



# DESDE A BASE

DESAFIOS E OPORTUNIDADES NO CONTEXTO DA  
AMÉRICA LATINA E DO CARIBE

# IA

## DESDE A BASE

DESAFIOS E OPORTUNIDADES NO CONTEXTO DA  
AMÉRICA LATINA E DO CARIBE

### **Autores**

Guillermo Cruz

Alexander Riobó

María Angélica Pfeifer

Diana Duarte

### **Design e diagramação**

.Puntoaparte

Setembro 2024

## Catálogo na fonte fornecida pela

### Biblioteca Felipe Herrera do

#### Banco Interamericano de Desenvolvimento

IA desde a base: desafios e oportunidades no contexto da América Latina e do Caribe / Guillermo Cruz, Alexander Riobó, María Angélica Pfeifer, Diana Duarte.

p. cm. — (Monografia do BID ; 1247)

Inclui referências bibliográficas.

1. Inteligência artificial - América Latina. 2. Inteligência artificial - Área do Caribe. 3. Infraestrutura (Economia) - Efeito das inovações tecnológicas na América Latina. 4. Infraestrutura (Economia) - Efeito das inovações tecnológicas na Área do Caribe. I. Cruz, Guillermo. II. Riobó Patino, Alexander. III. Pfeifer, María Angélica. IV. Duarte, Diana. V. Banco Interamericano de Desenvolvimento. Divisão de Transportes. VI. Banco Interamericano de Desenvolvimento. Divisão de Energia. VII. Banco Interamericano de Desenvolvimento. Divisão de Água e Saneamento. VIII. Banco Interamericano de Desenvolvimento. Setor de Infraestrutura e Energia. IX. Série.

IDB-MG-1247

Palavras-chave: Inteligência Artificial, infraestrutura inteligente, transformação digital, Deep learning / Códigos JEL: O31, O32, O33

Design e diagramação: .Puntoaparte

Dezembro de 2024

Copyright © 2024 Banco Banco Interamericano de Desenvolvimento (BID). Esta obra está sujeita a uma licença Creative Commons CC BY 3.0 IGO (<https://creativecommons.org/licenses/by/3.0/igo/legalcode>). Os termos e condições indicados no link URL devem ser cumpridos e o devido reconhecimento deve ser dado ao BID.

De acordo com a seção 8 da licença indicada, qualquer mediação relacionada a disputas que surjam sob esta licença será realizada de acordo com o Regulamento de Mediação da OMPI. Qualquer disputa relacionada ao uso das obras do BID que não possa ser resolvida amigavelmente será submetida à arbitragem de acordo com as regras da Comissão das Nações Unidas para o Direito Comercial Internacional (CNUDMI). O uso do nome do BID para qualquer finalidade diferente do devido reconhecimento e o uso do logotipo do BID não são autorizados por esta licença e requerem um acordo de licença adicional.

Observe que o link URL inclui termos e condições que fazem parte integrante desta licença.

As opiniões expressas nesta obra são exclusivamente dos autores e não refletem necessariamente o ponto de vista do BID, de seu Conselho Executivo ou dos países que representa.



# CONTEÚDO



**INTRODUÇÃO**  
**6**

**O QUE É INTELIGÊNCIA ARTIFICIAL?**  
**8**

2.1 Definição de Inteligência Artificial  
**8**

2.2 Tipos de sistemas de IA  
**12**

**IA NOS SETORES DE INFRAESTRUTURA: OPORTUNIDADES E APLICAÇÕES**  
**21**

3.1 A importância das infraestruturas críticas  
**21**

3.2 Oportunidades e aplicações de IA nos setores de infraestrutura  
**22**

**CONSIDERAÇÕES SOBRE A ADOÇÃO DA IA NOS SETORES DE INFRAESTRUTURA**  
**45**

4.1 Metodologia de desenvolvimento ágil para soluções baseadas em IA  
**45**

4.2 Princípios recomendados para o desenvolvimento de soluções de IA  
**67**

**CONCLUSÕES E RECOMENDAÇÕES**  
**70**

Recomendações gerais  
**71**

Recomendações na fase de identificação de oportunidades e planejamento de soluções  
**72**

Recomendações na fase de desenvolvimento de protótipos e soluções  
**73**

Recomendações na fase de implementação, manutenção e aumento de escala da solução  
**74**

**ANEXOS**  
**76**

Anexo 1. Revisão dos marcos regulatórios da IA na ALC  
**76**

Anexo 2. Metodologia das entrevistas  
**87**

Referências  
**90**

## Índice de Figuras e Quadros

<b>Figura 1.</b> Sistema de Inteligência Artificial	<b>9</b>
<b>Figura 2.</b> Sistemas de IA	<b>12</b>
<b>Figura 3.</b> Representação de uma rede neural de camada única (Perceptron)	<b>13</b>
<b>Figura 4.</b> Modelo de redes neurais multicamadas	<b>14</b>
<b>Figura 5.</b> Esquema dos três principais tipos de aprendizagem em ML	<b>18</b>
<b>Figura 6.</b> Descrição do caso Pavimenta2	<b>29</b>
<b>Figura 7.</b> Descrição do caso ViaSegura	<b>31</b>
<b>Figura 8.</b> Descrição do caso Energizado	<b>34</b>
<b>Figura 9.</b> Descrição do caso Aquadata	<b>39</b>
<b>Figura 10.</b> Esboço da abordagem ágil de inovação e desenvolvimento	<b>46</b>
<b>Figura 11.</b> Condução de dados	<b>56</b>
<b>Quadro 1.</b> Marcos regulatórios de proteção de dados na América Latina	<b>77</b>
<b>Quadro 2.</b> Marcos regulatórios da IA na América Latina	<b>81</b>

## Glossário de Acrônimos

<b>ALC</b>	América Latina e o Caribe	<b>GPS</b>	Sistema de Posicionamento Global
<b>ANN</b>	Redes Neurais Artificiais	<b>GPU</b>	Unidade de Processamento Gráfico
<b>API</b>	Interface de Programação de Aplicações	<b>IA</b>	Inteligência Artificial
<b>ATMS</b>	Sistemas Avançados de Gestão do Tráfego	<b>iRAP</b>	Programa Internacional de Avaliação de Estradas
<b>BID</b>	Banco Interamericano de Desenvolvimento	<b>IoT</b>	Internet das Coisas
<b>CAF</b>	Banco de Desenvolvimento da América Latina e do Caribe	<b>LLM</b>	Modelos Linguísticos de Grande Dimensão
<b>CNN</b>	Redes Neurais Convolucionais	<b>ML</b>	Aprendizagem Automática
<b>DL</b>	Aprendizagem Profunda	<b>MVP</b>	Produto Mínimo Viável
<b>DNP</b>	Departamento Nacional de Planejamento da Colômbia	<b>PNL</b>	Processamento de Linguagem Natural
<b>DT</b>	Gêmeos Digitais	<b>OCDE</b>	Organização para a Cooperação e Desenvolvimento Econômico
<b>EPMAPS</b>	Empresa Pública Metropolitana de Água Potável e Saneamento de Quito	<b>SVM</b>	Máquina de Suporte Vetorial
<b>ETL</b>	Extrair Transformar Carregar	<b>UAVs</b>	Veículos Aéreos não Tripulados
<b>MEF</b>	Fórum Econômico Mundial	<b>UPS</b>	Fonte de Alimentação Ininterrupta
<b>FMI</b>	Fundo Monetário Internacional	<b>YOLO</b>	Só se olha uma vez



# INTRODUÇÃO

A Inteligência Artificial (IA) adquiriu uma importância crucial pela sua capacidade de transformar, significativamente, vários setores econômicos e múltiplas dimensões da sociedade. O potencial impacto dessa tecnologia é tal que, no contexto internacional, foi salientado<sup>1</sup> que ela está em vias de se tornar uma tecnologia de uso geral, assim como foram no passado a máquina a vapor, a eletricidade, a informática e a Internet.

---

<sup>1</sup> Ver, por exemplo, a Recomendação do Conselho da OCDE sobre Inteligência Artificial OECD/LEGAL/0449



O crescimento exponencial da capacidade de computação e a consequente redução dos custos associados, aliados à digitalização das informações e à implantação da Internet, têm sido fatores fundamentais para tornar essa tecnologia disponível a governos e organizações de diversos setores econômicos. Nesse contexto, diversas empresas e entidades dos setores de energia, transporte, água, saneamento e resíduos sólidos vêm adotando recentemente soluções baseadas em IA para fins estratégicos e orientados a missões, incluindo a melhoria do planejamento de sistemas, a otimização das operações e manutenção de ativos, a redução de custos e a prestação de melhores serviços. Essas novas possibilidades de criação de valor possibilitadas pela IA são de grande importância para países, governos e organizações públicas e privadas, visto que os serviços prestados por esses setores são essenciais para o crescimento econômico e o funcionamento normal das sociedades.

Esse documento fornece um conjunto de recomendações e considerações técnicas para o desenvolvimento e a adoção de soluções baseadas em IA nos setores de infraestrutura. Essas recomendações são baseadas em evidências globais, na experiência do BID e nas lições aprendidas com a implantação de ferramentas na América Latina e no Caribe (ALC). Para a preparação dessa publicação, foram realizadas 17 entrevistas

com equipes técnicas do BID, bem como com clientes e atores externos com experiência no desenvolvimento e implementação de tecnologias emergentes e soluções de IA. Além disso, uma análise dos marcos regulatórios aplicáveis à IA na ALC é incluída como anexo.

O objetivo da publicação é fornecer abordagens conceituais e metodológicas a líderes, decisores políticos, equipes de missão, unidades tecnológicas dos setores público e privado, programadores e outros intervenientes no ecossistema empresarial, para ajudar a reforçar a concepção e o desenvolvimento de soluções nos setores da infraestrutura e maximizar as oportunidades que a IA oferece nessa área.

O documento conclui com um conjunto de recomendações para o desenvolvimento e a implementação bem-sucedidos dessas soluções na ALC. Entre as principais recomendações estão: (i) implementar metodologias ágeis de desenvolvimento e inovação em IA e considerar a implementação de provas de conceito, protótipos e produtos mínimos viáveis, que representam espaços de experimentação, aprendizagem e feedback para a melhoria das soluções, (ii) definir esquemas organizacionais que permitam o desenvolvimento e adoção dessas soluções, bem como avaliar e garantir a existência das competências necessárias nas equipes, (iii) compreender

a importância dos dados e da sua governança e, neste sentido, determinar os dados necessários, fontes disponíveis, (iv) identificar e avaliar, desde a fase de concepção, os requisitos das ferramentas tecnológicas e da infraestrutura de dados para o desenvolvimento de soluções, nomeando as capacidades de armazenamento e processamento de dados, (v) definir critérios e objetivos para a seleção de modelos, associados à natureza do problema, ao tipo e qualidade da informação, à capacidade de computação, aos objetivos de desempenho e à explicabilidade, entre outros, e (vi) prestar especial atenção aos aspectos éticos, de privacidade e de segurança desde as fases iniciais da concepção.



# O QUE É A INTELIGÊNCIA ARTIFICIAL?

## 2.1 Definição de Inteligência Artificial

O conceito de IA tem sido comumente utilizado na disciplina de Ciências da Computação desde a década de 1940, a partir do trabalho de professores como Alan Turing<sup>2</sup> e John Von Newman<sup>3</sup>, entre outros. Especificamente, esse conceito nasceu em um workshop realizado no Dartmouth College, em 1956, com a participação de especialistas como John McCarthy, Alan Newell, Arthur Samuel, Herbert Simon e Marvin Minsky, a quem se atribui o termo (OECD, 2019; Wang, 2019).

2 Alan Turing, na sua obra "Computing Machinery and Intelligence" (1950), colocou a questão "can machines think?", para a qual desenvolveu um jogo - "The Imitation Game" -, mais tarde conhecido como "Teste de Turing", no qual, com base em uma série de perguntas, o investigador podia determinar se o seu interlocutor era um humano ou uma máquina.

3 John Von Neumann desenvolveu uma série de princípios matemáticos com o objetivo de construir um computador capaz de efetuar cálculos complexos num curto espaço de tempo e de contribuir para a resolução de problemas mais estruturais.



Diferentes organizações a nível internacional propuseram definições de IA que partilham certos componentes, mas também incluem elementos específicos. O Instituto de Engenheiros Elétricos e Eletrônicos (IEEE) define IA como “a teoria e o desenvolvimento de sistemas de informática capazes de realizar tarefas que normalmente exigem inteligência humana, como a percepção visual, o reconhecimento da fala, a aprendizagem, a tomada de decisões e o processamento de linguagem natural” (IEEE-EUA, 2017).

O BID<sup>4</sup>, em diferentes documentos, referiu-se à IA como um conceito amplo que inclui tecnologias de computação que podem emular competências humanas típicas<sup>5</sup>. Essa definição refere-se a sistemas de informática que podem identificar o ambiente circundante, pensar, aprender e decidir com base nas contribuições e objetivos do modelo<sup>6</sup>. O Banco Mundial define

IA como a capacidade de os sistemas de informática realizarem tarefas associadas à inteligência humana, como visão, fala e linguagem, e conhecimento e pesquisa (Banco Mundial, 2020), enquanto a CAF (Corporação Andina de Fomento) afirma que a IA “é um campo de estudo que se refere à criação, a partir da utilização de tecnologias digitais, de sistemas capazes de desenvolver tarefas para as quais se considera necessária a inteligência humana” (Vélez et al., 2022).

A UE considera que um sistema de IA requer um nível mínimo de autonomia e que, utilizando dados fornecidos por máquinas e/ou seres humanos, infere o processo para cumprir objetivos definidos pelo ser humano. Isso é feito através de aproximações do conhecimento, da aprendizagem automática e/ou de abordagens lógicas. Os resultados gerados incluem conteúdos, recomendações, decisões ou previsões que, por sua vez, modificam o sistema de IA circundante.<sup>7</sup>

Do mesmo modo, a Organização para a Cooperação e Desenvolvimento Econômico (OCDE) define IA como um sistema automatizado que infere, a partir de inputs, como criar

outputs com base em objetivos explícitos ou implícitos. Os resultados gerados incluem conteúdos, decisões, previsões e recomendações. Um sistema de IA é representado pelos seus componentes e pela forma como interage com o ambiente, em termos de inputs e outputs (**Figura 1**).

A definição da OCDE refere-se a objetivos-modelo explícitos quando são diretamente programados por um programador humano, enquanto são implícitos quando são desenvolvidos através de um conjunto de regras definidas por um humano, ou quando o sistema pode aprender novos objetivos.<sup>8</sup>

4 Em outros documentos, como o *Responsible Use of AI for Public Policy: A Data Science Handbook*, a OCDE remete para a definição fornecida pela Organização para a Cooperação e Desenvolvimento Econômico (OCDE), tal como consta do presente documento.

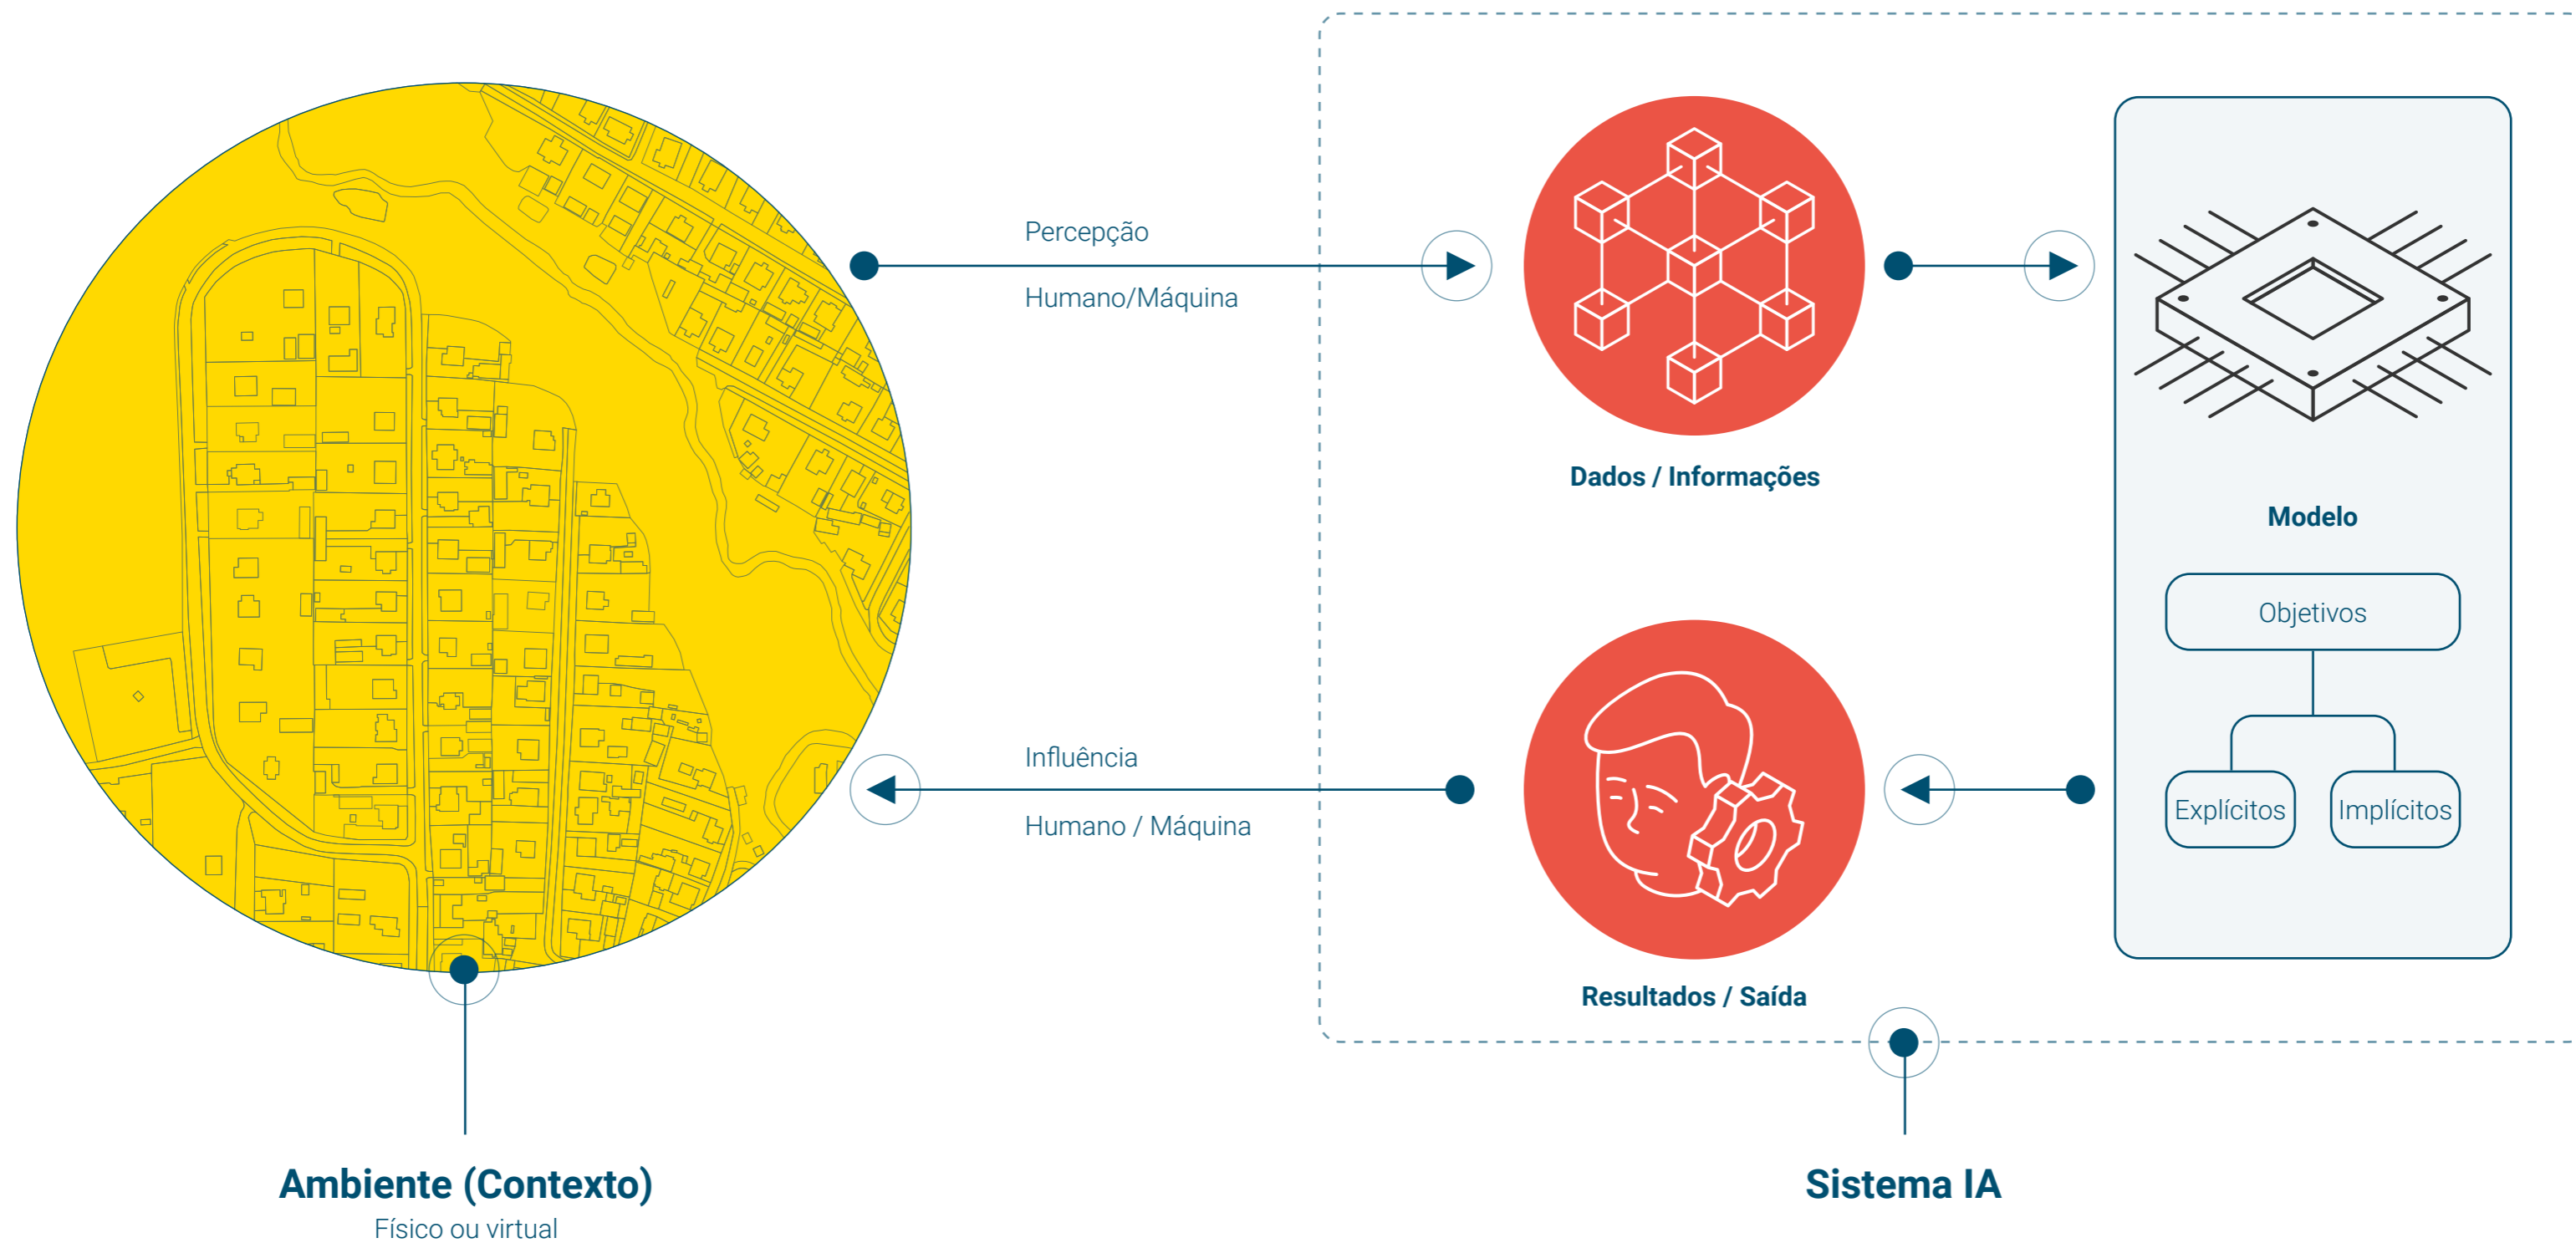
5 Inteligência Artificial: conceitos básicos e aplicações em desenvolvimento (2019, fevereiro). Obtido em <<https://blogs.iadb.org/conocimiento-abierto/es/inteligencia-artificial/>>

6 Inteligência Artificial: o que ela traz e o que ela muda no mundo do trabalho (2022, setembro). Recuperado de <<https://blogs.iadb.org/trabajo/es/inteligencia-artificial-que-aporta-y-que-cambia-en-el-mundo-del-trabajo/>>

7 A Lei da Inteligência Artificial da UE. Obtido em <[https://www.artificial-intelligence-act.com/#:~:text=Artificial%20intelligence%20system%20\(AI,logic%2D%20and%20knowledge%20based%20approaches%2C](https://www.artificial-intelligence-act.com/#:~:text=Artificial%20intelligence%20system%20(AI,logic%2D%20and%20knowledge%20based%20approaches%2C)>

8 Ibidem.

Figura 1. Sistema de Inteligência Artificial



Fonte: Adaptação própria de OCDE (2023) Atualizações na definição de sistema de IA da OCDE explicadas

Por outro lado, os sistemas de IA podem ser genericamente classificados em três tipos, consoante às suas funcionalidades e capacidades:



### Inteligência Artificial Estreita ou Fraca (IA Estreita):

Todos os desenvolvimentos de IA conhecidos até à presente data encontram-se nesta classificação. Os sistemas de IA Estreita têm a capacidade de executar uma tarefa ou função específica (OCDE, 2019; Pombo et al., 2020; Vélez et al., 2022) sem ter consciência, sensibilidade, nem estar influenciado pelas emoções (Vélez et al., 2022). No entanto, no caso da IA Generativa, os modelos fundamentais de ferramentas como o ChatGPT, o Gemini ou o Meta AI podem adaptar as suas respostas para simular empatia com os seus usuários<sup>9</sup>


---

9 Fonte: Conversas com ChatGPT, Gemini e Meta AI sobre sentimentos e emoções



### Inteligência Artificial Geral (IA Geral ou Forte):

Refere-se a sistemas que têm a capacidade de compreender e executar tarefas em diferentes áreas do conhecimento como fazem os seres humanos, mesmo que tenham capacidades cognitivas semelhantes (OCDE, 2019; Pombo et al., 2020; Vélez et al., 2022). Até à presente data, estes sistemas continuam sendo puramente teóricos.



