar e analisar os dados da estação *EnvCity* de qualquer local.

Dessa maneira, a arquitetura proposta cumpriu seu objetivo de demonstrar um projeto containerizado de código aberto voltado para visualização e processamento de dados oriundos de dispositivos IoT. No entanto, a principal contribuição está na viabilização da integração entre dados de uma estação com algoritmos de aprendizagem de máquina, promovendo um ambiente flexível para a análise preditiva.

No estudo de caso apresentado, optou-se pelo uso do algoritmo regressivo *Random Forest* devido a performance satisfatória apresentado na previsão da concentração de monóxido de carbono (CO). No entanto, a arquitetura atual possibilita, sem grandes modificações, a integração com outros modelos de regressão ou classificação, favorecendo estudos comparativos e ampliando o potencial de aplicação. Dessa forma, esta solução *open-source* que utiliza componentes da Plataforma Fiware contribui para o fortalecimento do paradigma das Cidades Inteligentes favorecendo gestores nas tomadas de decisões no meio urbano.

Como trabalhos futuros, existe a necessidade de exploração de outros modelos de aprendizado de máquina, além do *Random Forest* com o objetivo de comparar os desempenhos e aumentar a precisão das previsões dos poluentes monitorados. Também, pretende-se investigar o uso de diferentes plataformas de visualização ou outros tipos de *dashboards* personalizados para oferecer interfaces adaptáveis a diferentes públicos.

Outro trabalho futuro trata da verificação da escalabilidade da solução desenvolvida, que envolve testar o desempenho da aplicação com múltiplas estações simultaneamente, avaliando o comportamento do sistema quanto ao processamento de dados,

tempo de resposta e integridade das informações no ecossistema Fiware. Este trabalho se torna essencial para verificar a viabilidade da implementação do projeto em cenários de larga escala, como em redes municipais ou regionais de monitoramento ambiental.

Essas possibilidades abrem caminho para a consolidação de uma arquitetura robusta, inteligente e replicável para aplicações em Cidades Inteligentes voltadas à gestão da qualidade do ar.

AGRADECIMENTOS

Agradecimentos à Fundação Araucária pelo financiamento da bolsa de pesquisa e à Universidade Estadual do Oeste do Paraná.