### Inteligência Artificial Superinteligente (IA Superinteligente):

Este é o terceiro tipo de IA que poderá ultrapassar em todas as facetas a capacidade cognitiva dos seres humanos (Pombo et al., 2020). Esse sistema continua sendo especulativo e carece de modelos teóricos sólidos que prevejam desenvolvimentos de curto prazo.

## 2.2

# Tipos de sistemas de IA

Em geral, a literatura refere-se a um conjunto amplo de sistemas de IA que incluem a Aprendizagem Automática (*Machine Learning - ML*) e a Aprendizagem Profunda (*Deep Learning - DL*) como subcomponentes. Há sistemas de IA que não são considerados Aprendizagem Automática, porque não se baseiam em modelos de treinamento a partir de dados. Alguns exemplos de IA que não são considerados ML são os sistemas periciais<sup>10</sup>, os algoritmos genéticos<sup>11</sup> e os algoritmos de pesquisa<sup>12</sup>, entre outros<sup>13</sup>.

10 Estes podem ser definidos como “Sistemas de informação avançados que modelam conhecimentos específicos de um domínio para imitar processos de tomada de decisão de peritos”: ScienceDirect. Disponível em: <<https://www.sciencedirect.com/topics/social-sciences/expert-systems>>

11 Como mencionado na Seção 3.2.2, um algoritmo genético é uma técnica de pesquisa computacional para encontrar soluções aproximadas para modelos de otimização e problemas de pesquisa. Inspira-se no processo de evolução natural, em que as melhores soluções para um problema são selecionadas, combinadas e mutadas para criar novas soluções, tudo em um processo iterativo que para e informa quando é encontrada a melhor solução possível. Fonte: <<https://www.sciencedirect.com/topics/engineering/genetic-algorithm>>

12 Os algoritmos de pesquisa são métodos computacionais utilizados para localizar dados específicos em uma coleção de dados. Definição baseada em: Rouse (2017). *Algoritmo de pesquisa*. Techopedia. Disponível em: <<https://www.techopedia.com/definition/21975/search-algorithm>>

13 William E. (2023). *Exemplos de IA sem aprendizagem automática*. Meio de comunicação. Disponível em <<https://emmawilliam.medium.com/non-machine-learning-ai-examples-3e8c8fd85149>>

Segue uma descrição geral dos conceitos de Aprendizagem Automática (*Machine Learning - ML*), Aprendizagem Profunda (*Deep Learning - DL*) e, em relação a essa última, IA Generativa (*Generative AI*):

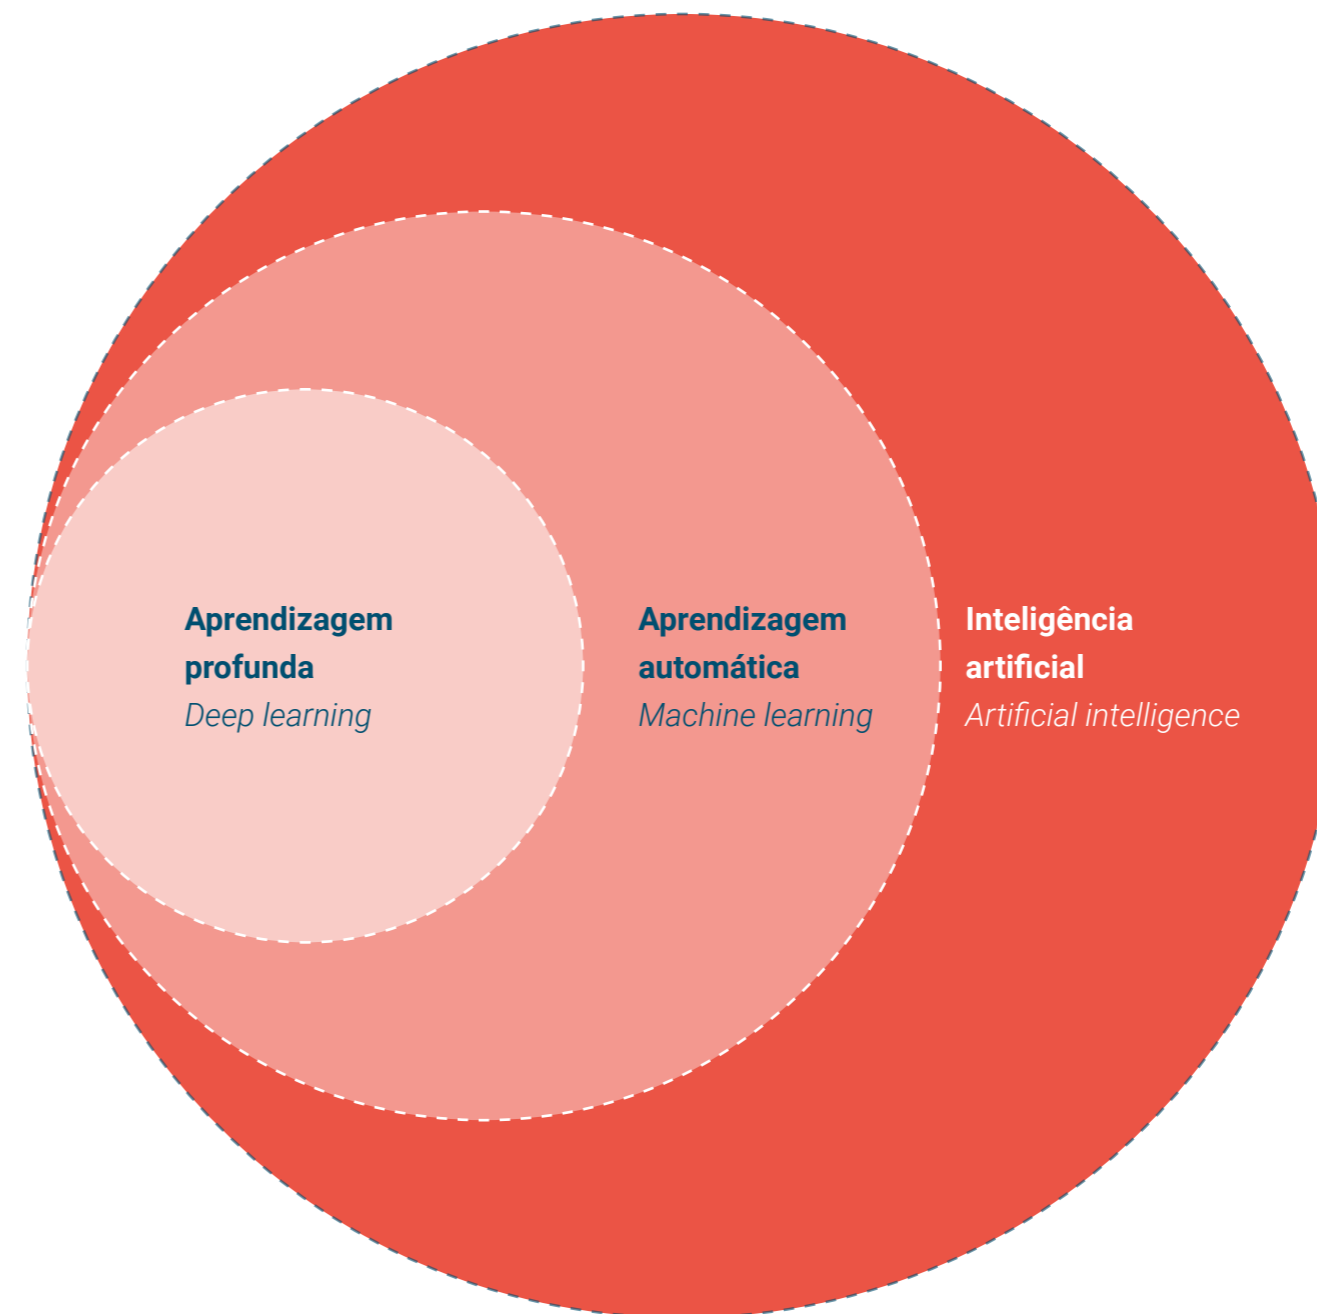
- **Aprendizagem Automática (*Machine Learning - ML*):** Refere-se a métodos de computação que, através da experiência, podem aumentar o seu desempenho ou alcançar maior precisão nas previsões (Mohri et al., 2018). Em particular, a experiência é entendida como a informação que é utilizada para o modelo aprender (Mohri et al., 2018). Assim, os modelos de ML têm a capacidade de resolver problemas descobrindo padrões a partir de exemplos, em vez de serem explicitamente programados para o fazer (Li, 2023).<sup>14</sup>

14 Li, F. (2023) The worlds I see: Curiosity, Explorations, and Discovery at the Dawn of AI. Capítulo 3.

Por exemplo, em uma inspeção de infraestrutura de rede elétrica, uma empresa de transmissão ou distribuição pode treinar um modelo com imagens de elementos de rede com defeito e em perfeito estado, a fim de criar um classificador que detecte com certo nível de precisão a infraestrutura que pode estar desgastada ou com algum componente anômalo, para que a manutenção preventiva e corretiva possa ser realizada em tempo hábil. Como se pode deduzir do exemplo, os modelos de ML baseiam-se nas informações utilizadas para os treinamentos, ou seja, nos dados com os quais o modelo aprende por si próprio.

Tipicamente em infraestruturas, os dados de entrada mais utilizados<sup>15</sup> são normalmente agrupados em séries temporais<sup>16</sup> e catálogos de imagens<sup>17</sup>. Embora exista uma variedade significativa de modelos dentro da família ML, em termos gerais têm a capacidade de se alimentar de dados de entrada relativamente simples, como séries numéricas, e encontrar padrões entre eles para prever um valor que seja facilmente interpretável pelo usuário. A **Figura 2** apresenta, em termos gerais, a cascata de subconjuntos de sistemas que constituem os sistemas de Inteligência Artificial, Aprendizagem Automática e Aprendizagem Profunda.

**Figura 2.** Aprendizagem Automática em Sistemas de IA



Fonte: AWS<sup>18</sup>

15 Exemplos de tipos de dados utilizados em sistemas de infraestruturas incluem: temperatura, pressão, tensão, caudal de água, precipitação, unidades de consumo de água ou energia, humidade, velocidade do vento, radiação solar, tráfego de veículos, frequência de percursos, localização geoespacial, emissões poluentes, tarifas de serviços públicos, entre outros.

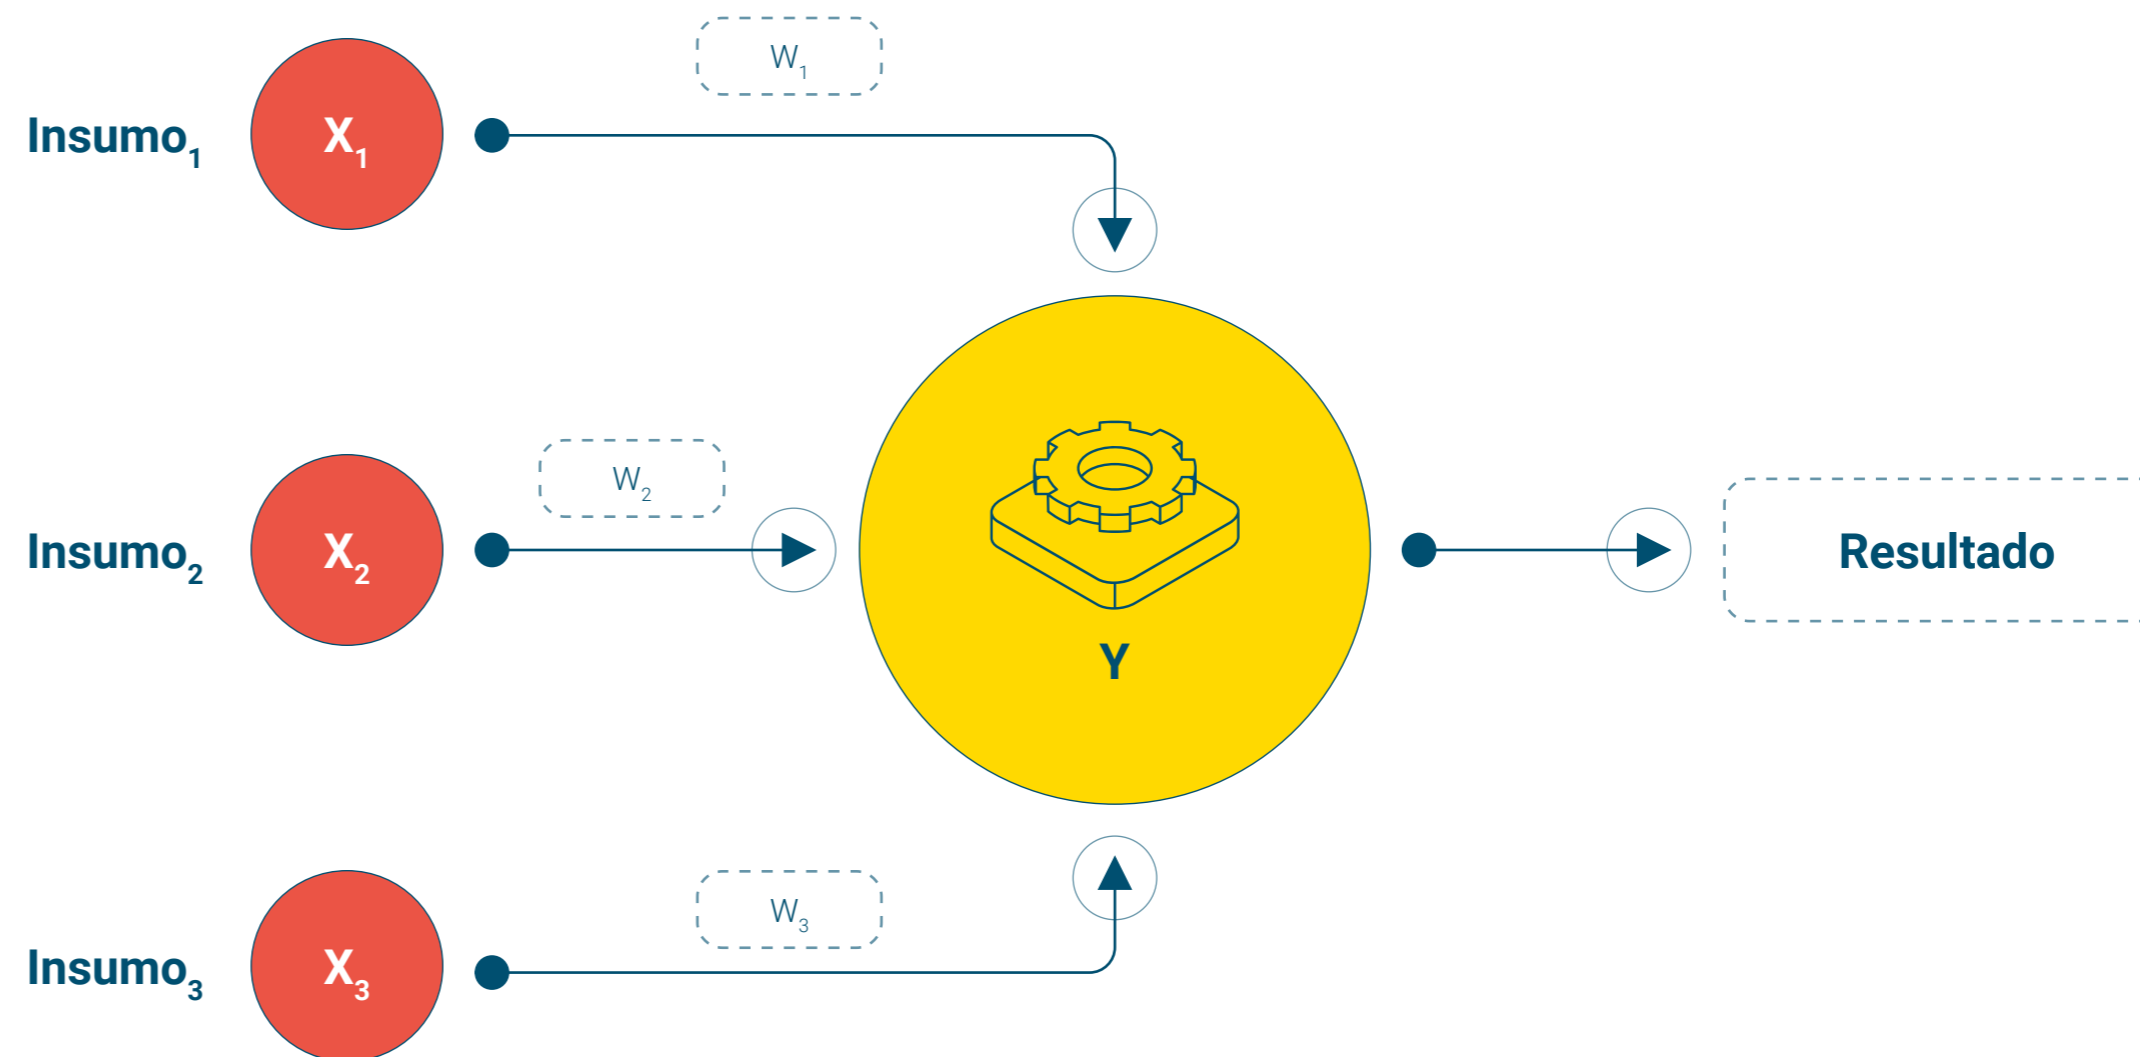
16 As séries cronológicas podem ser definidas como uma sequência ordenada de valores de uma variável distribuída por intervalos de tempo igualmente espaçados. Fonte: Instituto Nacional de Padrões e Tecnologia. Disponível em: <<https://www.itl.nist.gov/div898/handbook/pmc/section4/pmc41.htm>>

17 As imagens podem consistir em material fotográfico, mapas geoespaciais, desenhos técnicos, diagramas de rede, termografias, radiografias, modelos 3D de infraestruturas ou representações arquitetônicas, entre outros.

18 AWS. O que é a Inteligência Artificial (IA)? Recuperado de: <<https://aws.amazon.com/what-is/artificial-intelligence/>>

- **Aprendizagem Profunda (Deep Learning - DL):** O conceito de *Aprendizagem Profunda* está diretamente relacionado ao de redes neurais. A investigação sobre Redes Neurais Artificiais (RNA) foi motivada pela observação de que a inteligência humana surge de redes relativamente simples e não lineares de neurônios que aprendem ajustando a força das suas ligações (Bengio et al., 2021).<sup>19</sup> Uma rede neuronal de camada única (a abstração mais simples possível) está representada na **Figura 3** onde cada esfera representa um neurônio ou nó. As entradas são características ou atributos da informação que está sendo analisada. Os pesos, que são identificados com um  $W_n$ , representam a importância que o modelo está dando a cada entrada para produzir o resultado. Tal como acontece com os neurônios, o sinal elétrico deve ser suficientemente forte para transmitir a informação ao outro neurônio. No caso do modelo, o cálculo entre as entradas e os pesos deve ultrapassar um determinado

**Figura 3.** Representação de uma rede neuronal de camada única (Perceptron).



19 Bengio, Y., LeCun, Y., & Hinton G. (2021). Aprendizagem profunda para IA. Communications of the ACM, 64(7), 58-65. <http://dx>.


limite<sup>20</sup> para que o objetivo seja atingido. O modelo aprende, reorganizando os pesos até obter o melhor resultado possível.

Dessa forma, os modelos DL funcionam com várias camadas (ver **Figura 4**), sendo cada camada uma forma diferente de extrair e transformar a informação utilizada como entrada (Patterson & Gibson, 2017). As camadas (conjunto de neurônios ou nós) permitem otimizar e aperfeiçoar a precisão do resultado do modelo<sup>21</sup>.

Esses tipos de modelos recebem frequentemente entradas relativamente complexas, como imagens ou texto e, através do processamento complexo de cada parte da entrada, produzem resultados simples, como a classificação de um objeto ou o resumo de um

documento. Por exemplo, na inspeção da segurança rodoviária de uma estrada, é possível treinar um modelo de *Aprendizagem Profunda* utilizando imagens que representam as principais características que determinam o nível de segurança da estrada. Esse modelo pode funcionar como um classificador capaz de identificar com um elevado grau de precisão os segmentos da estrada que necessitam de intervenções para reduzir os riscos para pedestres, ciclistas e motoristas.

**Figura 4.** Modelo de redes neurais multicamadas



**Fonte:** Thajeb, S. Introdução ao aprendizado profundo (2020, julho). Recuperado de: <<https://medium.com/swlh/introduction-to-deep-learning-50d971374dd2>>

### ● **Inteligência Artificial Generativa (IA Generativa):**

Um tipo de IA que utiliza a Aprendizagem Automática, não para prever ou classificar com base em informações existentes, mas para produzir “novos” conteúdos, sejam eles dados numéricos, texto, vídeo, áudio ou imagens, entre outros, a partir da análise de padrões nos dados (Brynjolfsson et al., 2023; Cevallos et al., 2023). Os recentes avanços na IA Generativa devem-se, em parte, a progressos em áreas como a escala de computação, melhorias na arquitetura dos modelos e a possibilidade de treinar modelos utilizando grandes volumes de dados não rotulados<sup>22</sup> (Brynjolfsson et al., 2023).