REFERÊNCIAS

- [1] J. P. G. Sterbenz, "Smart city and iot resilience, survivability, and disruption tolerance: Challenges, modelling, and a survey of research opportunities," in *Proceedings of the 2017 9th International Workshop on Resilient Networks Design and Modeling (RNDM)*, Alghero, Italy, September 2017, pp. 1–6.
- [2] A. Zanella, N. Bui, A. Castellani, L. Vangelista, and M. Zorzi, "Internet of things for smart cities," *IEEE Internet of Things Journal*, vol. 1, no. 1, pp. 22–32, 2014, citado na página 12.
- [3] D. Giusto, A. Iera, G. Morabito, and L. Atzori, Eds., *The Internet of Things*. New York, NY, USA: Springer, 2010.
- [4] L. Atzori, A. Iera, and G. Morabito, "The internet of things: A survey," *Computer Networks*, vol. 54, no. 15, pp. 2787–2805, 2010.
- [5] A. Monzón, "Smart cities concept and challenges: Bases for the assessment of smart city projects," in *2015 International Conference on Smart Cities and Green ICT Systems (SMARTGREENS)*, [S.l.: s.n.], 2015, pp. 1–11, citado na página 12.
- [6] C. J. Barrow, *Developing the Environment: Problems & Management*, 1st ed. Abingdon, UK: Routledge, 2014.
- [7] S. Ullah, F. Amin, S. Ahmad, K.-I. Kim, H. A. Khattak, and A. Almogren, "A survey on artificial intelligence and blockchain applications in cybersecurity for smart cities," *IEEE Access*, vol. 10, pp. 90 114–90 134, 2022.
- [8] F. Cirillo, G. Solmaz, E. L. Berz, M. Bauer, B. Cheng, and E. Kovacs, "A standard-based open source IoT platform: FIWARE," *IEEE Internet of Things Magazine*, vol. 2, no. 3, pp. 12–18, 2019.
- [9] R. Giffinger, C. Fertner, H. Kramar, R. Kalasek, N. Pichler-Milanovic, and E. Meijers, "City-ranking of european medium-sized cities," Centre of Regional Science, Vienna University of Technology, Vienna, Austria, Tech. Rep., 2007, citado na página 12.
- [10] V. Fernández-Añez, J. M. Fernández-Güell, and R. Giffinger, "Smart city implementation and discourses: An integrated conceptual model. the case of vienna," *Cities*, vol. 78, pp. 4–16, 2018, citado na página 12. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0264275117306558>
- [11] S. Djahel, R. Doolan, G.-M. Muntean, and J. Murphy, "A communications-oriented perspective on traffic management systems for smart cities: Challenges and innovative approaches," *IEEE Communications Surveys & Tutorials*, vol. 17, no. 1, pp. 125–151, 2014.
- [12] F. Hussain, K. Muhammad, M. Alam, W. Afzal, and O. Khalid, "Health monitoring and management system using iot sensors and cloud computing," *International Journal of Computer Applications*, vol. 120, no. 7, pp. 1–5, 2015.
- [13] A. Vakali, L. Anthopoulos, I. Chondromatidis, and S. Kafetzoglou, "Sen2soc: Leveraging social media and iot for smart city services," *Proceedings of the 2014 IEEE International Conference on Big Data*, pp. 181–186, 2014.
- [14] E. F. Z. Santana, A. P. Chaves, M. A. Gerosa, F. Kon, and D. S. Milojicic, "Software platforms for smart cities: Concepts, requirements, challenges, and a unified reference architecture," *ACM Computing Surveys*, vol. 49, no. 3, pp. 1–37, 2016. [Online]. Available: <https://doi.org/10.1145/3126291>
- [15] G. D. Panfilis, "Fiware integrated iot platform managing product life cycle," FIWARE Foundation, e.V., Impact Story, Feb. 2021, impact story published on FIWARE website.
- [16] FIWARE Foundation, "About us," 2024, acessado em: 27 out. 2024. [Online]. Available: <https://www.fiware.org/about-us/>
- [17] M. M. Roncaglio, "Estação de baixo custo para monitoramento da qualidade do ar," Master's thesis, Programa de Pós-Graduação em Ciência da Computação, 2023, centro de Ciências Exatas e Tecnológicas. [Online]. Available: <https://tede.unioeste.br/handle/tede/7090>
- [18] J. Pereira, T. Batista, E. Cavalcante, A. Souza, F. Lopes, and N. Cacho, "A platform for integrating heterogeneous data and developing smart city applications," *Future Generation Computer Systems*, vol. 128, pp. 552–566, 2022.
- [19] J. Conde, A. Munoz-Arcenales, Alonso, J. Salvachúa, and G. Huecas, "Enhanced fiware-based architecture for cyberphysical systems with tiny machine learning and machine learning operations: A case study on urban mobility systems," *IT Professional*, vol. 26, no. 5, pp. 55–61, 2024.
- [20] United Nations, "The air that keeps us alive is making us sick," 2022. [Online]. Available: <https://news.un.org/en/story/2022/09/1126101>
- [21] OMS – ORGANIZAÇÃO MUNDIAL DA SAÚDE, "Household air pollution and health," 2023. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/household-air-pollution-and-health>
- [22] I. de Energia e Meio Ambiente. (2024) Dimensionamento da rede básica de monitoramento da qualidade do ar no brasil - brasil precisa de no mínimo mais 46 estações de monitoramento da qualidade do ar. Acesso em: 20 abr. 2024. [Online]. Available: https://energiaeambiente.org.br/wp-content/uploads/2024/02/202402_dimensionamentotarIEMA.pdf
- [23] CONSELHO NACIONAL DO MEIO AMBIENTE, "Resolução nº 491, de 19 de novembro de 2018," Diário Oficial da União. [Online]. Available: https://www.in.gov.br/web/guest/materia/asset_publisher/Kujrw0TZC2Mb/content/id/51058895/do1-2018-11-21-resolucao-n-491-de-19-de-novembro-de-2018-510588603
- [24] FAPESP, "Development of environmental quality monitoring network in smart cities - envcity," Fundação de Amparo à Pesquisa do Estado de São Paulo, 2023, citado na página 15. [Online]. Available: <https://bv.fapesp.br/en/auxilios/108005/development-of-environmental-quality-monitoring-network-in-smart-cities-envcity/>
- [25] F. Xavier and Others, "Evaluation of low-cost sensors for real-time water quality monitoring," in *2022: Anais Estendidos do XII Simpósio Brasileiro de Engenharia de Sistemas Computacionais*, [S.l.: s.n.], 2022, pp. 56–61, citado na página 15.
- [26] L. Martins, E. Camargo, and M. Morais, "Low-cost sensors for odor monitoring: The state of the art and challenges," in *Proceedings of the ...*, [S.l.: s.n.], 2023, pp. 01–04, citado na página 15.
- [27] A. F. Pastório and Others, "A machine learning-based approach to calibrate low-cost particulate matter sensors," in *2022 XII Brazilian Symposium on Computing Systems Engineering (SBESC)*, [S.l.: s.n.], 2022, pp. 1–8, citado 2 vezes nas páginas 15 e 35.
- [28] M. M. Roncaglio, E. T. de Camargo, L. D. Martins, and M. S. Oyamada, "Development of an air quality station using low-cost sensors," in *2023 XIII Brazilian Symposium on Computing Systems Engineering (SBESC)*, 2023, pp. 1–6.
- [29] T. G. Dietterich, "Ensemble learning," in *The Handbook of Brain Theory and Neural Networks*, 2nd ed., M. A. Arbib, Ed. MIT Press, 2002, pp. 110–125.
- [30] L. Breiman, "Random forests," *Machine Learning*, vol. 45, no. 1, pp. 5–32, 2001, citado na página 28.
- [31] FIWARE, "Orion Context Broker documentation," 2024. [Online]. Available: <https://fiware-orion.readthedocs.io/en/master/>
- [32] —, "NGSI v2 tutorials," 2024. [Online]. Available: <https://github.com/FIWARE/tutorials.NGSI-v2>