O exemplo mais comum de IA Generativa, após o aparecimento do ChatGPT, são os modelos de Linguagem de Grande Dimensão (LLM). Estes modelos fazem parte da família do Processamento de Linguagem Natural (PLN), que automatiza as funções linguísticas através da análise, produção, modificação e resposta à fala e escrita humanas (OCDE, 2023). Os LLMs são treinados com grandes quantidades de dados

20 Para mais informações sobre funções de ativação, ver: Sharma et al., 2020 <<https://www.ijeast.com/papers/310-316,Tesma412,IJEAST.pdf>> & Manoharan, I 190. Demystifying the Gears: Activation Functions & Loss Functions for Neural Networks (2024, março). Recuperado de: <<https://medium.com/@ilakk2023/190-demystifying-the-gears-activation-functions-loss-functions-for-neural-networks-778f29d7780f>>.

21 Ibidem.

22 Um exemplo de dados não rotulados pode ser uma série de imagens de animais sem informação relacionada com o seu tipo, ou seja, se é um leão, um coelho, um cão ou um gato.

(estima-se que o GPT-4 inclui 1,8 bilhões de parâmetros e é treinado com cerca de 13 bilhões de tokens<sup>23</sup>), o que lhes permite classificar e simular a compreensão da estrutura do texto, as complexidades gramaticais e os diferentes contextos das frases, pelo que são capazes de estabelecer conversas, dar respostas precisas e criar “novos” textos<sup>24</sup> (Brynjolfsson et al, 2023; Cevallos et al., 2023). Embora o ChatGPT<sup>25</sup> seja o gerador de texto mais conhecido, existem outras plataformas como o LLaMA<sup>26</sup> da Meta AI, o Gemini<sup>27</sup> da Google e o Claude IA<sup>28</sup> desenvolvido pela Anthropic, entre outros.

Os Foundation Models (FMs),<sup>29</sup> incluindo os LLMs, têm a capacidade de se adaptarem a qualquer assunto, desde que sejam treinados com milhões de dados e, ao contrário dos modelos deep ou machine learning que são projetados para executar uma tarefa específica, esses modelos têm a capacidade de analisar inputs complexos para produzir formas mais avançadas de conhecimento como, por exemplo, completar códigos de programação ou analisar textos, entre outros<sup>30</sup>, embora também possam gerar resultados incorretos em termos de vieses ou alertas, quando há problemas com a qualidade e integridade dos dados com os quais são alimentados<sup>31</sup>. Esses tipos de modelos podem contribuir para melhorar a eficiência dos processos administrativos das entidades do setor de

infraestruturas como, por exemplo, na melhoria dos sistemas de gerenciamento de documentos ou os sistemas de respostas aos cidadãos.

## Tipos de aprendizagem em modelos de Machine Learning

Essa subseção apresenta uma análise dos principais tipos de aprendizado utilizados nos sistemas de Aprendizagem Automática. Como já foi referido, o ML tem a capacidade de descobrir padrões e relações em grandes quantidades de dados, ajudando a criar ferramentas de previsão ou classificação com um bom nível de precisão. Em geral, os problemas para os quais os modelos de aprendizagem automática são utilizados podem ser resumidos em três vertentes:

23 Nos modelos de PLN, um token refere-se a uma unidade básica de texto, que pode ser uma palavra, um número, um símbolo de pontuação ou qualquer outra entidade linguística com significado.

24 O que são Modelos de Linguagem de Grande Porte (LLM)? Recuperado de: <<https://aws.amazon.com/what-is/large-language-model/>>

25 Para mais informações: <<https://chat.openai.com/>>

26 Para mais informações: <<https://llama.meta.com/>>


27 Para mais informações: <<https://gemini.google.com/>>

28 Para mais informações: <<https://claude.ai/chats>>

29 Para mais informações: <<https://claude.ai/chats>>  
Os Modelos Fundacionais (FM) são redes neurais de aprendizagem profunda, treinadas em grandes quantidades de dados e compostas por um número significativo de parâmetros, que podem realizar diferentes tarefas gerais, como gerar texto e imagens, compreender línguas humanas e manter conversas, entre outras (Fonte: What are foundational models? Obtido em <https://aws.amazon.com/es/what-is/foundation-models/>).

30 AWS. O que são Foundation Models? Recuperado de: <<https://aws.amazon.com/what-is/foundation-models/#:~:text=Foundation%20models%20are%20a%20form,form%20of%20human%20language%20instructions.>>

31 Google Cloud: O que são alucinações de IA? Recuperado de: <<https://cloud.google.com/discover/what-are-ai-hallucinations?hl=es-419>>




## Classificação:

Neste caso, o problema a resolver é a identificação da categoria ou categorias a que pertence cada elemento em análise. O exemplo mais comum é a classificação de imagens. Normalmente, esses tipos de modelos aprendem com dados de treinamento rotulados. As técnicas que podem ser utilizadas incluem limiarização simples, regressões, modelos de Markov, florestas aleatórias ou redes neuronais, entre outras. Por exemplo, em uma rede elétrica, é essencial identificar rapidamente falhas ou anomalias que possam causar interrupções no fornecimento de energia. Para o efeito, é utilizado um modelo de aprendizagem automática para classificar os eventos da rede em diferentes categorias, como “funcionamento normal”, “sobrecarga”, “falha de energia” ou “falha de equipamento”.



## Clustering:

Esses modelos permitem encontrar relações entre conjuntos de dados, de modo com que aqueles que têm características comuns façam parte do mesmo grupo ou cluster. Um exemplo no setor de transportes é o agrupamento das linhas de veículos para otimizar as rotas do transporte público. Neste caso, em uma cidade, o objetivo é otimizar as rotas dos ônibus ou do transporte público com base nas trajetórias reais dos veículos e nos padrões de demanda dos passageiros. Isso identifica as rotas com maior demanda e aquelas que podem ser otimizadas adicionando ou removendo paradas, ou ajustando as frequências de serviço nas principais rotas com base nos padrões de demanda.



## Previsão:

Com base em informações históricas, os modelos de previsão preveem valores atuais ou futuros, por exemplo, a demanda por eletricidade, a demanda por serviços de transporte, os níveis de congestionamento ou de acidentes e os fluxos de água nos sistemas de água e de esgoto.

Nesse caso, esse modelo pode ser utilizado em empresas de abastecimento de água, que precisam se antecipar à demanda futura para evitar sobrecargas no sistema de abastecimento ou falta de fornecimento de água. A utilização de modelos preditivos permite-lhes ajustar eficientemente o abastecimento de água de acordo com as necessidades futuras, o que é crucial para uma gestão sustentável.

Uma das características indispensáveis dos modelos de ML é que eles têm a capacidade de aprender com as informações disponíveis, portanto, sua estrutura difere principalmente nos algoritmos que usam para aprender (Rebala et al., 2019). Então, geralmente falamos sobre três tipos principais de modelos de aprendizagem dentro do ML: i) aprendizagem supervisionada, ii) aprendizagem não supervisionada e iii) aprendizagem por reforço.

Quanto à **aprendizagem supervisionada**, a sua principal característica é que o treinamento dos modelos é realizado com base em informações rotuladas, ou seja, o modelo é treinado com base no conhecimento das respostas corretas. Esse tipo de aprendizagem lida com dois problemas principais: a classificação e a regressão. Como já foi mencionado, a classificação refere-se à identificação da categoria a que pertence cada um dos itens que estão sendo analisados. Por outro lado, a técnica de regressão descobre a relação em diferentes dimensões de distintas variáveis, a fim de prever o comportamento de uma variável de interesse (Rebala et al., 2019). Algumas aplicações desse tipo de aprendizagem são o diagnóstico do estado das infraestruturas para fins de manutenção ou identificação de falhas, a detecção de fraudes no consumo de água e energia, a classificação de imagens para a detecção de vazamentos ou congestionamento de veículos,

a previsão de valores ou procura de serviços de energia, água ou transporte público, entre outros. Para o problema da classificação, os algoritmos mais utilizados são as máquinas de vetores de suporte (SVM), K-nearest neighbours (KNN), Naive Bayesian (Naive Bayes), árvores de decisão, florestas aleatórias e Redes Neurais Convolucionais (CNN), entre outros. No caso das regressões, são geralmente utilizadas a regressão linear, a regressão logística, a regressão polinomial, a regressão por máquina de vetores de suporte (SVM) e o Gradient Boosting (GBM), entre outras.

**A aprendizagem não supervisionada** é aquela em que os algoritmos não se concentram na previsão ou explicação de uma variável-alvo, mas sim na identificação de padrões ou relações entre os dados. Modelos desse tipo aprendem a identificar características semelhantes entre variáveis que as fazem pertencer ao mesmo grupo (Rebala et al., 2019). Em geral, esse tipo de aprendizagem utiliza algoritmos de clusterização, permitindo obter as principais particularidades dos dados, utilizando como entrada um conjunto de dados não rotulados. Nessa ordem de ideias, tendo em vista que esse tipo de aprendizagem se depara frequentemente com bases de dados com elevada dimensionalidade (grande número de variáveis), são utilizados algoritmos de redução da dimensionalidade, como a Análise Discriminante Linear (LDA)

ou a Análise de Componentes Principais (CPA), para que, ao reduzir o número de variáveis, se capte a informação mais importante da base de dados com que se está trabalhando<sup>32</sup>. Isso, entre outras coisas, melhora a interpretabilidade do modelo, o desempenho e a eficiência de computação<sup>33</sup>. A aprendizagem não supervisionada pode ser utilizada para a segmentação de clientes, classificação da condição de ativos de infraestrutura, detecção de padrões incomuns no desempenho de motores ou máquinas e criação de programas de políticas públicas. Os algoritmos de agrupamento mais comumente utilizados são o K-Means, o K-medoids, o DBSCAN e o Gaussian Mixtures (GMM), entre outros.

Além disso, os modelos **de aprendizagem por reforço** procuram tomar as melhores decisões com base na experiência adquirida por tentativa e erro<sup>34</sup>. Para isso, a aprendizagem ocorre por meio de “recompensas e punições”, onde não se

32 Brown, I. Seleção de recursos vs extração de recursos: Navegando na redução de dimensionalidade no aprendizado de máquina (2024, março). Recuperado de: <<https://medium.com/ai-in-plain-english/feature-selection-vs-feature-extraction-navigating-dimensionality-reduction-in-machine-learning-7c60e6742710>>

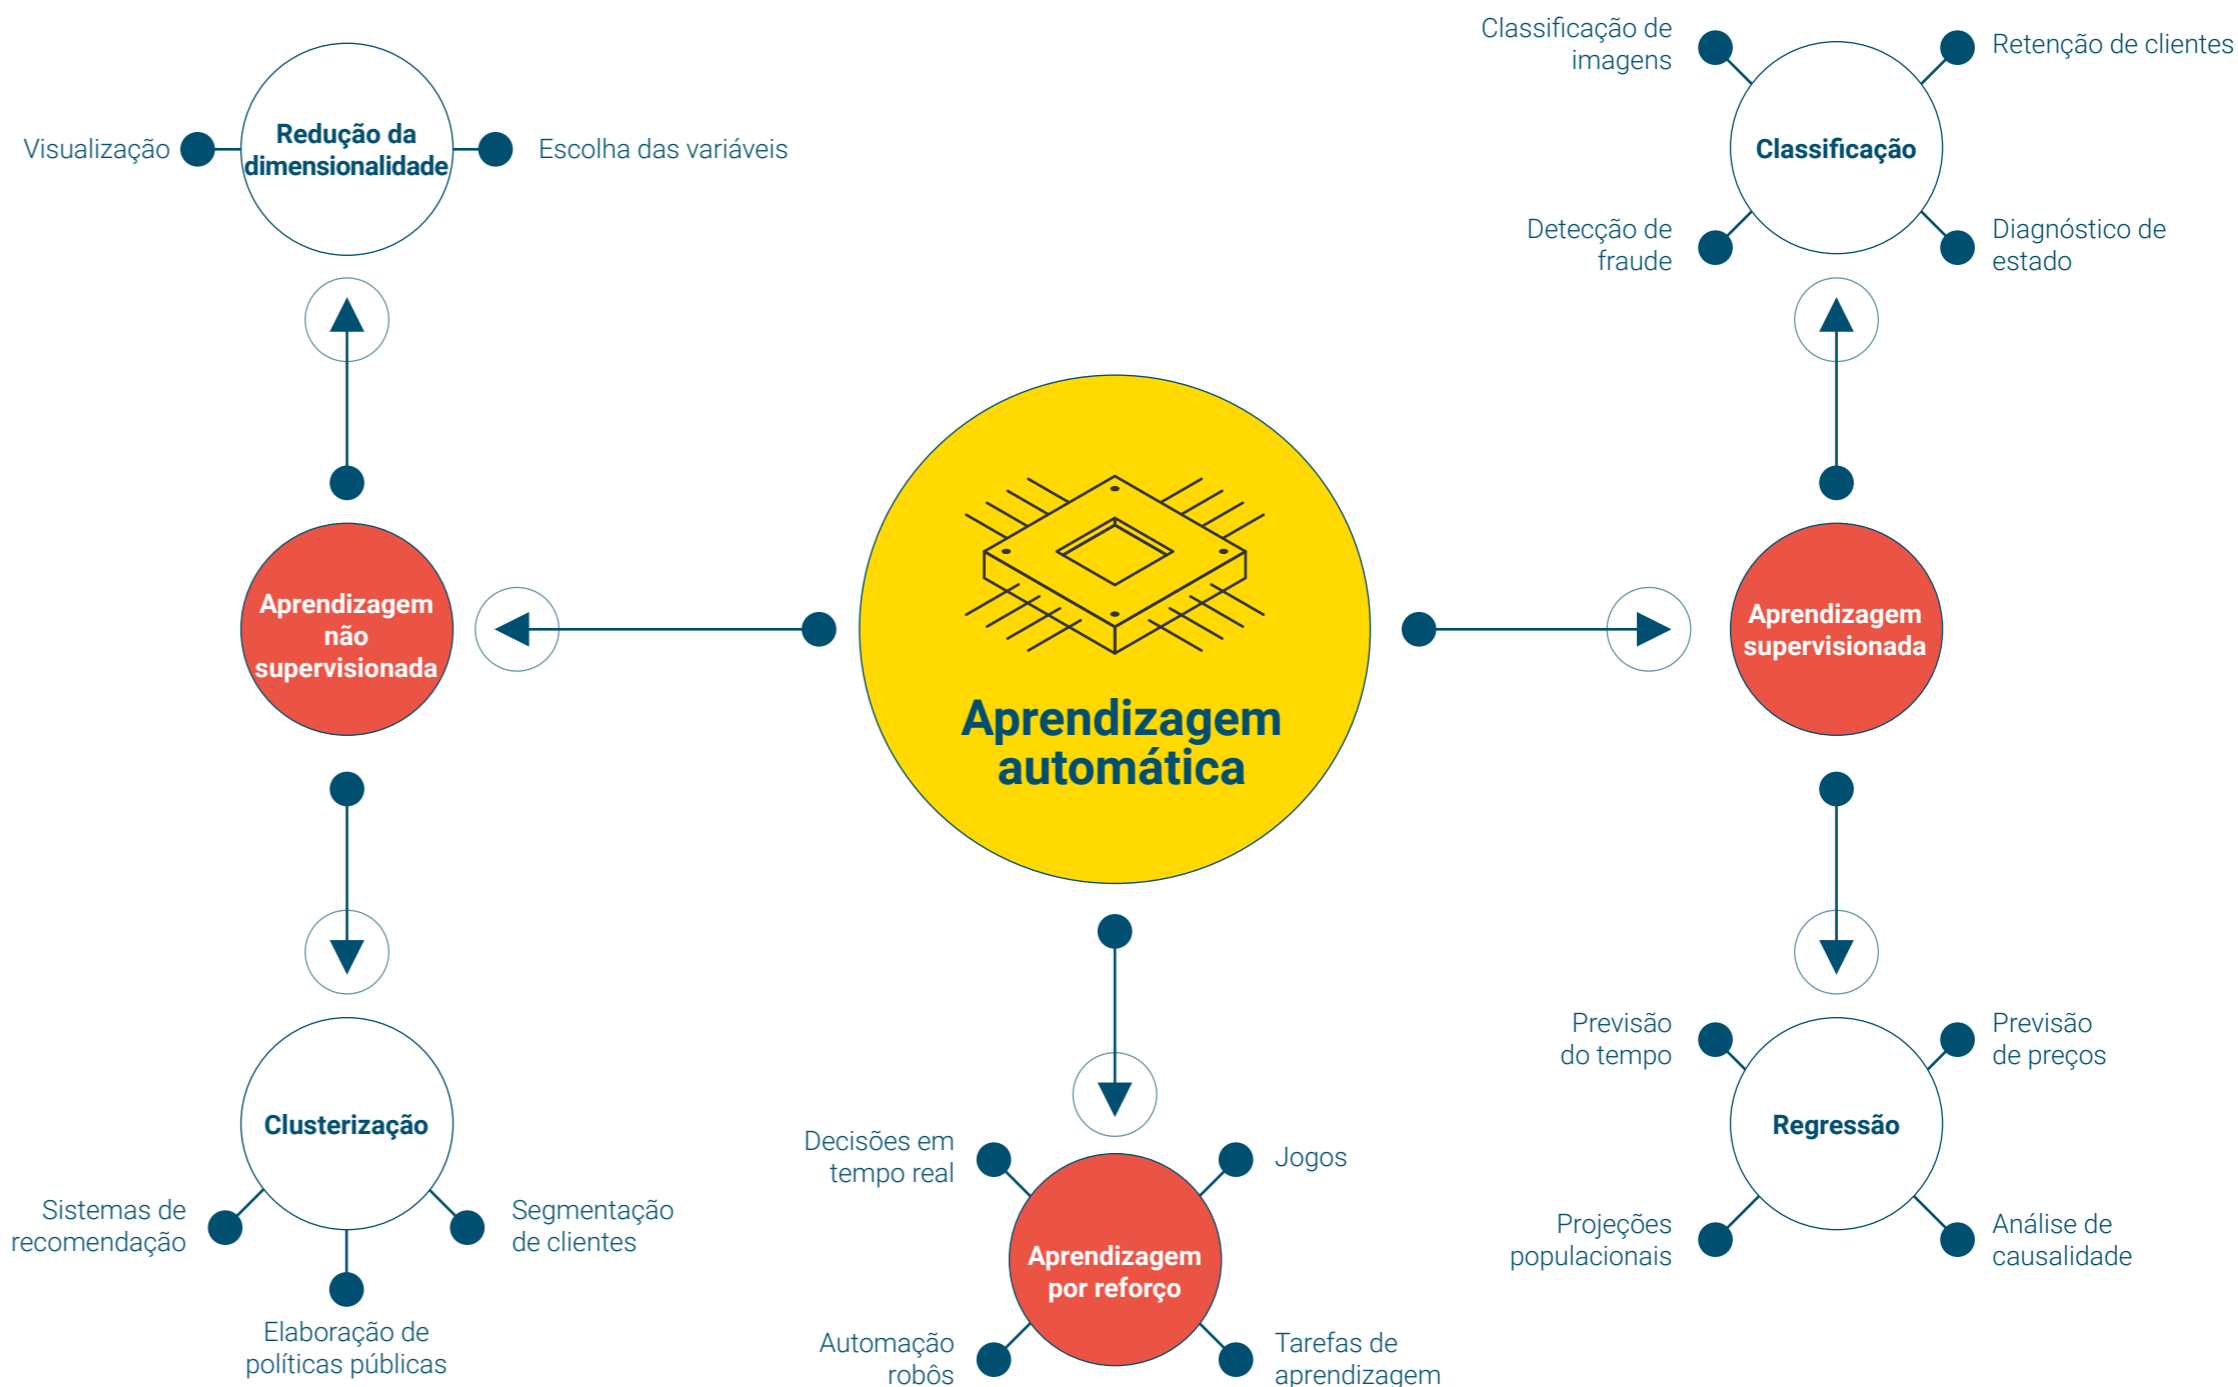
33 Ibidem.

34 AWS: O que é a Aprendizagem por Reforço? Obtido em: <

diz ao modelo quais decisões tomar, mas sim o objetivo a ser alcançado, bem como o tipo de “recompensa” e “punição” para cada ação realizada (Sutton & Barto, 2018). Uma das características fundamentais desse tipo de aprendizagem é que tem a capacidade de, à medida que progride no seu treinamento, encontra o melhor caminho para atingir o seu objetivo tendo em vista o impacto a longo prazo das suas decisões, ou seja, ao longo do caminho pode receber intencionalmente “castigos” para atingir o objetivo (Rebala et al., 2019). As aplicações que mais se destacam nesse tipo de aprendizagem estão relacionadas com a autonomia dos robôs, a gestão do tráfego automotivo baseada na administração dos semáforos, os veículos autônomos e treinamento de jogos, por exemplo, o AlphaGo<sup>35</sup>. Os algoritmos mais utilizados neste tipo de aprendizagem são: Q-Learning, Deep Q-Network (DQN), Proximal Policy Optimization (PPO) e Monte Carlo Tree Search (MCTS), entre outros.

A **Figura 5** resume os principais tipos de aprendizagem em sistemas de ML, assim como os problemas que eles abordam e algumas das aplicações em que são utilizadas.

**Figura 5.** Diagrama dos três principais tipos de aprendizagem em ML.



35 Para mais informações, consultar: <<https://deepmind.google/technologies/alphago/>>; e AlphaGo <<https://www.youtube.com/watch?v=WXuK6gekU1Y&t=1028s>>.

Fonte: Adaptado de Inteligência Artificial. Definição de aprendizagem automática (guia completo). Obtido em: <<https://medium.com/@artificialintelligenceai/machine-learning-definition-complete-guide-4cd615dd424d>>

Vale ressaltar que os modelos de IA dependem significativamente dos dados de entrada. Nesse sentido, quem desenvolve esses modelos pode enfrentar problemas relacionados à escassez ou baixa qualidade das informações, vieses nos dados disponíveis e limitações legais e éticas relacionadas ao tratamento de dados pessoais. Uma ferramenta que responde a estes desafios é a utilização de dados sintéticos. Os dados sintéticos são geralmente definidos como informação gerada artificialmente através de algoritmos ou simulações que recriam o comportamento de dados “reais” (Lu et al., 2024). Embora a utilização deste tipo de dados gere artificialmente grandes quantidades de dados de treinamento quando os dados são esparsos, de baixa qualidade ou tendenciosos, os dados sintéticos nem sempre capturam a complexidade e as interações presentes nos dados reais. Neste sentido, as conclusões da análise de dados e dos testes de hipóteses são, geralmente, mais fracas quando se utilizam dados sintéticos do que quando se utilizam dados reais, portanto, a significância estatística dessas análises deve ser devidamente ajustada. Além disso, a utilização de dados sintéticos dificulta o estabelecimento de vínculos entre diferentes conjuntos de dados reais e, por conseguinte, a criação de bases de dados maiores que contenham novas informações sobre as correlações entre os conjuntos de dados vinculados (Jordon et al., 2022).

Para a criação de dados sintéticos de imagem e vídeo, frequentemente são utilizados modelos generativos que são treinados para recriar as características e propriedades dos dados do mundo real<sup>36</sup>. Para isso, normalmente são utilizadas redes Redes Neurais Generativas Adversariais (GAN), Autocodificadores Variacionais (VAEs) e modelos autorregressivos, entre outros. Por exemplo, na detecção de fraudes no consumo de água ou energia, é comum gerar variáveis sintéticas para complementar a disponibilidade limitada de dados reais.

Outra técnica relevante que resolve o problema da informação insuficiente é o aumento dos dados. Essa técnica aumenta artificialmente o conjunto de dados, modificando os dados originais em uma pequena quantidade, o que permite não apenas aumentar a amostragem, mas também incluir diversidade nos dados de treinamento para melhorar a generalização do modelo.<sup>37</sup>

Finalmente, um problema constante nos modelos de classificação é o desequilíbrio de categorias. Isso pode levar a um fraco desempenho dos preditores de classes, na medida em que raramente preveem a classe minoritária (aquela com menos dados) e, por tanto, a avaliação do modelo leva em consideração apenas o desempenho da classe majoritária. Algumas soluções para este problema estão relacionadas com a sub amostragem da classe dominante, com réplicas à classe minoritária ou a ponderação de cada classe de tal forma que o peso total de cada uma das classes seja equilibrado por pesos diferentes, entre outras soluções (Ávalos et al., 2021).