- [33] MongoDB, “MongoDB: The developer data platform,” 2024. [Online]. Available: <https://www.mongodb.com>
- [34] The Things Industries, “The Things Stack: Open Source LoRaWAN Network Server,” 2024. [Online]. Available: <https://www.thethingsindustries.com/stack/>
- [35] FIWARE, “LoRaWAN IoT Agent documentation,” 2024. [Online]. Available: <https://fiware-lorawan.readthedocs.io/en/latest/>
- [36] OASIS, “MQTT Version 5.0: Standard for Lightweight Publish-Subscribe Messaging Protocol,” 2024. [Online]. Available: <https://mqtt.org/>
- [37] FIWARE, “Cygnus documentation,” 2024. [Online]. Available: <https://fiware-cygnus.readthedocs.io/en/latest/>
- [38] PostgreSQL Global Development Group, “PostgreSQL: The World’s Most Advanced Open Source Relational Database,” 2024. [Online]. Available: <https://www.postgresql.org>
- [39] Python Software Foundation, “Python: Official Website,” 2024. [Online]. Available: <https://www.python.org/>
- [40] FastAPI, “FastAPI: Official Documentation,” 2024. [Online]. Available: <https://fastapi.tiangolo.com/>
- [41] I. Docker, “Docker documentation,” <https://docs.docker.com/>, 2024, acessado em: 27 out. 2024.
- [42] —, “Docker compose documentation,” <https://docs.docker.com/compose/>, 2024, acessado em: 27 out. 2024.