---

36 Shah, D. O que são dados sintéticos no aprendizado de máquina e como gerá-los (2022, junho). Recuperado de: <<https://www.v7labs.com/blog/synthetic-data-guide#h1>>

37 AWS. O que é Data Augmentation. Obtido em: <[https://aws.amazon.com/what-is/data-augmentation/#:~:text=Data%20augmentation%20is%20the%20process,machine%20learning%20\(ML\)%20models.](https://aws.amazon.com/what-is/data-augmentation/#:~:text=Data%20augmentation%20is%20the%20process,machine%20learning%20(ML)%20models.)>



# IA NOS SETORES DE INFRAESTRUTURA: OPORTUNIDADES E APLICAÇÕES

## 3.1 A importância das infraestruturas críticas

A infraestrutura econômica é uma componente central da base de capital de um país que permite a atividade econômica e o funcionamento da sociedade, e tem efeitos positivos no bem-estar e na qualidade de vida das pessoas. O Fórum Econômico Mundial - FEM (2012) definiu as infraestruturas econômicas como o conjunto de projetos que geram crescimento econômico e permitem o funcionamento da sociedade em setores como os transportes - terrestres, aéreos, fluviais, marítimos -, os serviços públicos - água, gás e eletricidade -, a defesa contra inundações e a gestão de resíduos, entre outros.



Dada a importância da infraestrutura econômica, os diferentes sistemas e elementos deste tipo têm sido denominados infraestrutura crítica, pois, além do impacto econômico e social que geram, seu impacto representa um risco considerável para os países. Nesse sentido, uma infraestrutura é definida como crítica quando se considera que uma eventual interrupção pode gerar uma crise socioeconômica significativa. Isso, por sua vez, poderia ter repercussões estratégicas, políticas e de segurança para a sociedade (Laubshtein, 2023).

A literatura econômica analisou a contribuição econômica dos setores de infraestrutura e concluiu que estes setores têm efeitos significativos e positivos no desenvolvimento econômico dos países<sup>38</sup>. Por exemplo, o Fundo Monetário Internacional - FMI (2016) faz referência da existência de uma relação positiva entre a qualidade da infraestrutura e o nível de desenvolvimento dos países, medido, por exemplo, pela renda per capita. De acordo com essa organização, o investimento em infraestrutura contribui para o crescimento econômico futuro, sendo o estado da infraestrutura um importante e determinante

fator da competitividade e dos fluxos de investimentos nos países. Na mesma linha, segundo a OCDE (2023), os setores dos transportes e das telecomunicações podem funcionar como catalisadores do crescimento econômico, permitindo que as empresas criem ligações aos mercados a nível nacional, regional e mundial, enquanto as infraestruturas de qualidade nos setores de energia e de água contribuem para a sustentabilidade e a transição ecológica dos países, bem como para os benefícios decorrentes dessa transição para os cidadãos.

Além disso, vários autores concluíram que existe uma relação positiva entre o investimento em infraestrutura e a criação de emprego. Moszoro (2021), por exemplo, avaliou o impacto na criação de empregos do investimento público em infraestrutura crítica em 41 países ao longo de um período de 19 anos. Constatou que, a cada US\$ 1 milhão de investimento público em infraestrutura leva à criação de 3 a 6 postos de trabalho nas economias avançadas, de 10 a 17 postos de trabalho nas economias emergentes e de 16 a 30 postos de trabalho nas economias de baixa renda. Assim, a nível mundial, um aumento de 1% do PIB global no investimento público nestes setores poderia criar mais de 7 milhões de empregos.

## 3.2

### Oportunidades e aplicações da IA nos setores de infraestrutura

A IA e a transformação digital dos setores de infraestrutura

A IA surgiu como uma das tecnologias com maior potencial para permitir transformações econômicas nos mercados nos próximos anos, uma vez que a sua implementação pode abrir portas para múltiplas oportunidades de criação de valor, tanto para as organizações como para os consumidores. A Deloitte (2021) aponta seis maneiras pelas quais a IA cria valor para as organizações:

- **Redução de custos:** A IA é utilizada para reduzir os custos através da automatização de tarefas repetitivas e de baixo valor, aumentando assim a eficiência e a qualidade.
- **Velocidade na execução:** A IA otimiza o tempo necessário para obter resultados operacionais e comerciais.

38 Ver, por exemplo: Zhang Y. & Cheng L. (2023), Hong J., Chu Z., & Wang Q. (2011), Jiwattanakupaisarn P., Noland R., & Graham D. (2012).

- **Redução da complexidade:** Essa tecnologia ajuda a melhorar a compreensão das empresas e a tomada de decisões através de análises de dados que são “mais proativas, preditivas e capazes de detectar padrões em fontes cada vez mais complexas”.
- **Transformação do engajamento:** A IA torna possível mudar a forma como as pessoas interagem com a tecnologia, permitindo que as empresas se conectem com os clientes em termos humanos.
- **Impulsionar a inovação:** A IA permite a inovação em novos produtos, mercados e modelos empresariais, induzindo a uma redefinição da estratégia empresarial e de negócios.
- **Fortalecimento da confiança:** Essa tecnologia ajuda a proteger as empresas dos riscos associados, como a fraude e a cibercriminalidade, bem como a melhorar a qualidade, a coerência, a transparência e a confiança dos usuários.

A IA também oferece um enorme potencial de criação de valor para o desempenho dos governos e para a realização das suas funções e objetivos. Os organismos públicos se beneficiam da IA para se transformarem em organizações mais inteligentes,

mais eficientes e mais reativas, que desenvolvem melhores processos de tomada de decisão (Pombo et.al, 2018).

Neste contexto, o desenvolvimento e a adoção da IA oferecem oportunidades significativas para impulsionar a transformação digital nos setores de infraestrutura econômica dos dois países, entendida como o uso de dados e a adoção de tecnologias digitais, como a IA, para reestruturar processos, organizações ou sistemas, com o objetivo de criar valor<sup>39</sup>.

Os setores da infraestrutura econômica têm características comuns que permitem a sua transformação digital baseada na IA, tais como serem compostos por sistemas complexos, organizados através de arquiteturas de rede,

---

<sup>39</sup> Existem diferentes definições de transformação digital. Por exemplo, a OCDE define-a como o impacto das tecnologias e dados digitais e a sua utilização em atividades existentes e novas. A AWS define a transformação digital como o processo através do qual uma organização integra a tecnologia digital em todas as áreas da empresa. A McKinsey define-a como a reconfiguração de uma organização, com o objetivo de criar valor através da implantação contínua de tecnologia em escala. Fontes: OCDE. Transformação digital. Obtido em: <<https://www.oecd.org/en/topics/digital-transformation.html>>. AWS. O que é a transformação digital? Obtido em: <https://aws.amazon.com/es/what-is/digital-transformation/>. McKinsey & Company. O que é a transformação digital? Obtido em: <<https://www.mckinsey.com/featured-insights/mckinsey-explainers/what-is-digital-transformation>>

envolvendo múltiplos intervenientes, e serem intensivos em capital físico, bem como na geração e consumo de dados. As organizações nestas áreas econômicas enfrentam, assim, desafios comuns em que a IA se tornará uma ferramenta crítica, como o desenvolvimento de previsões de oferta e procura, o monitoramento da construção de projetos, a inspeção e manutenção de ativos, a detecção de perdas na rede, a sustentabilidade do sistema e a resiliência das infraestruturas face às alterações climáticas e às catástrofes naturais.

Da mesma forma, nos setores de infraestrutura, a transformação digital tem desempenhado um papel disruptivo a três níveis (Calatayud et al. 2022): (i) melhorando a eficiência das unidades de produção, (ii) reconfigurando as cadeias de produção, e (iii) formando novos mercados através da emergência de plataformas bilaterais conhecidas como marketplaces. Embora a velocidade de adoção tecnológica e de transformação digital nestes setores tenha

sido heterogênea<sup>40</sup>, na maioria dos setores as tecnologias digitais tornaram-se um fator de mudança.

Em um questionário realizado em 275 representantes do setor dos transportes e de energia na ALC, o BID constatou que 71% das empresas do setor de energia utilizam a computação em nuvem e que mais de 50% das empresas, tanto deste setor como do setor de transportes, adotaram ferramentas de análise de dados e soluções de big data. As organizações destes setores estão empregando elementos de captura, processamento e análise de dados, incluindo sensores, drones, redes elétricas, a partir dos quais estão implementando sistemas que lhes permitem melhorar os processos de interação com os clientes, realizar monitoramento em tempo real e gerir a oferta e a procura, entre outras aplicações (Irigoyen e Mayorga, 2024).

As tecnologias emergentes, associadas a fases mais avançadas da digitalização, como a IA, estão apenas começando a captar a atenção dos setores econômicos na ALC. Nos setores das infraestruturas, o questionário

evidenciou um interesse crescente no avanço da implantação da IA nos próximos anos, para além do desenvolvimento e da adoção de tecnologias para reduzir o impacto ambiental.

Assim, as oportunidades de criação de valor que a IA oferece às organizações dos setores das infraestruturas, e que geram impactos positivos em várias fases do ciclo de vida dos projetos, são apresentadas nas fases de: (i) **Planejamento e concepção**, que engloba a identificação de necessidades, a formulação, a estruturação e a concepção; (ii) **Construção e gestão de ativos**, que inclui a implantação de infraestruturas e a respetiva gestão patrimonial; e (iii) **Operação e manutenção**, que se refere à operação de infraestrutura, à manutenção de ativos, à prestação de serviços e à consolidação do sistema em termos de sustentabilidade e resiliência climática.

Em cada uma destas fases, a IA oferece oportunidades significativas. Na fase de planejamento e concepção, facilita a modelação avançada do sistema e melhora a análise de riscos e a tomada de decisões com base em dados e previsões avançadas. Durante a construção e a gestão de ativos, ajuda a aumentar a eficiência na execução e supervisão dos trabalhos, o que otimiza a

identificação, o monitoramento e manutenção dos ativos. Além disso, na fase de operação e manutenção, a IA impulsiona a incorporação de melhorias na eficiência e sustentabilidade dos sistemas, permite a otimização dos tempos de manutenção, reforça a gestão de ativos e o monitoramento da qualidade do serviço e contribui para reforçar os processos de relacionamento com os usuários.

## Oportunidades e aplicações nos setores de infraestrutura

### Planejamento e concepção de sistemas de infraestruturas

A IA oferece às organizações dos setores de infraestrutura oportunidades para otimizar os processos de planejamento e concepção de projetos e sistemas. No setor de energia, os avanços tecnológicos, o crescimento demográfico, o aumento da produção e a melhoria das condições de vida da população conduziram a um aumento significativo do consumo mundial de eletricidade nas últimas décadas (Bedi & Toshniwal, 2019). Neste contexto, a utilização de modelos de previsão da demanda tem aumentado nos últimos anos para fazer projeções a curto e longo prazos, bem como para projetar o

40 O setor da energia tem sido tradicionalmente um dos primeiros a adotar a tecnologia, em comparação com outros setores tradicionais como a da água e do saneamento.

consumo a nível micro (consumidores individuais) e a nível macro (cidades e mesmo países) (Del Real et al. 2020).

Do mesmo modo, os modelos de IA foram utilizados em diferentes países para otimizar a conceção de centrais elétricas e calibrar o seu dimensionamento (Kumar & Saini, 2021). A este respeito, Senthil Kumar et al (2013) utilizaram um modelo de Rede Neural Artificial (RNA) para prever a carga de sedimentos nas bacias hidrográficas, o que permitiu otimizar a conceção e a capacidade de produção de uma central hidrelétrica. Os algoritmos de IA também foram utilizados para identificar os tipos de elementos que afetam a produção de uma central e, assim, otimizar a sua conceção (Kumar & Saini, 2021). No Iraque, por exemplo, os pesquisadores previram a produção de energia de uma pequena central hidrelétrica na barragem do Lago Himreen utilizando um modelo baseado em RNA e concluíram que as variáveis com maior impacto na produção de energia são o fluxo de água e a queda líquida da turbina (Hammid et al., 2018).

Do mesmo modo, a IA oferece oportunidades para melhorar o projeto de parques eólicos, para otimizar o uso da terra e o número de turbinas a serem instaladas. Um exemplo disso é

o uso de algoritmos genéticos<sup>41</sup> que podem ajudar a tornar mais eficiente a instalação de parques eólicos e a maximizar a capacidade de produção de energia (Grady et al., 2005). Esses algoritmos levam em consideração as variações na direção e velocidade do vento no local das turbinas e, desta forma, identificam o projeto ideal que minimiza o custo por unidade de energia gerada (Grady et al., 2005).

No planejamento do setor de transportes, as sociedades enfrentam desafios em termos de mobilidade, congestionamento, segurança rodoviária, utilização do espaço público e emissões de gases, entre outros. O desenvolvimento de sistemas de transporte bem conectados e multimodais é um dos objetivos mais importantes para as agências de planejamento como meio de aumentar a eficiência e diminuir as barreiras de acesso e o congestionamento nas áreas metropolitanas (Yang et al., 2018).

---

41 Um algoritmo genético é uma técnica de pesquisa computacional para encontrar soluções aproximadas para modelos de otimização e problemas de pesquisa. Inspira-se no processo de evolução natural, em que as melhores soluções para um problema são selecionadas, combinadas e mutadas para criar novas soluções, tudo num processo iterativo que para quando é encontrada a melhor solução possível. Para mais informações, consultar: <<https://www.sciencedirect.com/topics/engineering/genetic-algorithm>>

Os modelos de IA desempenham um papel importante neste campo, permitindo, por exemplo, maior precisão das matrizes origem-destino para adaptar o gerenciamento dos semáforos ao fluxo de tráfego de veículos, ou otimizar as operações de transporte público para responder a choques de demanda em intervalos de tempo específicos. Alguns dos modelos mais utilizados são as regressões<sup>42</sup> que preveem o fluxo de tráfego entre diferentes pontos de origem e destino com base em variáveis como a localização, a faixa horária, o dia da semana e as condições meteorológicas (Gutiérrez Puebla et al., 2020; Yang et al., 2018). Da mesma forma, é comum o uso de modelos de redes neurais, teoria dos gráficos e simulação, entre outros (Rodrigues et al., 2019).

Algumas cidades habilitaram os seus modelos de transporte para processar dados de novas fontes de informação, como redes sociais (X, Instagram, TikTok, Waze, Strava, entre outras), serviços web (Google Maps, Waze), smartphones, cartões inteligentes de transporte e sensores instalados em infraestruturas passivas - semáforos, câmeras de segurança -, bem como informações georreferenciadas de ônibus, bicicletas, táxis e outros transportes

---

42 Regressão linear, logística e polinomial, entre outras.

públicos (Gutiérrez Puebla et al., 2020). Da mesma forma, no caso da ALC, a Divisão de Transportes do BID desenvolveu uma análise abrangente das características e custos do congestionamento urbano em dez cidades da região, utilizando Big Data e IA para analisar a dinâmica do congestionamento em cada uma dessas cidades e seu impacto nos custos diretos e indiretos para os países (Calatayud et al., 2021).

Outro caso de utilização relevante é a aplicação de modelos preditivos de oferta e procura para o planejamento do sistema de transportes. Um exemplo é o modelo preditivo desenvolvido pelo BID para a Área Metropolitana de San Salvador, em El Salvador. Para a construção do modelo, o BID utilizou a metodologia *Smart Steps*<sup>43</sup> da LUCA-Telefónica, através da qual, por meio de informações fornecidas por registros de *detalhes de chamadas* (CDR)<sup>44</sup>, e com informações de

tráfego obtidas através de *crowdsourcing* no Google, os pesquisadores identificaram as viagens realizadas e criaram matrizes de origem e destino (Rendón Rodríguez et al., 2020).

O modelo delineado fornece informações sobre as estradas mais movimentadas, o fluxo de veículos, as infraestruturas críticas do sistema, a ocupação dos transportes públicos e as faixas horárias de maior tensão, o que permite avaliar o impacto de vários projetos de infraestrutura através de simulações. Os projetos que podem ser analisados incluem a reorganização das rotas e estações de transportes públicos, alterações nos sentidos das estradas, a expansão da rede rodoviária e a inclusão de novos modelos de transporte (Rendón Rodríguez et al., 2020).

A IA é também utilizada no planejamento para melhorar a capacidade de resposta da infraestrutura de transportes, energia e água a fenômenos meteorológicos e catástrofes naturais. No setor hidrelétrico, como mencionado, a projeção de fluxos de água representa um dos principais desafios de planejamento. Tradicionalmente, os operadores de centrais

os números envolvidos, a localização, o custo e algumas informações sobre a qualidade da chamada.

elétricas têm utilizado dados históricos e modelos básicos para prever os fluxos de água, mas com o aumento da variabilidade meteorológica esses métodos tradicionais tornaram-se menos confiáveis. Em resposta, a IA processa grandes quantidades de dados de várias fontes, gerando previsões de fluxo mais precisas e oportunas. Na Índia, por exemplo, a empresa HydroGrid ajudou um operador de uma central hidrelétrica a gerir a sua central de forma segura durante a estação das chuvas sazonais de vento (monção). De acordo com a empresa, a solução de planejamento inteligente baseada em IA permitiu ao operador aumentar a eficiência e as receitas durante este período e melhorar a segurança da população local.<sup>45</sup>

Outro exemplo dessas aplicações são aquelas que visam prever os fluxos de águas residuais para o correto planejamento e gerenciamento das estações de tratamento (Q. Zhang et al., 2019). Alguns modelos de previsão de fluxos de águas residuais têm se concentrado na simulação do comportamento dos sistemas de coleta. No entanto, esses modelos podem apresentar desafios em relação aos pressupostos necessários, porque o comportamento da precipitação, da infiltração, do derretimento da

43 É o primeiro serviço de Big Data da Telefónica que recolhe, anonimiza e agrega dados móveis da rede da Telefónica para compreender o comportamento de segmentos da população como um todo. Com uma abordagem diferenciada de acordo com o setor em estudo, analisa as tendências e os comportamentos de multidões, mas não de indivíduos.

44 Refere-se a um registo detalhado de uma chamada. As informações normalmente captadas por este tipo de registo são: a hora e a data da chamada, a duração,

45 Fonte: International Water Power (2024). Aproveitar a IA para transformar a energia hidroelétrica. Disponível em: < <https://www.waterpowermagazine.com/analysis/harnessing-ai-to-transform-hydropower/> >

neve e da adaptação da infraestrutura já existente não são fáceis de simular. Conseqüentemente, foram desenvolvidos modelos de previsão com técnicas de IA de aprendizagem profunda utilizando informações coletadas pelas estações de tratamento. Nesse sentido, um exercício realizado com informações da estação de tratamento de Ontário, Canadá, no qual foi implementado um modelo de rede neural multicamadas, obteve uma previsão satisfatória (Q. Zhang et al., 2019).

### Construção de sistemas, implantação e gestão de ativos

O setor de energia elétrica é intensivo em capital porque suas operações dependem de infraestrutura de geração, redes de transmissão e distribuição e outros ativos físicos. Neste setor, as atividades de monitoramento e inspeção de infraestrutura são geralmente caras porque alguns dos ativos podem estar localizados em locais remotos e de difícil acesso, exigem pessoal altamente especializado (Lekidis et al., 2022) e geralmente devem ser realizadas com os equipamentos em operação. Em resposta a isso, diversas empresas desenvolveram programas de inspeção remota e monitoramento em tempo real para otimizar o gerenciamento e a manutenção da infraestrutura, fornecer alertas antecipados, reduzir o tempo do operador em campo, reduzir acidentes e melhorar os indicadores de disponibilidade dos equipamentos.

Neste campo, destacam-se três abordagens apoiadas em tecnologia - incluindo a IA – que vêm sendo utilizadas pelas empresas do setor: i) a utilização de Veículos Aéreos Não Tripulados (VANTs) em conjunto com algoritmos de análise de imagens e vídeos, que reduzem os custos de levantamento (topografia), o tempo de trabalho e melhoram a precisão (Rennie et al, 2020); ii) a utilização da Internet das Coisas (IoT), através da implantação de sensores em diferentes componentes da infraestrutura e do desenvolvimento de análises avançadas com base nas informações coletadas (Rennie et al., 2020); e iii) o desenvolvimento de “gêmeos digitais” (DT) para modelar o comportamento dos elementos da rede por meio de técnicas de aprendizado de máquina e simular esse comportamento.

Nesse sentido, modelos de IA que processam os dados coletados pelos UAV foram utilizados nos últimos anos para detectar objetos e identificar falhas e anomalias. Esses modelos<sup>46</sup> identificam todos os elementos da rede e reconhecem o status desses elementos, para que alertas

possam ser gerados para manutenção de forma preventiva. Além disso, esses modelos permitem elaborar esquemas de classificação<sup>47</sup> de falhas e anomalias, a fim de otimizar as atividades de manutenção corretiva. Por exemplo, o operador de uma central hidrelétrica na Grécia implementou um sistema piloto de monitoramento e inspeção baseado em UAVs, que incluía um componente de análise de imagens e vídeos através de redes neuronais convolucionais. Com isso, foi possível reduzir o número de acidentes por ano em cerca de 70%, aumentar a taxa de identificação de falhas e anomalias em 80% e gerar uma economia aproximada de 85% do orçamento de manutenção (Lekidis et al., 2022; Liu et al., 2020).

Programas semelhantes estão sendo desenvolvidos em diferentes países da região. Na Colômbia, a Interconexión Eléctrica - ISA, uma empresa de transmissão de energia elétrica, utilizou a IA para detectar falhas na infraestrutura de transmissão de energia elétrica e incorporar maior eficiência no planejamento da manutenção. A ferramenta de IA analisa fotografias associadas a relatórios de inspeção de campo

46 Seções posteriores do documento explicam mais detalhadamente este tipo de modelos para compreender o seu alcance, oportunidades e limitações, mas, em geral, para o tipo de soluções aqui descritas, foram utilizadas Redes Neuronais Convolucionais (CNN) e YOLO (You Only Look Once).

47 Em seções posteriores do documento, este tipo de modelo é explicado mais detalhadamente de forma a compreender o seu alcance, oportunidades e limitações, no entanto, em geral, para o tipo de soluções aqui descritas, foram utilizados modelos de clustering como o DBSCAN e modelos de classificação como o Random Forest e o XGBoost (Extreme Gradient Boosting).

e, utilizando algoritmos de detecção de objetos, constrói modelos de classificação para identificar falhas ou anomalias, o que reduziu significativamente os tempos de intervenção.<sup>48</sup>

Existem também sistemas baseados em IA que monitoram o estado dos transformadores nas redes elétricas, com o objetivo de gerenciar seu status, planejar a manutenção e prevenir falhas. Esses sistemas utilizam geralmente informações sobre gases gerados, temperatura, corrente, tensão, entre outras, coletadas por sensores (Li, 2023). Um exemplo disso é o *Ronin AI*, uma plataforma em nuvem desenvolvida pela empresa *Seetalabs* que permite monitorar em tempo real o estado dos transformadores para evitar quedas abruptas no fornecimento de energia e planejar a manutenção adequada desses equipamentos.<sup>49</sup>

Por sua vez, como mencionado, os gêmeos digitais são uma ferramenta que utiliza algoritmos de aprendizagem automática e que tem um grande potencial de uso nos

setores de infraestrutura. Esta ferramenta consiste em uma representação virtual e em tempo real de um objeto, sistema, processo ou infraestrutura física, que está conectada bidireccionalmente à sua contraparte física (Fuller et al., 2020; Latorre et al., 2024; Sharma et al., 2022). Esta ligação permite ao gêmeo digital coletar, processar e analisar dados do objeto físico em tempo real, o que lhe permite monitorar, simular e otimizar o desempenho do elemento, bem como prever as necessidades de manutenção preventiva (Fuller et al., 2020; Latorre et al., 2024; Sharma et al., 2022). Uma característica importante desta ferramenta é que não só replica o estado e o comportamento da infraestrutura física, como também prevê o seu desempenho futuro, contribuindo para otimizar o seu funcionamento. Da mesma forma, permite simular os efeitos de alterações no objeto físico sem danos reais, possibilitando testar modificações nos processos a baixo custo (Fuller et al., 2020; Latorre et al., 2024; Sharma et al., 2022).

A ferramenta dos gêmeos digitais tem sido muito utilizada no setor da energia para otimizar o funcionamento das centrais elétricas e dos sistemas de transmissão e distribuição (Latorre et al., 2024). Por exemplo, a empresa espanhola de energia

Endesa<sup>50</sup>, que opera principalmente na Espanha e Portugal, implementou gêmeos digitais nas 38 principais centrais hidrelétricas, que representam aproximadamente 70% da capacidade instalada. Isto permitiu-lhe analisar informações relevantes como temperatura, velocidade, pressão e vibração, entre outras, para otimizar o controle do funcionamento das centrais, bem como para alertar sobre anomalias e possíveis falhas no sistema. Da mesma forma, na Finlândia, o operador do sistema de transmissão *-Fingrid-* implementou com a Siemens um modelo de gêmeo digital para otimizar a rede de transmissão neste país. Isto permitiu melhorar a eficiência, a precisão e a consistência dos modelos utilizados para a gestão da rede (Sharma et al., 2022; Gámiz et al., 2020).

Por outro lado, no setor de transportes, uma área relevante de criação de valor da IA é a melhoria dos processos de monitoramento e manutenção dos ativos instalados. Por um lado, os modelos de IA permitem antecipar falhas e anomalias nas infraestruturas, possibilitando a realização de manutenção preventiva, visando aumentar

48 ISA Intercolombia aposta na Inteligência Artificial para detectar modos de falha em linhas de transmissão (2023, 18 de dezembro). Recuperado de: <<https://news.microsoft.com/es-xl/isa-intercolombia-le-apuesta-a-la-inteligencia-artificial-para-detetar-modos-de-falla-en-lineas-de-transmision/>>

49 Fonte: Seetalabs. Disponível em:< <https://seetalabs.com/product/>>

50 Endesa aplica inteligência artificial para criar "gêmeos digitais" das suas centrais hidroelétricas (2024, 8 de janeiro). Retirado de: <<https://elperiodicodelaenergia.com/endesa-aplica-inteligencia-artificial-crear-gemelos-digitales-centrales-hidroelectricas/>>Endesa - Sobre a Endesa. (2024).< <https://www.endesa.com/es/sobre-endesa/nuestro-negocio>>

sua disponibilidade e confiabilidade. Em segundo lugar, quando ocorrem falhas, os modelos identificam com maior precisão a necessidade de intervenção e geram informações relevantes para o reparo eficaz das avarias, o que, por sua vez, permite otimizar os orçamentos de manutenção, em contextos de recursos limitados (Calatayud et al., 2022).

A utilização da tecnologia e, especificamente da IA, para a detecção precoce de falhas nas infraestruturas rodoviárias contribui para reduzir o número de acidentes rodoviários nos países. Um exemplo importante na região é a ferramenta Pavimenta2, desenvolvida pelo BID e que foi implementada pelas autoridades de transporte e segurança rodoviária em onze países da ALC. Esta solução utiliza vídeos das estradas e, com base em modelos de aprendizagem profunda e visão computacional, permite diagnosticar o estado da pavimentação e da sinalização rodoviária, a fim de priorizar as atividades de manutenção rodoviária e otimizar os recursos a serem alocados. Esta ferramenta, de código aberto, facilitou a análise de 50.000 quilômetros de estradas na ALC e permitiu aumentar a eficiência dos processos de detecção do estado dos ativos rodoviários nos países onde foi implementada (**Figura 6**).

Outro caso focado na detecção de falhas na segurança viária é o *ViaSegura*, uma solução de IA baseada em aprendizado de máquina e visão computacional desenvolvida pelo BID e pelo IRAP<sup>51</sup>. Essa aplicação realiza um monitoramento preciso das estradas e detecta elementos de segurança rodoviária como a disposição e o número de faixas de rodagem, a iluminação, a presença de estações de serviços de apoio, entre outros, para gerar alertas de manutenção preventiva e corretiva<sup>52</sup>. Essa solução, de uso gratuito, permitiu o processamento de mais de 61.000 quilômetros no Brasil, Equador, Guatemala e Peru<sup>53</sup> (**Figura 7**). Da mesma forma, o Ministério dos Transportes e Obras Públicas do Uruguai, em colaboração com o BID, realizou um exercício-piloto de levantamento de falhas na rede rodoviária do país, que se baseou na análise de imagens através de um modelo de IA. Os resultados deste teste forneceram ao ministério elementos para tornar as atividades de inspeção e manutenção mais eficientes.<sup>54</sup>

Outro componente importante da gestão da rede rodoviária é a identificação das estradas nas zonas rurais. Esta é uma tarefa difícil porque abrange áreas do país que, em função da sua localização e topografia, são remotas. Em diferentes países, a forma convencional de identificar e monitorar este tipo de estrada tem sido manual, com equipes que saem para identificar as estradas e reportar o seu estado. Na Colômbia, o Departamento Nacional de Planejamento (DNP) desenvolveu um aplicativo que, através da análise de imagens de satélite e da utilização de modelos de *aprendizagem automática*, permitiu inventariar a rede rodoviária terciária do país. Este inventário serviu de base para a formulação da Estratégia Integral da Rede Rodoviária da Colômbia (Assessoria Presidencial para os Assuntos Econômicos e a Transformação Digital, 2020).

51 O Programa Internacional de Avaliação de Estradas (IRAP) é uma instituição de caridade que tem como objetivo salvar vidas através da eliminação de estradas de alto risco em todo o mundo. Mais informações estão disponíveis em: <<https://irap.org/about-us/>>

52 ViaSegura. Recuperado de: <https://irap.org/es/rap-tools/light-ratings/viasegura>  
ViaSegura. Recuperado de: <<https://fairlac.iadb.org/piloto/viasegura>>

53 ViaSegura. Recuperado de: <<https://fairlac.iadb.org/piloto/viasegura>>

54 Fonte: entrevista com funcionários do Ministério dos Transportes e Obras Públicas do Uruguai.

**Figura 6.** Descrição do caso Pavimenta2

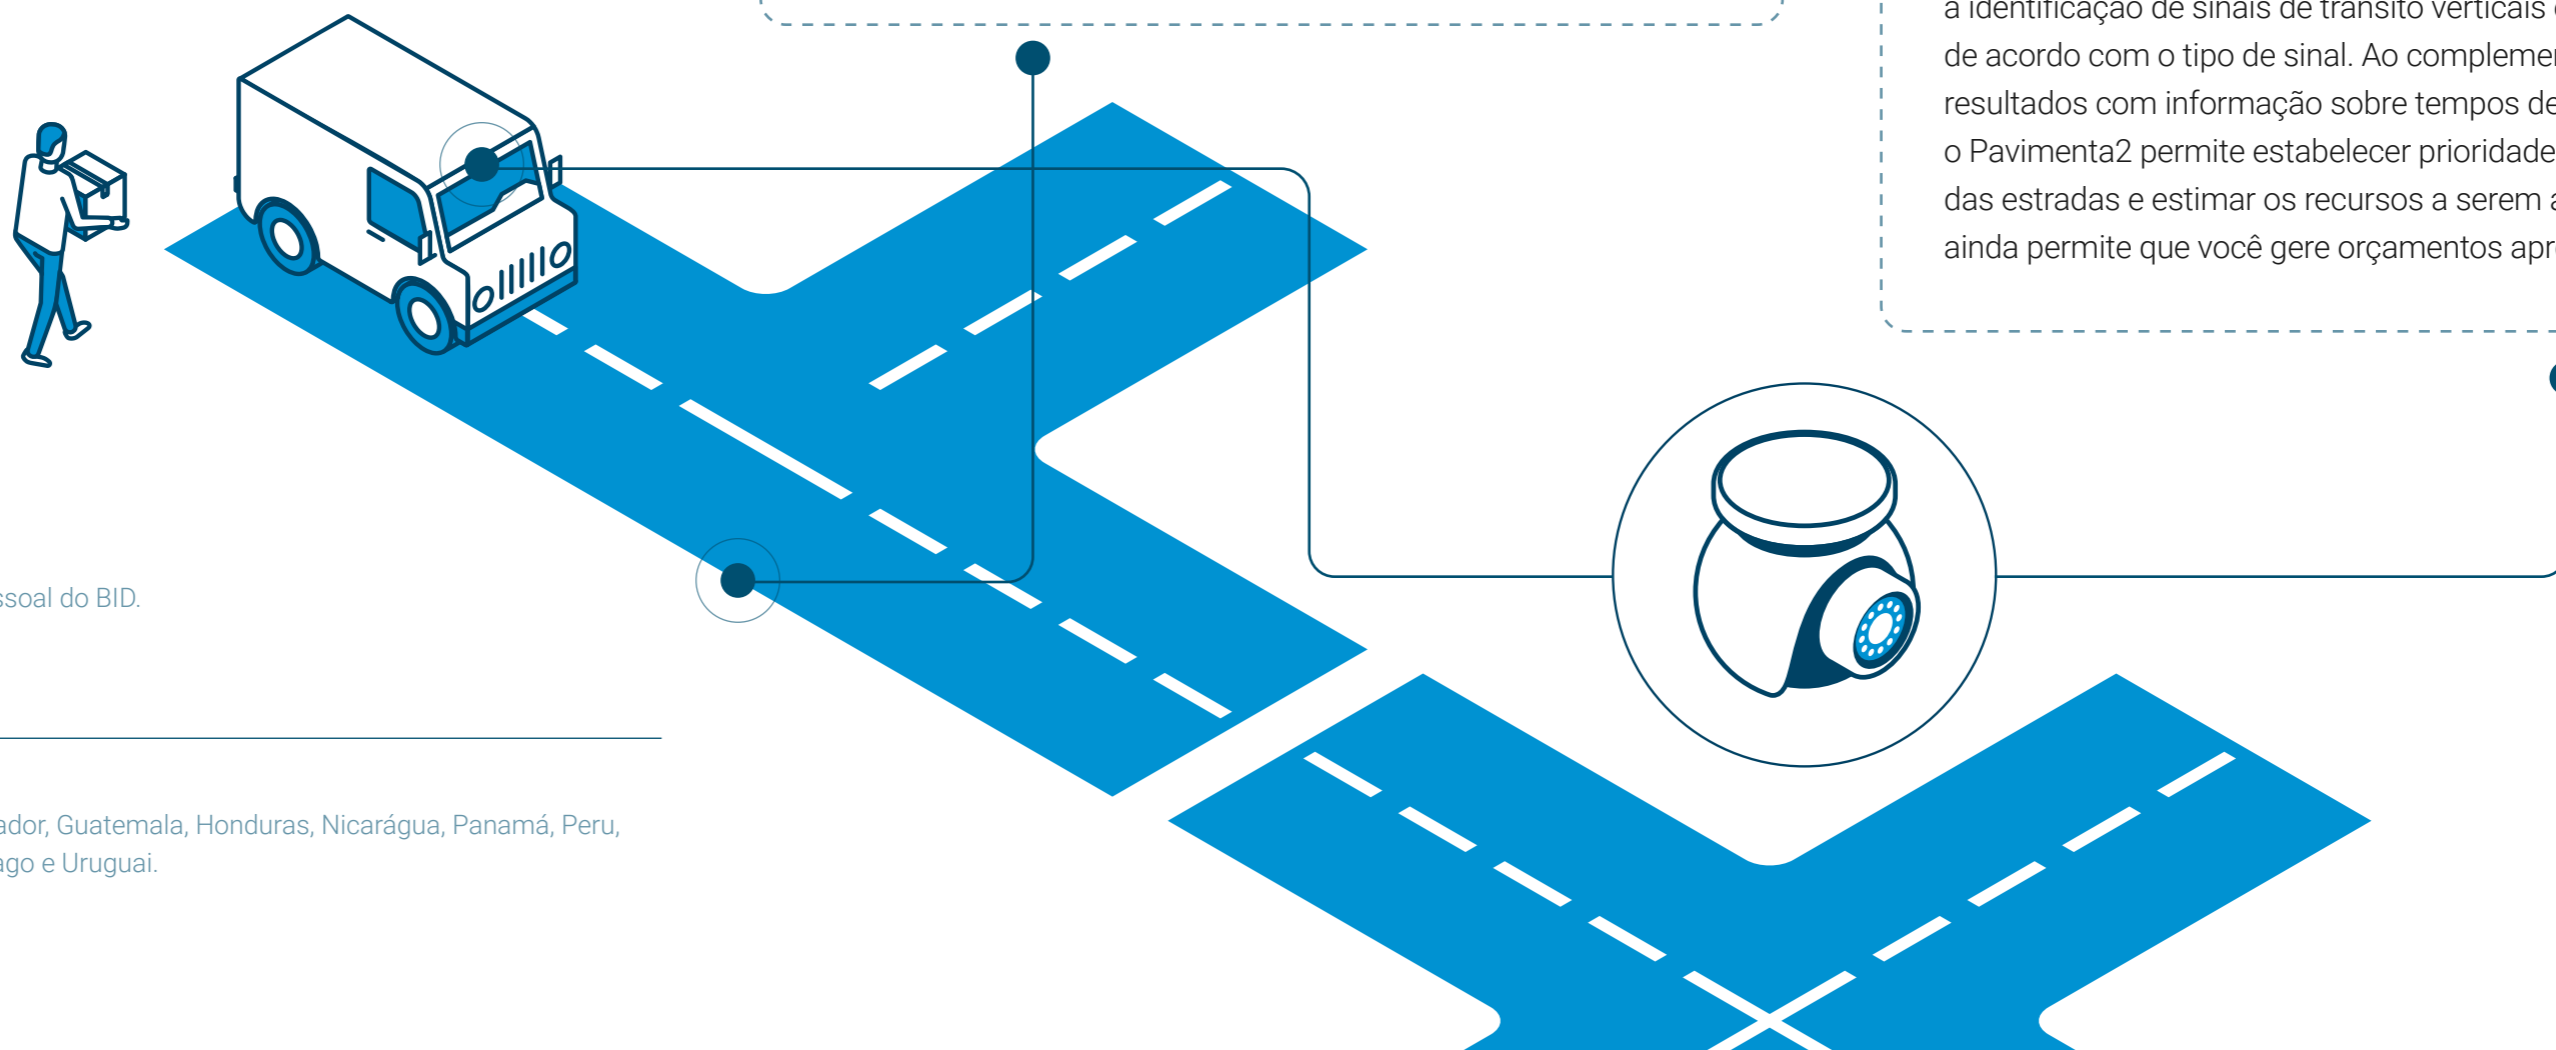
**Pavimenta2** é uma solução baseada em IA desenvolvida pelo BID que facilita a gestão do inventário de ativos rodoviários através da detecção do estado da sinalização rodoviária e do pavimento. Essa ferramenta tem sido utilizada por entidades de transportes e segurança rodoviária em onze países da América Latina e do Caribe.<sup>55</sup>

#### Problema a ser resolvido

A análise da infraestrutura rodoviária e dos ativos rodoviários é demorada, dispendiosa e requer pessoal especializado com capacidade para analisar as estradas manualmente. As estimativas do orçamento necessário para analisar 10.000 quilômetros de estradas ultrapassam os 3 milhões de dólares americanos em um ano e meio. Diante deste problema, a IA oferece alternativas para tornar a análise mais eficiente, facilitando o fluxo de veículos e a manutenção oportuna e frequente dos ativos rodoviários, minimizando os riscos rodoviários associados e aprimorando a logística e a integração econômica.

#### Descrição da solução

O Pavimenta2 é uma solução de código aberto que utiliza como entrada os vídeos gravados por câmeras do Sistema de Posicionamento Global (GPS) localizadas em veículos convencionais. Essa informação é analisada por meio de ferramentas de IA de aprendizagem profunda e *visão computacional* e é incorporada em relatórios que georreferenciam e quantificam as descobertas. Estes resultados incluem, por um lado, a detecção, classificação e medição de defeitos no pavimento, tais como rachaduras, pele de crocodilo, fissuras e buracos, entre outros. Os resultados também incluem a identificação de sinais de trânsito verticais e a sua classificação de acordo com o tipo de sinal. Ao complementar estes resultados com informação sobre tempos de viagem e acidentes, o Pavimenta2 permite estabelecer prioridades na manutenção das estradas e estimar os recursos a serem alocados. Ele ainda permite que você gere orçamentos aproximados.



Fonte: BID, entrevistas com pessoal do BID.

55 Brasil, Costa Rica, El Salvador, Guatemala, Honduras, Nicarágua, Panamá, Peru, Suriname, Trinidad e Tobago e Uruguai.

## Resultados e impacto

A implementação do Pavimenta2 facilitou a análise de 50.000 quilômetros de estradas da região e tornou mais eficiente o processo de detecção do estado do patrimônio rodoviário, com níveis de precisão superiores a 85%. Além disso, a adoção do Pavimenta2 permitiu uma redução de 53 vezes nos custos e de 39 vezes no tempo necessário para analisar a rede rodoviária, em comparação com a alternativa manual. Esta solução contribuiu também para a redução do erro humano e para a promoção de uma melhor tomada de decisão relativamente às infraestruturas através de visualizações.

Além disso, em 2023, o BID lançou o curso “Inteligência Artificial no Transporte”. Trata-se de um curso virtual de acesso gratuito voltado para participantes da ALC cujo campo de atuação profissional esteja relacionado ao setor de transportes. O curso introduz uma visão geral da IA e apresenta algumas aplicações atualmente disponíveis no setor de transportes. O curso também examina tecnologias específicas, tais como os modelos de *aprendizagem automática* desenvolvidos para a solução Pavimenta2.

## Conclusões

De acordo com os entrevistados, o Pavimenta2 permitiu georreferenciar a rede rodoviária e os seus defeitos, priorizar as intervenções e o tipo de reparações a serem realizadas. A implementação do Pavimenta2 tem sido receptiva aos beneficiários em termos das vantagens desta ferramenta. Entre as lições aprendidas está a importância das competências digitais que permitem a gestão de ferramentas semelhantes, o envolvimento de outros setores, como o acadêmico, e a importância de ter a infraestrutura de TI necessária. Código disponível em: <https://iadb.org/es/indes/rea-inteligencia-artificial-en-el-transporte>

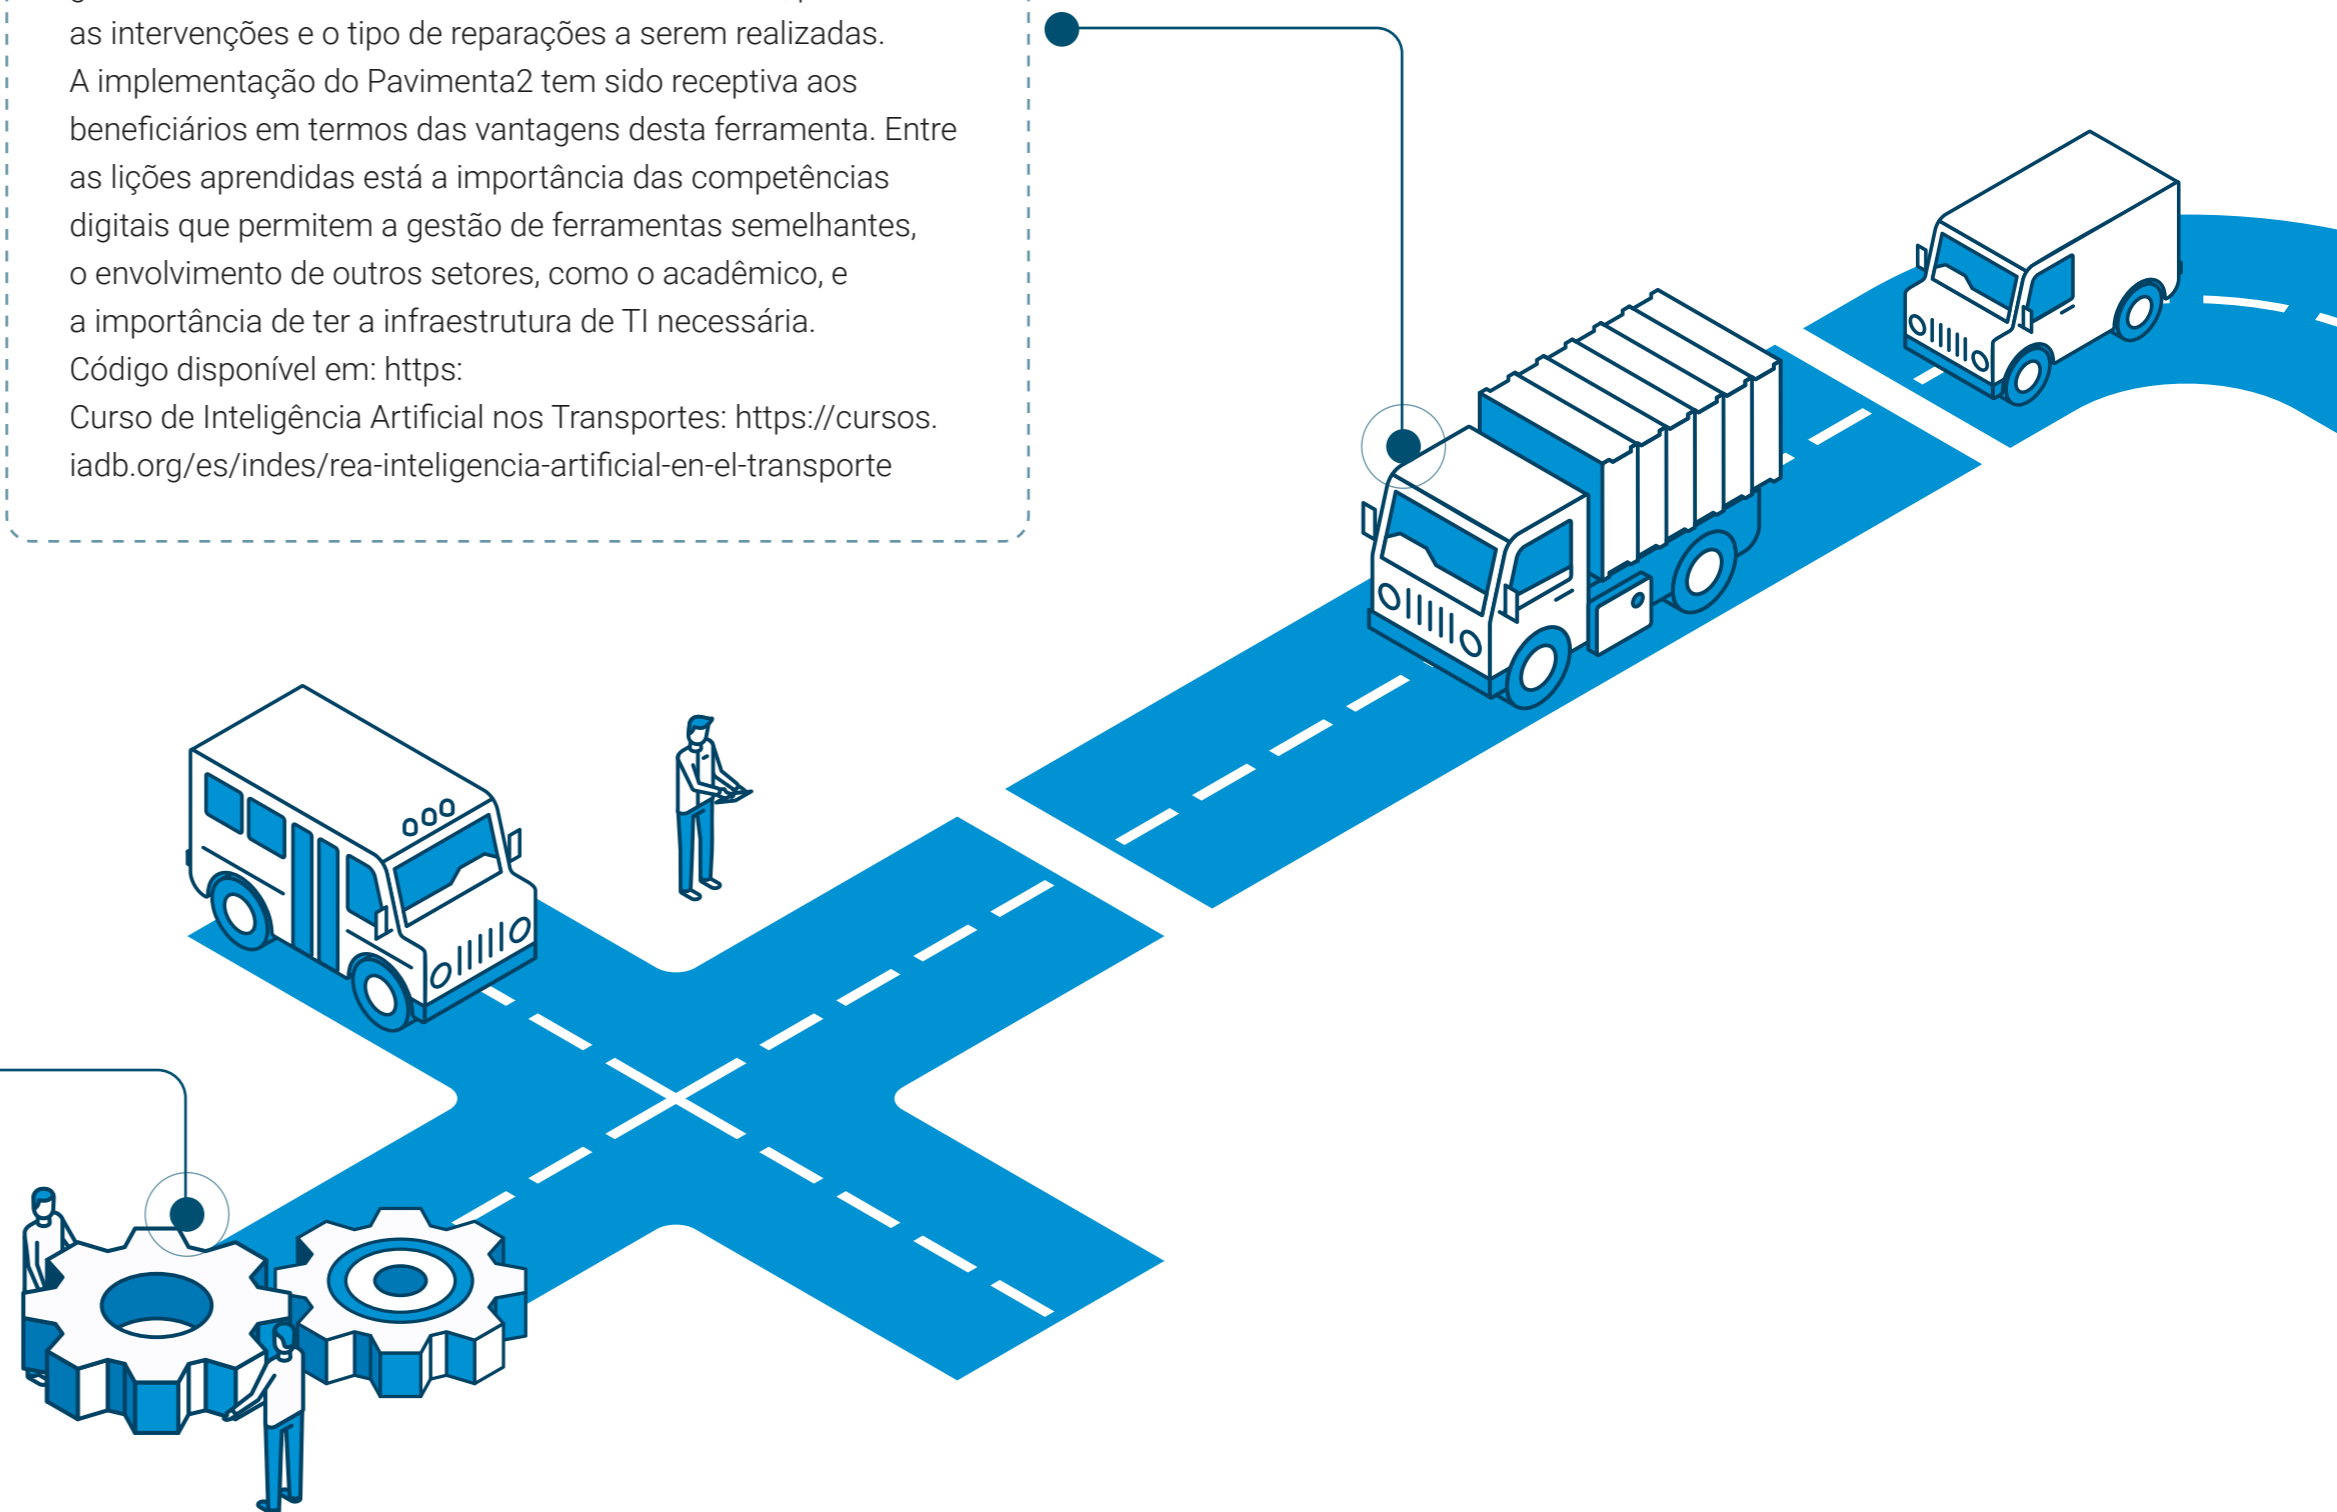


Figura 7. Descrição do caso ViaSegura

**ViaSegura** é um projeto piloto desenvolvido em conjunto pelo BID e pelo International Road Assessment Programme (iRAP). Este projeto utilizou a IA para detectar precocemente as condições das estradas e melhorar a segurança rodoviária em quatro países da região (Brasil, Equador, Guatemala e Peru).

#### Problema a ser resolvido

Os defeitos na infraestrutura rodoviária podem causar ferimentos e mortes de pessoas envolvidas em acidentes. Como resultado, o iRAP criou um protocolo (Star Rating) para determinar o nível de segurança da infraestrutura rodoviária para diferentes partes interessadas, classificando manualmente as estradas com base em imagens e vídeos em uma escala de 1 a 5, onde um é o menos seguro e cinco é o mais seguro. O ViaSegura permitiu automatizar este processo através de IA e, nesse sentido, otimizar a identificação de diferentes elementos de segurança rodoviária como a delimitação e iluminação da estrada, o número de faixas de rodagem, e outros aspectos como a qualidade das curvas e a resistência à derrapagem, entre outros.

#### Descrição da solução

O ViaSegura automatiza a análise de classificação de rodovias utilizando ferramentas de IA, em especial machine learning (aprendizado supervisionado), deep learning e visão computacional. Esses modelos foram treinados em mais de 60.000 imagens de rodovias do Brasil.

#### Resultados e impacto

Este projeto conseguiu marcar imagens de infraestrutura rodoviária de forma mais rápida e eficiente em mais de 61.000 quilômetros de estradas na região, permitindo às autoridades de transportes tomarem medidas corretivas em relação a essa infraestrutura. De fato, o BID e o iRAP mencionaram que a ferramenta reduziu o tempo de inspeção da infraestrutura rodoviária de 78 para 2 semanas por cada 10.000 quilômetros de estradas, com uma precisão de mais de 85%. Isto, por sua vez, gerou reduções significativas nos custos associados.

Código disponível em: <https://github.com/EL-BID/VIasegura>.



No setor de água e saneamento, as perdas físicas de água nos sistemas de abastecimento representam um dos maiores desafios para o setor, uma vez que têm um impacto significativo no volume de negócios das empresas. Essas perdas geralmente estão associadas a vazamentos em dutos de distribuição causados por problemas como deterioração da infraestrutura e subsidência do solo.

As estratégias tradicionais de controle de perdas técnicas são baseadas no tratamento de vazamentos relatados pelos usuários (controle passivo), pesquisas periódicas ou monitoramento por zona ou setor. A supervisão geralmente recai sobre a competência do operador em serviço, e a precisão da identificação pode ser afetada pela subjetividade do agente e seu nível de treinamento. Por este motivo, surgiram recentemente aplicações baseadas em IA que procuram acrescentar valor, estabelecendo mecanismos de classificação com precisão suficiente para detectar vazamentos de água com base nas informações coletadas (Mounce et al., 2010; Vanijirattikhan et al., 2022).

Uma dessas soluções é fornecida pela empresa estatal Servicio de Agua Potable y Alcantarillado de Lima (SEDAPAL), que opera na Área Metropolitana de Lima. Essa empresa, em parceria com o BID, a Fundação FEMSA e os governos

da Suíça e de Israel, realizou um projeto piloto que utiliza computação em nuvem e modelos de IA para gerenciar sistemas de tratamento de água e resíduos. Com este projeto piloto, a empresa conseguiu detectar 7.000 eventos, incluindo perdas de água, aumento de vazão, falha nos medidores ou na telemetria e alterações de pressão (Brzezinski, 2023).

### Operação e manutenção dos sistemas

Um dos fatores determinantes na gestão dos sistemas de geração e distribuição de energia é a necessidade de garantir a eficiência da sua operação e manutenção, para atender ao aumento contínuo da demanda e proporcionar um fornecimento confiável de eletricidade.

O gerenciamento eficiente da capacidade da rede prioriza a geração de energia de menor custo<sup>56</sup>, tanto em termos monetários quanto ambientais. Da mesma forma, a gestão de energia pode se concentrar na otimização da capacidade dos sistemas locais. Alguns trabalhos empíricos constataram

que a implementação de uma estratégia de monitoramento de consumo em conjunto com um sistema de armazenamento que permite reduzir o consumo da rede em momentos de estresse do sistema, reduz consideravelmente os custos operacionais e as emissões de CO<sub>2</sub> (H. Zhang et al., 2012). Um caso de utilização da IA nesse sentido são os sistemas de gerenciamento inteligente que integram o sistema de gerenciamento da capacidade e o uso de sistemas de armazenamento de energia com modelos de previsão do preço e demanda para determinar os cronogramas ideais de carregamento e de utilização do armazenamento, seja da rede de distribuição ou do sistema de baterias (Abdalla et al., 2021; Ahmad et al., 2022).

No mesmo sentido, estão sendo desenvolvidas soluções baseadas em IA relevantes para os provedores de serviços de fornecimento de energia elétrica em torno das *redes inteligentes*, que utilizam contadores inteligentes, tecnologias avançadas de telecomunicações e sistemas de controle remoto para coordenar eficientemente todos os agentes da rede. Esses sistemas permitem a comunicação bidirecional entre os centros de informações e os usuários e produzem informações que alimentam os modelos de gerenciamento da demanda para desenvolver aplicações como o gerenciamento dos picos de demanda, em que o consumo é gerenciado em função dos

<sup>56</sup> Normalmente, os países usam um modelo de otimização de múltiplas restrições para determinar a entrada de energia no sistema. Avalia a capacidade e o custo médio de geração de diferentes usinas, sejam elas térmicas (gás ou carvão), hidrelétricas, nucleares, solares ou eólicas, selecionando aquelas que são mais eficientes e atendem à segurança energética do sistema.

níveis de carga no sistema (Johannesen et al., 2019). Além disso, foram desenvolvidas aplicações baseadas em IA que, a partir de informações coletadas de dispositivos de medição, identificam e monitoram em tempo real a topologia e o estado físico da rede em sistemas de distribuição de energia (Li et al., 2020), o que otimiza a sua operação e controle (Chung et al., 2023) e melhora a sua confiabilidade e resiliência.

Na França, uma empresa desenvolveu um aplicativo<sup>57</sup> que analisa o nível de consumo de energia elétrica no país e envia sinais aos usuários dependendo do nível de estresse no sistema. A plataforma fornece informações em tempo real sobre a demanda e os preços no atacado, bem como modelos de previsão para que os consumidores possam planejar o seu consumo de eletricidade ao longo do dia. Além disso, em países com elevados níveis de perdas técnicas e não técnicas, a utilização de tais redes permitiu a identificação eficaz dessas perdas e, portanto, o desenvolvimento de planos para preveni-las (Levy et al., 2018).

Outro caso de soluções que visam a eficiência e a sustentabilidade na operação são os *sistemas de gestão*

*de energia em edifícios* (BEMS) que incluem modelos de previsão da demanda, que foram implementados para melhorar o planejamento e o gerenciamento do consumo de energia, otimizar os recursos e diminuir a emissão de carbono (Runge & Zmeureanu, 2021). Uma empresa britânica desenvolveu uma aplicação que combina informações do sistema de gerenciamento de energia de um edifício com informações meteorológicas para otimizar a utilização de energia em tempo real<sup>58</sup> utilizando algoritmos de IA. Este software se conecta a medidores inteligentes e à rede central de energia, permitindo aos gerentes otimizarem o consumo com base nos preços de atacado. Isso gerou uma economia nos custos de energia de cerca de 10% nos edifícios que implementaram esta ferramenta e uma redução aproximada de até 40% nas emissões de carbono.<sup>59</sup>

A detecção de perdas de energia, sejam elas perdas físicas nas redes (perdas técnicas) ou consumos não autorizados associados à pirataria ou fraude (perdas não técnicas), é

outro dos principais desafios enfrentados pelas empresas de fornecimento de energia elétrica. Em relação às perdas não técnicas, têm sido desenvolvidas soluções baseadas em IA que permitem às empresas prever a possibilidade de consumo não autorizado por parte de determinados clientes, possibilitando otimizar as atividades de monitoramento e fiscalização. Um caso relevante na região é a ferramenta *Energizados*, desenvolvida pelo BID e implementada por empresas de energia no Brasil, Guatemala e Costa Rica. Esta solução analisa dados históricos do consumidor e utiliza modelos de aprendizado de máquina para identificar conexões com alta probabilidade de fraude. Com o uso do *Energizados* em duas empresas da região, o índice de recuperação do investimento (Benefit-Cost Ratio) por auditoria foi de 2,9, enquanto com o método tradicional o resultado dessa relação é de 1,7. Além disso, nesses casos foi possível aumentar em média 1,65 vezes a detecção de fraudes com energia elétrica (**Figura 8**).

58 Grid Edge. Recuperado de: <<https://gridedge.ai/ai-for-flexibility/>>

59 Estudo de caso: Inteligência Artificial para Sistemas de Gestão de Energia em Edifícios (2019, 20 de junho). Recuperado de: <<https://www.iea.org/articles/case-study-artificial-intelligence-for-building-energy-management-systems>>

57 Ecowatt. Recuperado de: <<https://www.monecowatt.fr/>>

**Figura 8.** Descrição do caso Energizado

**O Energizados** é uma ferramenta desenvolvida pelo BID que identifica através de IA as perdas técnicas e não técnicas das entidades do setor elétrico. Esta solução foi implementada na Companhia Estadual de Eletricidade do Rio Grande do Sul no Brasil, na Companhia de Eletricidade da Guatemala e na Companhia Nacional de Força e Luz da Costa Rica.

### Problema a ser resolvido

Na ALC, o setor elétrico enfrenta perdas de cerca de 15% do fornecimento total de energia elétrica. As perdas não técnicas, associadas ao furto de energia, fraudes ou erros de contagem, afetam a sustentabilidade financeira das empresas de energia, aumentam os custos para a população e constituem um risco para a segurança das comunidades no caso de ligações ilegais (“gatos” na energia). O Energizados busca solucionar esses problemas, melhorando o funcionamento da rede elétrica e aumentando a eficiência das atividades de distribuição de energia.

### Descrição da solução


O Energizados é uma solução de código aberto que utiliza dados históricos de consumo para identificar ligações com elevada probabilidade de serem fraudulentas, utilizando ferramentas de IA como modelos de regras supervisionados, semi-supervisionados e analíticos. Esses modelos facilitaram a análise das conexões elétricas de todas as empresas e a identificação de anomalias e fraudes, que foram posteriormente verificadas por inspeções manuais que retroalimentam os modelos. Além disso, o Energizados apresenta os resultados através de visualizações geográficas que facilitam a análise territorial e contribuem para uma melhor tomada de decisão, proporcionando maior eficiência no planejamento das fiscalizações.

### Resultados e impacto

Com a utilização do Energizados em duas empresas, a relação custo-benefício (RCB) aumentou de 1,7 para 2,9. Além disso, a detecção de fraudes de eletricidade pode ser aumentada em 1,65 vezes com esta ferramenta. No caso da Companhia Estadual de Eletricidade do Rio Grande do Sul, no Brasil, a adoção do Energizados aumentou a taxa de identificação de fraudes de 17-23% para 28%. Desta forma, onde foi implementado, o Energizados aumentou a precisão e a eficiência das fiscalizações e reduziu os seus custos.

### Conclusões

De acordo com os entrevistados, o Energizados é um exemplo de solução acessível e de fácil implementação em outros países da região que transforma o setor por meio do uso de IA, alcançando níveis mais altos de precisão de fiscalização a um custo menor e em menos tempo. Dentre os fatores de sucesso desse projeto estão a disponibilidade de dados, o compromisso da direção das empresas com a inovação e a articulação entre cientistas de dados, desenvolvedores de produtos e clientes. Código disponível: <https://github.com/EL-BID/Energizados>



Além disso, o desenvolvimento e a implementação de modelos de previsão de preços no atacado ganharam força neste setor. Esses modelos são usados como entrada para a formulação de planos de produção para geradores, bem como para o desenho de estratégias de licitação para empresários. Isso permite que os fornecedores avancem na otimização de seus processos e na redução de seus custos, resultando em maior eficiência no uso de recursos naturais, melhor programação do consumo e menores tarifas para o usuário final (Pourdaryaei et al., 2024). Por exemplo, na fase de operação e manutenção, os modelos de previsão ajudam a otimizar a variabilidade do fluxo de água para as usinas hidrelétricas e a reduzir as suas perdas (Arch et al., 2019). Da mesma forma, no campo do marketing, esses modelos potencializam a automação de ofertas comerciais, o que aumenta a probabilidade de fechar contratos (Arch et al., 2019). Neste contexto, nos últimos anos, o desenvolvimento destes modelos tem incorporado componentes de IA que respondem melhor a desafios como a análise de choques não lineares<sup>60</sup> relacionados com o comportamento dos preços, a inferência de relações ocultas entre variáveis e o

60 O conceito de uma relação não linear entre variáveis refere-se ao facto de essa relação envolver dependências complexas que não podem ser representadas por uma linha reta e, por isso, requer outras formas de representação, como uma função quadrática, polinomial ou de padrão irregular.

desenvolvimento de capacidades de aprendizagem sobre o passado para melhorar a precisão das previsões (Castelli et al., 2020; Pourdaryaei et al., 2019).

No setor de transporte, existem diversas ferramentas de IA focadas na gestão do tráfego, conhecidas como Sistemas Avançados de Gestão do Tráfego (ATMS)<sup>61</sup> que contribuem para reduzir o congestionamento, responder a acidentes de trânsito na estrada em tempo hábil e reduzir as taxas de acidentes, entre outros.<sup>62</sup> Os ATMS baseiam-se em modelos preditivos de tráfego que geram alertas à administração para solucionar problemas na infraestrutura existente ou aumentar a sua capacidade, bem como para avaliar os impactos de uma possível intervenção (Boukerche et al., 2020).

Na mesma linha, existem soluções que geram valor utilizando modelos de aprendizagem automática orientados para a previsão do congestionamento rodoviário, que analisam imagens captadas através de câmeras de segurança, drones ou fotos de fiscais de trânsito, para estimar o volume,

61 Sistemas avançados de gestão do tráfego -ATMS

62 EUA. Departamento de Transportes Administração Federal de Rodovias (2023, agosto). Recuperado de <<https://ops.fhwa.dot.gov/atdm/approaches/atm.htm>>

a velocidade e a trajetória dos veículos<sup>63</sup>. Isso aumenta a eficiência na gestão do tráfego, avaliando possíveis intervenções rodoviárias e gerenciando a distribuição dos agentes de trânsito para maximizar os recursos humanos<sup>64</sup>. Um exemplo disso são os sistemas de monitoramento baseados em IA que analisam imagens de câmeras de vigilância e modelam os fluxos de veículos para melhorar o gerenciamento dos semáforos em tempo real<sup>65</sup> e reduzir o congestionamento nas estradas<sup>66</sup>. Estes modelos foram utilizados em cidades como Pittsburgh, nos Estados Unidos, Bengaluru, na Índia, e Xangai, na China, entre outras<sup>67</sup>. Do mesmo modo, o governo de Singapura estabeleceu uma tarifação rodoviária dinâmica (Electronic Road Pricing - ERP), em que as taxas rodoviárias são fixadas utilizando modelos de aprendizagem automática que simulam o tráfego e preveem níveis de futuros congestionamentos, calculando assim um

63 Inteia. Recuperado de: <<https://inteia.com.co/estudios-de-movilidad/>>

64 Ibidem.

65 Tecnologia de Controlo Adaptativo dos Sinais (ASCT).

66 Lopez Conde, M., & Twinn, I. (2019). Como a inteligência artificial está a tornar os transportes mais seguros, mais limpos, mais fiáveis e eficientes nos mercados emergentes: Operações de gestão do tráfego. (2019, novembro). Obtido de: <<https://www.ifc.org/content/dam/ifc/doc/mgrt/emcompass-note-75-ai-making-transport-safer-in-emerging-markets.pdf>>

67 Ibidem.

nível ideal que reduzirá o congestionamento real. Para isso, desde 2020, o governo instalou sensores com tecnologia GPS nos veículos (Lehe, 2019).

Outro elemento essencial do gerenciamento de sistemas de mobilidade é a identificação dos locais dos usuários, sejam eles estáticos ou dinâmicos, o que analisa os padrões de viagem e permite um gerenciamento mais eficiente das operações dos sistemas. Essa identificação é possível graças ao *Sistema Global de Navegação por Satélite* (GNSS).<sup>68</sup> Neste sentido, em Madrid, Espanha, Romanillos et al. (2018) realizaram, em coordenação com a Empresa Municipal de Transportes da cidade, uma análise<sup>69</sup> de mais de 250.000 rotas do sistema de bicicletas públicas da cidade, BiciMAD, que permitiu estudar em profundidade os padrões de viagem dos usuários e obter informações sobre a ocupação das ruas, a fim de identificar quais delas poderiam ser habilitadas em

68 “Os GNSS são constelações de satélites coordenados para posicionar dispositivos em qualquer parte do globo”, sendo o mais conhecido o Sistema de Posicionamento Global (GPS) dos Estados Unidos, embora isso não signifique que não existam outros sistemas deste tipo desenvolvidos por outros países, como o BEIDOU da China, o GLONASS da Rússia e o GALILEO da União Europeia, só para citar alguns (Gutiérrez Puebla et al., 2020).

69 O estudo inclui análises da distribuição das viagens, do comprimento das distâncias percorridas, da velocidade, dos fluxos na rede por faixa horária e dos tempos de viagem, entre outros.

determinados dias para serem utilizadas por pedestres e bicicletas. Adicionalmente, com base nas matrizes origem-destino e na informação sobre os deslocamentos, os autores identificaram opções para alargar as vias exclusivas para bicicletas (Romanillos et al., 2018).

Do mesmo modo, foram desenvolvidos diferentes modelos de previsão de acidentes rodoviários que identificam os trechos menos seguros, bem como os padrões de localização e de fatalidade e a probabilidade de ocorrência. As informações geradas por esses modelos são utilizadas pelas autoridades de transporte para mitigar as causas dos acidentes (García De Soto et al., 2018), e priorizar as soluções a serem implementadas (Sameen & Pradhan, 2017; Santos et al., 2021). Um exemplo é o modelo baseado em *deep learning* que foi desenvolvido por um grupo de pesquisadores do MIT e do Qatar Centre for AI, que prevê acidentes de trânsito com elevado nível de precisão, tendo obtido bons resultados nas cidades onde foi aplicado<sup>70</sup>. Este modelo pode ser utilizado para planejar a construção de

70 O aprendizado profundo ajuda a prever acidentes de trânsito antes que eles aconteçam (2021, outubro). Recuperado de: <<https://www.csail.mit.edu/news/deep-learning-helps-predict-traffic-crashes-they-happen>>

novas infraestruturas rodoviárias, pois tem a capacidade de prever acidentes em locais que não há registos históricos<sup>71</sup>

Na mesma linha, há aplicações de IA para veículos que visam contribuir para reduzir o número e o nível de complexidade dos acidentes de trânsito. O BID apoiou o governo de San Salvador na implementação de um projeto piloto de um sistema de prevenção automática de colisões e acidentes -*Collision Avoidance System* (CAS)- no serviço de transporte público. Este sistema consiste em uma série de alarmes, câmeras e sensores que alertam os condutores do serviço no caso de se aproximarem iminentemente de pedestres, veículos ou outros componentes estranhos<sup>72</sup>. Também detecta sinais de trânsito e excesso de velocidade, monitora o sistema de iluminação, define distâncias de segurança entre veículos e alerta para saídas de faixa e potenciais colisões frontais e laterais com pedestres e bicicletas<sup>73</sup>. Após oito (8) semanas de implementação, a percentagem de condutores

71 Ibidem.

72 Projectos-piloto de inovação nos transportes públicos sem custos para os países? Sim, é possível (2018, setembro). Recuperado de: <<https://blogs.iadb.org/transporte/es/innovacion-en-el-transporte-publico-sin-costo-ninguno-para-los-paises-si-es-posible/>>

73 Ibidem.

que reduziram os alertas gerados ultrapassou os 40%. Estes tipos de sistemas contribuem para reduzir os acidentes entre veículos em até 30%.<sup>74</sup>

Outro aspeto fundamental da gestão inteligente do tráfego é a resposta a acidentes de viação. Atualmente, estão sendo desenvolvidas ferramentas que aumentam os níveis de automatização das respostas para fazer face a este tipo de emergência. Uma delas consiste na análise em tempo real de vídeos de câmeras de segurança utilizando redes neuronais convolucionais (CNN) para detectar objetos em tempo real. Uma vez identificado o acidente e a sua posição geográfica, é enviado um alerta para as unidades de emergência mais próximas, o que reduz consideravelmente os tempos de resposta e aumenta a eficácia da intervenção (Desai et al., 2021).

No setor portuário e logístico, os modelos de IA têm sido utilizados, entre outros aspectos, para gerenciar os fluxos de tráfego de veículos de carga que transitam pelos terminais (Valenciaport, 2020). Desta forma, as imagens aéreas dos portos identificam situações críticas em termos de

<sup>74</sup> Ibidem.

congestionamento, permitindo à administração gerenciar a velocidade de aproximação dos navios e, assim, mitigar o congestionamento e reduzir as emissões de CO2 geradas pelos navios<sup>75</sup>. Um exemplo disso foi a implementação no porto de Barcelona de um sistema que permite a rastreabilidade e a gestão do fluxo de contêineres no porto<sup>76</sup>. Os contêineres têm um código que não é fácil de identificar pelo pessoal em terra firme, uma vez que os contêineres podem estar em diferentes posições e alguns dos códigos não são legíveis<sup>77</sup>. Por esse motivo, os administradores portuários utilizaram algoritmos de análise de vídeo para obter os códigos dos contêineres, a fim de controlar automaticamente o fluxo.<sup>78</sup>

Por fim, existe uma preocupação generalizada com os níveis de poluição e o papel do setor de transporte no aumento da

<sup>75</sup> Quantil. Obtido em: [https://www.linkedin.com/posts/quantil-math\\_inteligencia-artificial-en-puertos-activity-7188503860242513920-lyPm?utm\\_source=share&utm\\_medium=member\\_desktop](https://www.linkedin.com/posts/quantil-math_inteligencia-artificial-en-puertos-activity-7188503860242513920-lyPm?utm_source=share&utm_medium=member_desktop) & ORCA AI. Obtido em <<https://www.orca-ai.io/>>

<sup>76</sup> Estudo de caso: Porto de Barcelona. Recuperado de: <<https://www.allread.ai/es/casos-de-exito/puerto-barcelona-usan-inteligencia-artificial-identificar-contenedores-vagones/>>

<sup>77</sup> Ibidem.

<sup>78</sup> Ibidem.

emissão de partículas de gases que afetam a população. De acordo com o BID, a nível mundial, 25% das emissões anuais de gases de efeito estufa são produzidas pelo setor de transporte, o que o torna como o segundo maior contribuinte para as emissões de gases de efeito estufa, atrás da indústria de geração de eletricidade e aquecimento (Calatayud et al., 2023). Neste sentido, um importante avanço para melhorar a compreensão desses níveis de poluição é o monitoramento da trajetória dos gases de efeito estufa. Para isso, o Laboratório de Física Aplicada (APL) da Universidade Johns Hopkins desenvolveu um modelo de aprendizagem profunda que, através de imagens de satélite e informações públicas sobre as estradas e ruas estima, com precisão, as emissões poluentes produzidas pelo setor de transporte nas 500 cidades com as maiores taxas de emissões a nível mundial.<sup>79</sup>

Em relação ao setor de água e saneamento, a gestão eficiente dos recursos hídricos desempenha um papel fundamental na luta contra a escassez de água e na sustentabilidade de setores como a agricultura, a saúde pública e a conservação do meio ambiente. Um componente

<sup>79</sup> Ibidem.

importante dos sistemas de gestão da água são as estações de tratamento e distribuição, que asseguram um abastecimento contínuo à comunidade. Neste sentido, a rede de distribuição requer um monitoramento contínuo do fluxo de água para evitar vazamentos que geram perdas de recursos. Da mesma forma, as estações de tratamento requerem processos avançados de detecção de contaminantes e separação de resíduos (Nova, 2023).

Uma solução relevante para uma gestão eficiente dos recursos hídricos é a utilização de medidores inteligentes. Por um lado, estes medidores facilitam a inspeção das redes através da detecção de consumos anormais e, por outro, facilitam a gestão dos consumos por parte das famílias e das empresas. Embora os medidores inteligentes não sejam, por si só, uma aplicação de IA, são um facilitador para este tipo de modelo, uma vez que geram e capturam as informações necessárias para executar análises de classificação e previsão. Um exemplo é a Empresa de Acueducto y Alcantarillado de Bogotá (EAAB), que lançou o projeto Smart Water Metering, que visa permitir que os grandes consumidores controlem o seu consumo e, assim, obtenham estatísticas e estabeleçam alarmes para monitorar os seus processos de produção e até identificar vazamentos

internos em menor tempo<sup>80</sup> Sistemas de telemedição semelhantes estão sendo instalados em diferentes cidades da ALC<sup>81</sup>, em grande parte porque criam valor ao fortalecer a digitalização dos sistemas de distribuição e tratamento de água, além de otimizar o consumo dos usuários.<sup>82</sup>

Por outro lado, em relação ao setor energético, um dos maiores problemas enfrentados pelas empresas do setor de águas são as perdas nas redes de distribuição, conhecidas como Água Não-Recebida (ANR), devido ao consumo não autorizado (pirataria ou fraude) - conhecido como perdas não técnicas às perdas físicas de recursos (Vanijjirattikhan et al., 2022) -perdas técnicas-.

80 Bogotá lança a medição inteligente de água (SWM). (2022, outubro). Obtido de: <<https://www.acueducto.com.co/wps/portal/EAB2/Home/general/sala-de-prensa/boletines/detalle/bogota+la+estrena+la+medicion+inteligente+del+agua+%28mia%29>>.

81 Análise de tamanho e participação do mercado de medidores inteligentes da América do Sul e Central: tendências de crescimento e previsões (2024-2029). Recuperado de: <<https://www.mordorintelligence.com/es/industry-reports/south-and-central-america-smart-meters-market-industry>>

82 A província de Neuquén instalou 300 contadores de água inteligentes Sigfox Recuperado de: <<https://www.grupodatco.com/neuquen-despliega-medidores-de-agua-inteligentes-con-tecnologia-sigfox/>>

Uma aplicação proeminente da IA neste setor é o desenvolvimento e a implementação de modelos para detectar perdas não técnicas de água em sistemas de aquedutos. Um caso de referência na região é o *Aquadata*<sup>83</sup>, uma solução desenvolvida pelo BID e implementada em 2023 pela Empresa Pública Metropolitana de Agua Potable y Saneamiento (EPMAPS) em Quito, Equador (**Figura 9**).

83 BID para a ALC. Acudata. <<https://fairlac.iadb.org/piloto/acudata>>. Entrevistas com funcionários da EPMAPS e do BID.

**Figura 9.** Descrição do caso Aquadata

**Aquadata** é uma solução desenvolvida pelo BID e implementada pela Empresa Pública Metropolitana de Agua Potable y Saneamiento de Quito (EPMAPS) em 2023. Esta solução detecta perdas de água não técnicas através de modelos de inteligência artificial e dados históricos.

### Descrição da solução

A Aquadata utiliza modelos de aprendizagem automática de IA, especificamente modelos de classificação supervisionados e o modelo de aceleração de gradiente baseados em dados de 2010-2022 de um milhão de clientes para identificar a sua probabilidade de fraude. Durante os testes, a EPMAPS verificou os bons resultados da ferramenta através da realização de auditorias de campo.

### Resultados e impacto

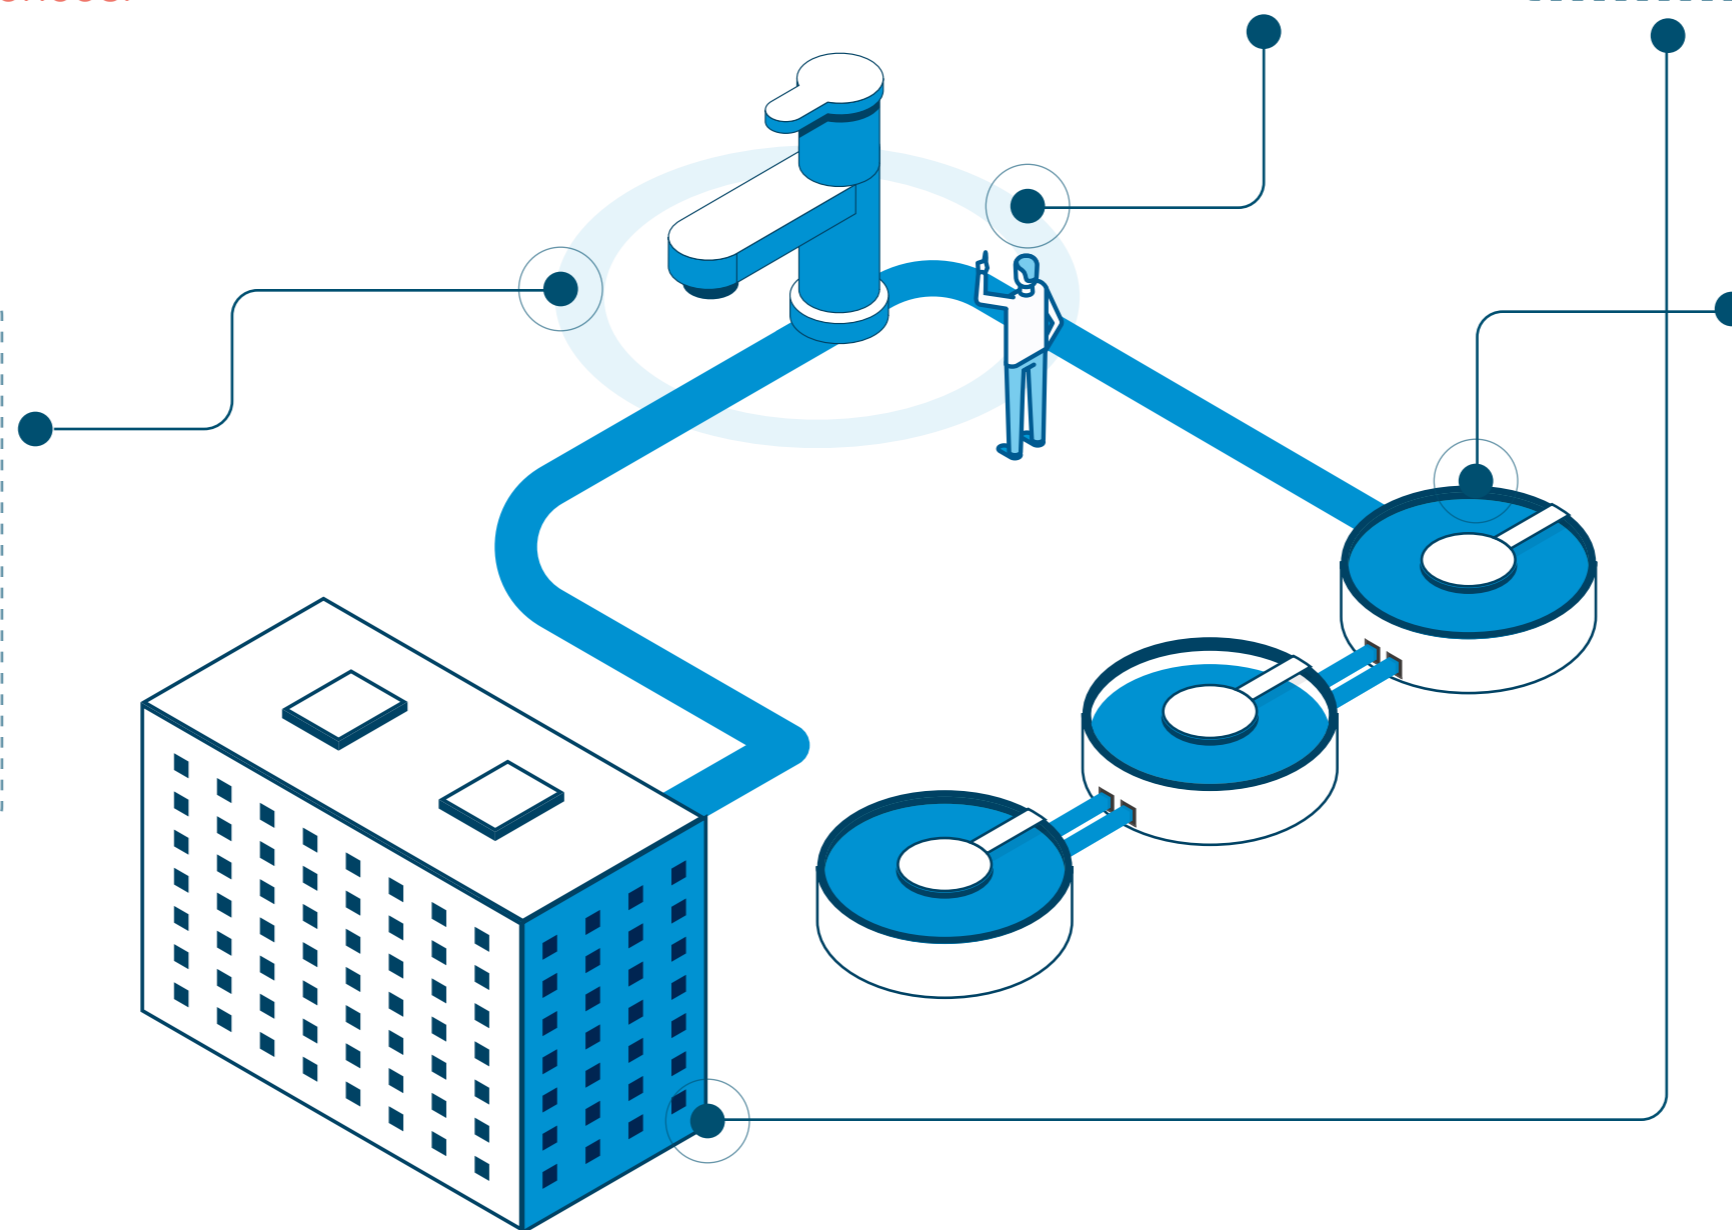
O Aquadata permitiu à EPMAPS detectar um maior número de anomalias no consumo de água com um nível de confiança superior a 90%. Isto permitiu uma maior eficácia dos inspetores de campo, cujos níveis de assertividade (aplicação de multas) aumentaram de 13% para 34% das inspeções, bem como a identificação de falhas em mais de 18% dos hidrômetros.

### Problemas a serem resolvidos

O objetivo do Aquadata é contribuir para a redução das perdas de água não técnicas e comerciais nos sistemas de abastecimento de água, que podem representar até 40% do recurso, e aumentar a eficácia na identificação de anomalias no consumo de água, com menos requisitos de monitoramento e inspeção.

### Conclusões

De acordo com as entrevistas com membros das equipes da EPMAPS e do BID, este projeto reforçou o desempenho financeiro da EPMAPS e contribuiu para a preservação dos recursos hídricos da cidade. Alguns dos fatores de sucesso deste projeto são a formação e a transferência de conhecimentos, bem como o trabalho de equipes multidisciplinares. Alguns dos desafios enfrentados incluem o ceticismo inicial, as dificuldades associadas à captura e formatação de dados e o armazenamento de dados em conformidade com os regulamentos locais.



Por outro lado, um dos principais problemas enfrentados pelas estações de tratamento é o elevado nível de contaminação da água que, geralmente, é causado pela existência de bactérias, parasitas, medicamentos, fertilizantes, inseticidas e pesticidas, entre outros, que geralmente são difíceis de classificar na fase inicial de tratamento, em parte porque não alteram permanentemente a cor da água e não são fáceis de reconhecer pelo olho humano (Maroju et al., 2023). Em resposta a este problema, vários estudos de caso concentram-se na aplicação de algoritmos de aprendizagem profunda e automática para identificar elementos de contaminação na água. Por exemplo, pesquisadores da Universidade de Chicago utilizaram a IA para criar sondas químicas capazes de detectar e remover substâncias nocivas na água.<sup>84</sup>

Há também empresas que implementam sistemas de automação para estações de tratamento de água, a fim de melhorar a sua gestão. Com base em um modelo digital da estação de tratamento, o desempenho da estação é monitorado para otimizar o seu funcionamento e fornecer

informações sobre as necessidades de manutenção.<sup>85</sup> Estes sistemas também adaptam os processos de tratamento das águas residuais às novas tecnologias, por exemplo, utilizando algoritmos de classificação para detectar corpos estranhos nas fontes de água e remover resíduos através de tratamento biológico.<sup>86</sup>

De igual modo, Granata et al. (2017) desenvolveram um modelo de previsão do nível de poluição do fluxo de águas residuais, através de algumas características e comportamentos da drenagem, com base em dados de 65 comunidades dos Estados Unidos, entre os anos de 1992 e 2002. Os pesquisadores verificaram que o modelo de aprendizagem automática<sup>87</sup> utilizado prevê corretamente o nível de poluição das águas residuais e é generalizável, ou seja, pode ser utilizado noutras estações de tratamento. É também eficaz para utilização em sistemas de gestão de estações com informação de sensores em tempo real (Granata et al., 2017). Do mesmo modo, o governo de Singapura utilizou uma ferramenta de monitoramento para

a estação de tratamento de Ulu Pandan que lhe permite realizar uma modelação preditiva de indicadores de águas residuais e da qualidade da água.<sup>88</sup> O software utiliza técnicas de aprendizagem automática para modelar o fluxo e a carga de águas residuais, bem como os níveis de oxigênio e de determinados produtos químicos nos corpos d'água da estação<sup>89</sup>. Uma vantagem desta ferramenta é o fato de ser alimentada pelos dados operacionais da estação, assim o modelo continua aprendendo e aumentando constantemente a sua precisão.<sup>90</sup>

Por último, a IA contribui para melhorar a gestão dos resíduos sólidos. Um caso de utilização é o reconhecimento de imagens que detecta aterros potenciais ou existentes e facilita a classificação dos resíduos. Por exemplo, a fundação argentina Bunge y Born desenvolveu um sistema que utiliza a IA e imagens de satélite para identificar lixeiras ilegais a céu aberto, a fim de evitar a sua expansão e o seu impacto negativo no ambiente e na saúde pública (Fundación Bunge y Born, n.d. e 2021).

84 Inteligência artificial aplicada ao tratamento de águas residuais municipais (2021, maio). Recuperado de: <<https://www.bluegold.es/es/inteligencia-artificial-aplicada-al-tratamiento-de-aguas-residuales-municipales/>>

85 Gerir o tratamento sustentável da água com Intelliflux. Recuperado de <<https://ifctrl.com/industries/water/>>

86 Ibidem.

87 Neste caso, os autores utilizaram árvores de decisão e regressão de vectores de apoio, tendo este último método obtido os melhores resultados.

88 IWA (2020). Digital Water, soluções de Inteligência Artificial para o setor da água: Controlo preditivo de estações de tratamento de águas residuais. Recuperado de: <[https://iwa-network.org/wp-content/uploads/2020/08/IWA\\_2020\\_Artificial\\_Intelligence\\_SCREEN.pdf](https://iwa-network.org/wp-content/uploads/2020/08/IWA_2020_Artificial_Intelligence_SCREEN.pdf)>

89 Ibidem.

90 Ibidem.

## Relações com os clientes

A utilização da IA no setor da energia contribui para melhorar a relação das empresas com os seus clientes, permitindo o fornecimento de informações relevantes e facilitando a comunicação. A adoção da IA pode gerar economias para os clientes devido ao acesso à informação sobre os custos da energia, os horários ideais para utilizar a energia, bem como a quantidade de energia que geram através de fontes renováveis (Engelhardt, McClelland & Collet, n.d.). Além disso, as ferramentas de IA, como os bots, dão suporte ao processamento de mensagens de correio eletrónico e de chats em plataformas digitais. Eles podem solicitar informações ausentes dos usuários, informá-los em caso de interrupções ou anomalias do serviço, ajudá-los a otimizar o seu consumo com base nas suas necessidades e consumos anteriores e dar-lhes respostas em prazo mais curto. Isso melhora a experiência e a satisfação dos usuários e, por sua vez, aumenta a fidelidade dos clientes às empresas.<sup>91</sup>

<sup>91</sup> Visor AI (2021); Microsoft - Streebo Inc (2024); Infosys BPM (2024); Wipro (2019); Talbott (2024); Sergiienko (2024).

Um caso de utilização da IA que gera valor ao otimizar o funcionamento dos sistemas de transporte e contribui para reduzir o congestionamento é o das aplicações orientadas para o usuário. Os modelos de tráfego preditivos que utilizam técnicas de IA<sup>92</sup> permitem o desenvolvimento de aplicações que visam fornecer aos cidadãos melhores informações para a tomada de decisões em matéria de transportes. É o caso do projeto TIMON, liderado por um grupo de pesquisadores da Universidade de Deusto, na Espanha, que otimiza os percursos dos usuários em função das suas necessidades, com base, por exemplo, nas previsões de trânsito.<sup>93</sup>

Há também aplicativos de IA orientados aos usuários que fornecem informações relevantes para o uso eficiente dos sistemas de transportes públicos. Os usuários do metrô e ônibus da cidade de Nova Iorque, através da aplicação da

<sup>92</sup> Apesar dos bons resultados que estão a ser obtidos em termos de precisão de previsão com modelos de aprendizagem automática em comparação com modelos estatísticos de séries temporais, é importante referir que ainda são necessários progressos em termos de redução da complexidade estrutural dos modelos, o que, por sua vez, aumenta a complexidade computacional e, por conseguinte, exige mais recursos.

<sup>93</sup> TIMON, Inteligência artificial que prevê o congestionamento do trânsito (2019, janeiro). Recuperado de: <[Metropolitan Transportation Authority \(MTA\),<sup>94</sup> têm acesso, em tempo real, a informações relacionadas com a ocupação dos veículos, os horários, o status do serviço, a existência de anomalias nos percursos e o tempo médio de espera, entre outras \(Calatayud et al., 2022\). Esta informação é fornecida graças à utilização de modelos de IA que processam os dados gerados por sensores localizados nas infraestruturas de transporte \(ônibus, trens e estações\) \(Calatayud et al., 2022\). Alguns estudos empíricos mostraram que a existência de tais aplicações aumenta a satisfação dos usuários, tendo um impacto positivo nos indicadores de confiabilidade e robustez do sistema \(Chan et al., 2020\).](https://www.spri.eus/es/teics-comunicacion/timon-inteligencia-artificial-que-predice-las-congestiones-de-trafico/#:~:text=El%20objetivo%20de%20TIMON%20es,inteligencia%20artificial%20y%20big%20data.></a></p>
</div>
<div data-bbox=)

Outro exemplo deste tipo de ferramenta é a que foi desenvolvida pelo BID para o aeroporto de Santa Cruz de la Sierra, Viru Viru, na Bolívia. Esta aplicação tem como objetivo proporcionar às pessoas com deficiência visual uma maior independência para transitar no aeroporto.<sup>95</sup> Esta aplicação capta imagens da localização do usuário e compara a imagem captada em tempo real com a coleção de imagens

<sup>94</sup> Para mais informações: <<https://new.mta.info/>>

<sup>95</sup> O aeroporto de Viru Viru na Bolívia está comprometido com a acessibilidade universal e a inclusão (2023, outubro). Recuperado de: <<https://blogs.iadb.org/transporte/es/el-aeropuerto-de-viru-viru-en-bolivia-apuesta-por-la-accesibilidad-universal-y-la-inclusion/>>

em nuvem, do aeroporto e, através de comandos de voz, guia o usuário pela estação.<sup>96</sup> Para que o usuário possa pesquisar as estações, estas são agrupadas de acordo com a sua categoria, por exemplo, companhias aéreas, banheiros, caixas eletrônicos, restaurantes, entre outros.<sup>97</sup> Este tipo de aplicação permite, por um lado, incluir esta comunidade na utilização de uma infraestrutura crítica como a de um aeroporto<sup>98</sup> e, por outro lado, otimizar os recursos operacionais do aeroporto, fornecendo ajuda personalizada e facilitando o contato com os responsáveis em caso de necessidade de assistência.

Por outro lado, um fator relevante no planejamento e gestão da capacidade dos sistemas de transporte é a perspectiva de gênero na concepção dos diferentes sistemas de transporte

96 Ibidem.

97 Ibidem.

98 De acordo com o *mobiliblog* do BID, a contribuição do turismo na Bolívia é equivalente a 4,6% do PIB e a mais de 320.000 empregos diretos e indirectos. Um dos locais-chave para o turismo no país é o aeroporto de Santa Cruz de la Sierra, Viru Viru. Este é considerado o aeroporto mais importante, uma vez que um grande número de mercadorias e passageiros saem do país.

público e na avaliação do impacto da sua implementação. A este respeito, alguns trabalhos empíricos utilizaram modelos de aprendizagem automática, como as redes bayesianas (BN), para analisar dados de demanda por transporte público, a fim de identificar as características que devem ser melhoradas para consolidar sistemas de transportes públicos sensíveis ao gênero. Um estudo em particular analisou dados do transporte ferroviário e do sistema de bicicletas públicas, entre outros serviços, e concluiu que, para ter um sistema ferroviário mais justo e que aumente a procura por parte das mulheres, é necessário melhorar a disposição dos assentos para reduzir a interação social, aumentar o espaço pessoal, integrar serviços de mobilidade compartilhada para ligações de última milha, construir pontos de apoio para as usuárias em caso de agressão ou necessidade, anunciar meios de contato para ajuda, bem como promover campanhas para reduzir incidentes (Molero et al., 2021). Este estudo constatou ainda que, no caso do sistema de *bike sharing*, é necessário concentrar esforços na redução de percursos com um certo nível de inclinação, na inclusão de bicicletas elétricas, na disponibilização de elementos de proteção contra a chuva e na inclusão de cadeirinhas para crianças, entre outros (Molero et al., 2021).

Da mesma forma, para avançar na melhoria da segurança nas estações, especialmente para as mulheres, estão sendo desenvolvidos modelos de *aprendizagem automática* em diferentes locais para analisar em tempo real os vídeos das câmeras de segurança instaladas e comunicar possíveis comportamentos anômalos. Um exemplo disso é o software que está sendo desenvolvido pela Universidade de Wollongong, na Austrália, para detectar comportamentos como brigas e assédio nas estações de transportes públicos que possam indicar episódios de insegurança. Se identificados, o modelo emite alertas para que as autoridades possam intervir em tempo hábil.<sup>99</sup>

A adoção da IA no setor de água e saneamento gera valor, tal como no setor de energia, ao melhorar as relações das empresas com os seus clientes. Através da IA, os serviços públicos compreendem o consumo dos clientes, o que lhes permite personalizar os serviços a baixo custo, detectar


99 Universidade de Wollongong, Austrália. Investigação em IA para ajudar a segurança das mulheres nos transportes públicos. Recuperado de: <<https://www.uow.edu.au/media/2020/ai-research-to-aid-womens-safety-on-public-transport.php>>

anomalias na demanda e informar os clientes sobre interrupções e falhas no serviço. Isso gera economia de água e melhora a experiência do usuário.<sup>100</sup> Uma empresa de abastecimento de água e de águas residuais que utilizou a IA para este fim foi a Dubai Electricity and Water Authority. Esta organização desenvolveu o *Rammas*, um chatbot que resolve consultas de vários agentes, como clientes, fornecedores, potenciais trabalhadores e empreiteiros, através da aplicação da organização e de outras plataformas digitais (Deloitte, 2023). Uma das vantagens desta ferramenta é que funciona sempre em dois idiomas, o que facilita a interação com o cliente.

Da mesma forma, o BID, através da aliança “Source of Innovation”,<sup>101</sup> implementou projetos-piloto que aplicam *tecnologias inteligentes de resíduos* para melhorar a gestão dos resíduos sólidos domésticos. Um desses projetos está sendo implementado com o *Consórcio*

*Intermunicipal do Médio Vale do Itajaí (CIMVI)*, no Brasil. O projeto visa melhorar a comunicação com os usuários finais e melhorar a coleta e análise de dados para gerar indicadores de gestão e apoiar a tomada de decisões. A central de triagem de resíduos do CIMVI no Brasil integrou a tecnologia *Greyparrot*, que utiliza visão computacional e IA para analisar os resíduos recicláveis. Este sistema automatiza a auditoria e a análise de 100% dos resíduos processados, identificando 89 das classes de resíduos em 13 categorias, incluindo mais de 35 tipos de plásticos rígidos e flexíveis.

**A tecnologia fornece dados em tempo real sobre a composição dos resíduos, sendo esta informação apresentada em um dashboard com informação relevante sobre os tipos e quantidades de resíduos. Este esforço de digitalização permite à CIMVI acessar a dados confiáveis e oportunos, o que melhora a tomada de decisões e a comunicação com as partes interessadas e, em última análise, melhora os seus serviços de gerenciamento de resíduos.**



100 Nestor, (2023); Talbott, (2024); Wipro, (2019); Tempest, (2023)

101 Source of Innovation é uma aliança do Grupo do BID com parceiros externos que promove o desenvolvimento e a adoção de soluções inovadoras no setor da água e do saneamento básico na ALC, com o objetivo de obter serviços inteligentes, inclusivos e sustentáveis. Fonte: Site< <https://www.iadb.org/es/quienes-somos/topicos/agua-y-saneamiento/iniciativas/fuente-de-innovacion>>



## CONSIDERAÇÕES SOBRE A ADOÇÃO DA IA NOS SETORES DE INFRAESTRUTURAS

### 4.1

#### Metodologia para o desenvolvimento ágil de soluções baseadas em IA

Como referido no capítulo 3, as soluções baseadas na IA têm potencial para gerar valor e afetar significativamente o desempenho de setores de infraestruturas como a energia, os transportes, a água, o saneamento e os resíduos sólidos. Em particular, representam uma ferramenta para reforçar o planeamento e a concepção, a construção, a gestão de ativos e a manutenção, para otimizar a eficiência operacional e para melhorar a participação dos usuários.



A incorporação da IA pode tornar-se um fator de transformação, implicando a alteração de processos, sistemas, relações entre áreas e, em alguns casos, a adoção de novos modelos de funcionamento e de negócio. Por isso, é relevante que as organizações de infraestruturas implementem metodologias de desenvolvimento e inovação em IA que sejam robustas, alinhadas com os seus objetivos e em linha com as melhores práticas. O desenvolvimento e a implementação bem-sucedidos de tais soluções envolvem a adoção de considerações técnicas, jurídicas, éticas, matemáticas, de gestão, culturais, tecnológicas e de gestão de projetos. Isso exige uma compreensão holística do problema e da solução, o que requer a implementação de metodologias flexíveis que incorporem efetivamente estas considerações. Além disso, a utilização de modelos de IA implica normalmente a incorporação de estratégias de gestão da mudança. Neste sentido, a adoção de soluções de IA exigem uma governança responsável, incluindo a comunicação, a transparência, a inclusão, a equidade, a segurança da informação e dos sistemas, a confiabilidade dos resultados e a responsabilização.

A experiência do BID na promoção e desenvolvimento de soluções baseadas em IA em setores de infraestruturas

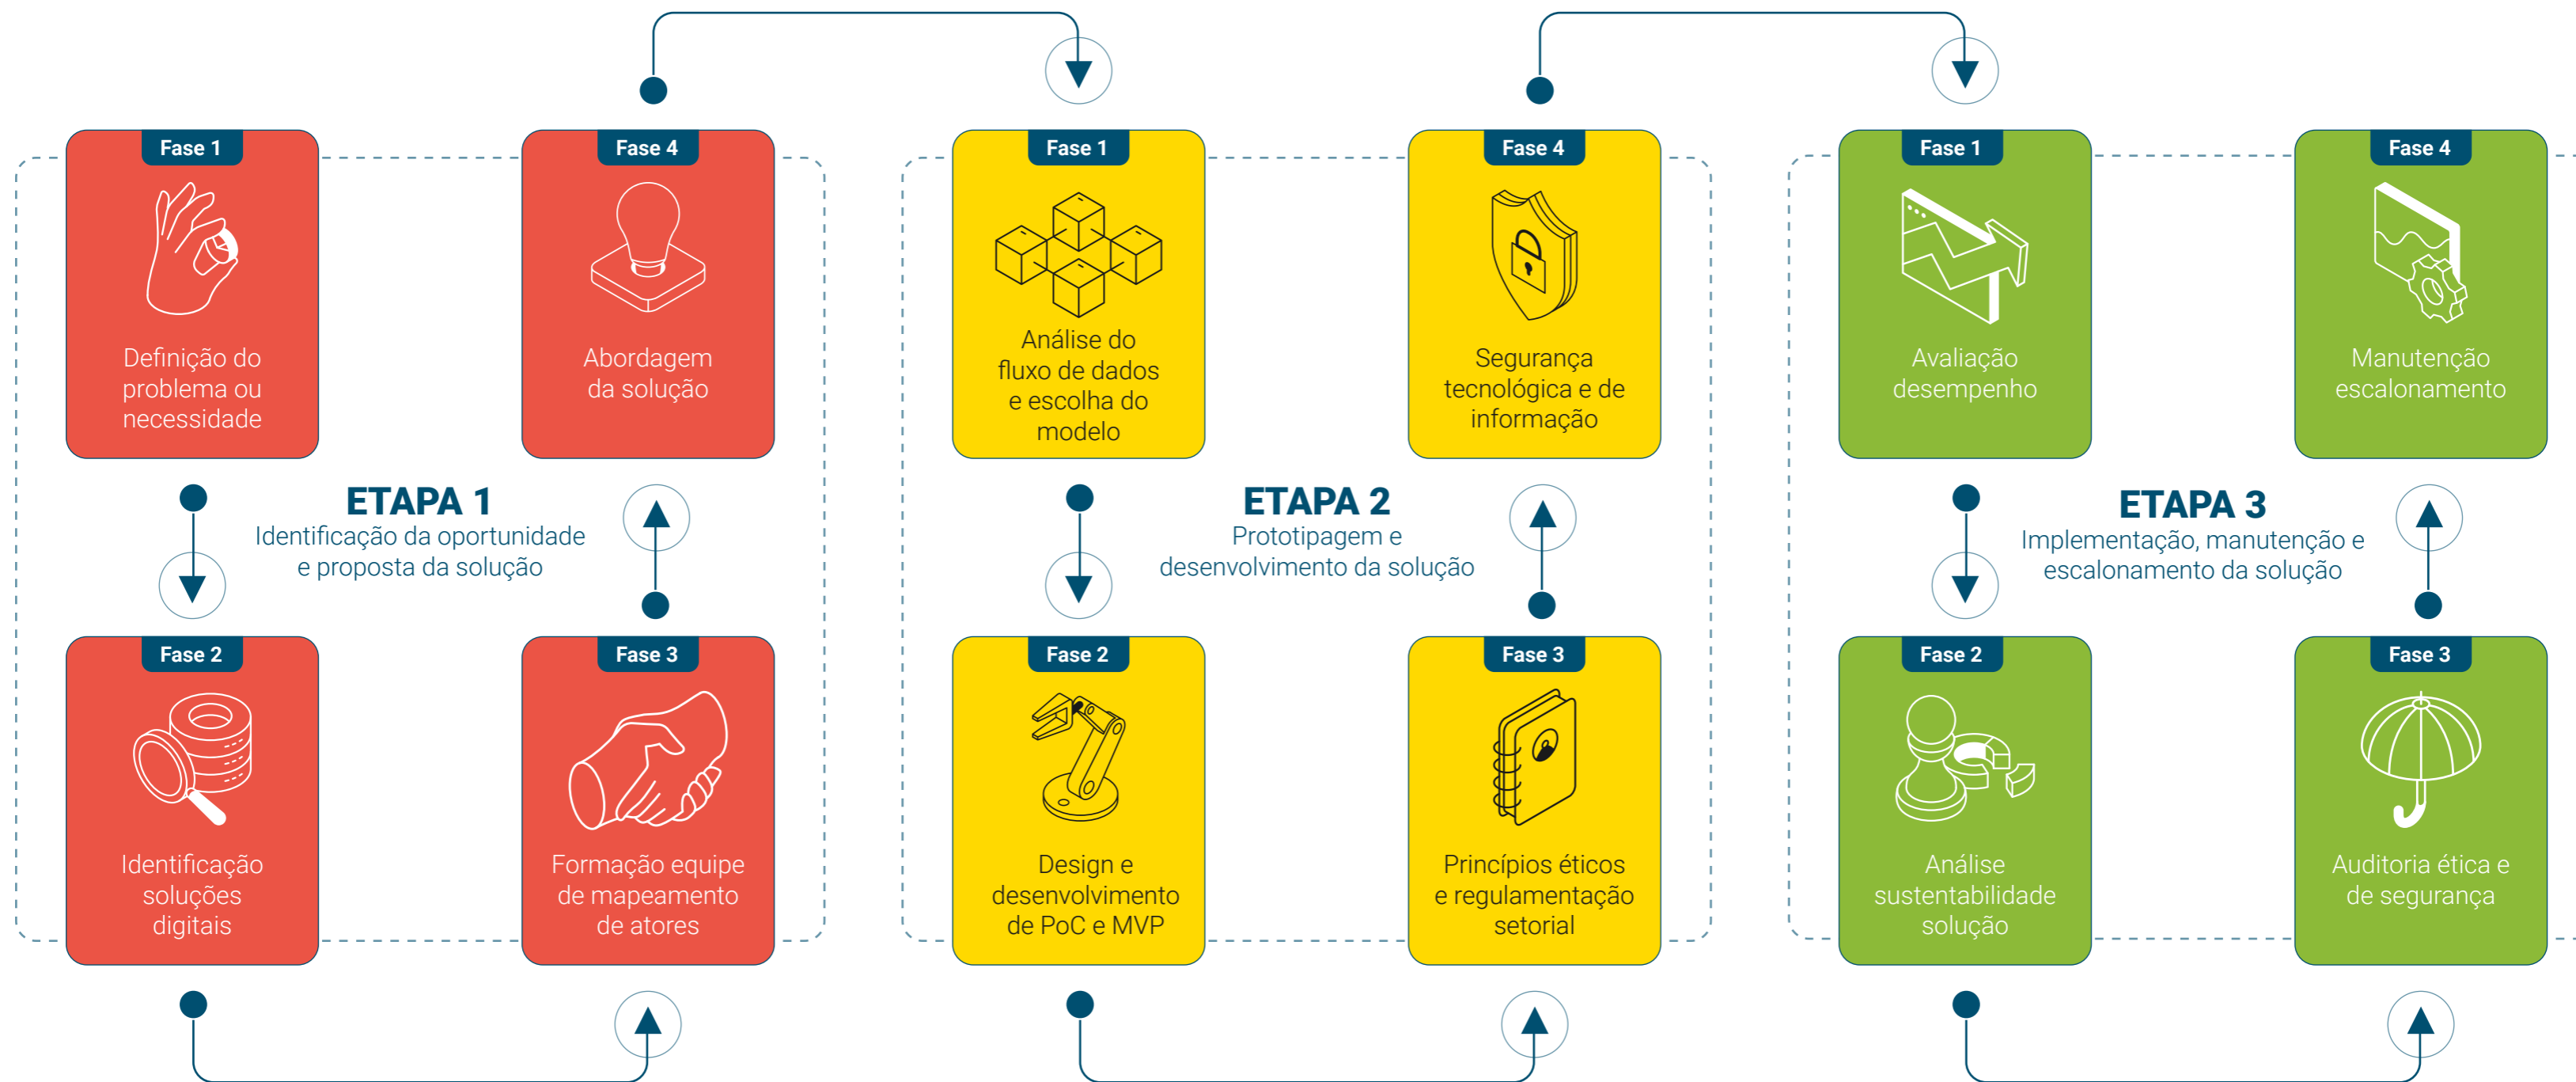
permitiu concluir que a abordagem de desenvolvimento e inovação ágeis,<sup>102</sup> comumente utilizada em processos de empreendedorismo e inovação tecnológica, é também relevante para o desenvolvimento e adoção deste tipo de soluções nesses setores. Como o próprio nome indica, essa abordagem privilegia a flexibilidade dos processos, a adaptabilidade, a experimentação e o feedback contínuo do usuário ou cliente. Além disso, ele considera iterações contínuas ao longo de toda a cadeia de produção do sistema, permitindo modificações oportunas na estrutura do modelo. Para o efeito, isso inclui normalmente o desenvolvimento de protótipos e pilotos que permitem a experimentação de versões funcionais do produto. Essa característica confere flexibilidade ao processo, uma vez que uma solução diferente pode ser reformulada em qualquer fase do desenvolvimento, como resultado da experimentação de usuários reais (Minatta et al., 2022).

<sup>102</sup> O termo ágil refere-se a um conjunto de estruturas e princípios que codificam um método de desenvolvimento de software. Este conceito descreve projetos que dão prioridade à simplicidade, à colaboração e interação entre a equipe e o cliente, com resultados frequentes, e à criação de equipes auto-organizadas e adaptáveis que refletem e dão prioridade à satisfação do cliente. Essa metodologia caracteriza-se por ser iterativa e difere da tradicional em vários aspectos. O termo ágil é atualmente utilizado para designar várias práticas de desenvolvimento e inovação, sendo mesmo utilizado em outras áreas do conhecimento que não o desenvolvimento de software. Fontes: (i) Agile Alliance, What is Agile? Disponível em: <https://www.agilealliance.org/agile101/>. (ii) Dyba T., Dingsoyr. (2009). O que sabemos sobre desenvolvimento ágil de software? IEEE Software.

A abordagem ágil permite que as organizações que geram infraestruturas críticas possam iterar nos seus modelos e sistemas, incorporar continuamente feedback e novas ideias e fazer ajustes em tempo real. Isto é crucial para garantir a continuidade operacional, melhorar a segurança e assegurar que as infraestruturas podem se adaptar rapidamente a novas exigências ou a riscos emergentes. Além disso, ao utilizar protótipos e projetos-piloto no processo de desenvolvimento, as organizações identificam e atenuam potenciais falhas antes de estas afetarem o sistema global.

Tendo em vista o que precede, a abordagem de desenvolvimento e inovação ágeis consiste geralmente em três (3) fases principais, que são: i) Identificação da oportunidade e abordagem da solução; ii) Prototipagem e desenvolvimento da solução; e iii) Implementação, manutenção e escalonamento da solução (**Figura 10**).

**Figura 10.** Esboço da abordagem de desenvolvimento ágil e inovação



Como se observa na **Figura 10**, o esquema é iterativo de fase para fase e, em cada fase, é mantido um ciclo constante de melhorias. Pretende-se, com isso, representar a flexibilidade e a adaptabilidade do modelo, uma vez que podem ser introduzidas alterações em qualquer parte do ciclo sem afetar significativamente o seu desenvolvimento.

A seguir, apresentamos um conjunto de considerações fundamentais que o BID recomenda que sejam levadas em consideração pelos formuladores e implementadores de soluções de IA nos setores de infraestrutura durante todo o processo de desenvolvimento e implementação dessas soluções. Essas considerações foram identificadas a partir da análise de casos e práticas internacionais, bem como da experiência e das lições aprendidas pelo BID no apoio aos países da região na adoção dessas tecnologias. Essas considerações são fundamentais para garantir que a integração da IA seja feita de forma eficaz, alinhada com os objetivos estratégicos, e que os benefícios para as infraestruturas críticas sejam maximizados.

## Etapa 1. Identificar a oportunidade e propor a solução

A primeira fase do esquema de Desenvolvimento Ágil e Inovação é a **Identificar a Oportunidade e Propor a Solução** e tem como objetivo definir e restringir o problema, bem como estabelecer os elementos de decisão para implementar uma solução de IA. Geralmente, inclui quatro (4) fases principais.

### Etapa 1, Fase 1

#### Definição do problema ou da necessidade:

A organização formula um problema específico que precisa ser resolvido ou identifica uma necessidade, como o reforço da tomada de decisões ou a inovação em produtos, serviços ou processos.

Uma boa definição de problema tem, geralmente, as seguintes características: deve ser clara, concisa e referir-se a uma situação suscetível de ser resolvida. Para isso, é essencial identificar: quais são as suas causas e consequências? Por que é que é importante resolvê-lo? O que acontece na ausência de intervenção? Quais os grupos de pessoas interessadas são afetados? Quais são os indicadores que sustentam a existência do problema?

Por que o problema ainda não foi resolvido?<sup>103</sup> Para definir o problema, é essencial coletar o maior número possível de informações e provas, para que a formulação se baseie em fatos e dados concretos e não em suposições.

### Etapa 1, Fase 2

#### Identificação de possíveis soluções digitais:

Refere-se à definição das alternativas de solução que seriam mais adequadas para resolver o problema identificado e à determinação da relevância da utilização da IA na solução. Trata-se de um filtro para evitar o risco de desenvolver projetos de IA baseados na própria tecnologia e não no problema a ser resolvido (Pombo et al., 2020).

Para analisar a conveniência e a necessidade de implementar uma solução baseada na IA, é importante compreender primeiro o problema antes de pensar na forma de como resolvê-lo. Em muitas ocasiões, os grupos de trabalho começam com a relação causal oposta. Ou

<sup>103</sup> Departamento de Infraestruturas (INE). *Guia de desenvolvimento de produtos digitais*. [Slides de PowerPoint]. Banco Interamericano de Desenvolvimento (BID).

seja, escolhem a solução de IA que querem implementar e depois decidem onde aplicá-la. Na experiência do BID, especificamente em setores de infraestruturas, os projetos bem-sucedidos são aqueles que começaram pela identificação de um problema, reduziram-no para não perderem o foco e depois decidiram quais as ferramentas necessárias para o resolver.<sup>104</sup> Assim, nesta fase, é útil colocar as seguintes questões: por que razão é necessária uma solução digital para resolver o problema, quais são os aspectos diferenciais de um produto digital em relação a uma solução não digital e quais são as vantagens de um produto digital em relação a uma solução não digital?

#### Análise dos métodos de soluções existentes

É prioridade compreender os possíveis métodos de solução e a sua viabilidade, bem como encontrar os fundamentos teóricos e empíricos das primeiras abordagens a uma possível solução. Neste sentido, é aconselhável realizar um

estudo de mercado dos métodos de soluções existentes e das soluções atuais. Isto implica uma análise das tendências tecnológicas e dos casos de utilização disponíveis. Além disso, no âmbito da análise de possíveis métodos de solução, são normalmente considerados a complexidade do desenvolvimento (viabilidade técnica), os custos associados a cada opção e os tipos de competências e capacidades necessárias para a implementação.

Pode acontecer que métodos de solução baseados na IA semelhantes aos que estão sendo contemplados neste caso tenham sido adotados no mesmo ou em outros setores. Neste caso, esses métodos, bem como os ensinamentos do seu desenvolvimento e aplicação, podem ser úteis para a concepção da nova solução. Neste contexto, as bases de código partilhadas permitem ganhar tempo e incorporar as melhores práticas de projetos anteriores. Um exemplo são as aplicações desenvolvidas pelo BID em setores de infraestruturas,<sup>105</sup> que têm repositórios públicos para que possam ser utilizadas por formuladores e implementadores de soluções, tais como *BA Obras*, *Caminos de la Villa*, *VíaSegura*, *Ciclo de Movilidad*, *Distancia2*, *Energizados*, *Pavimenta2* e *Congestiómetro*, só para mencionar alguns.

O aproveitamento de soluções previamente desenvolvidas por empresas em fase inicial ou parceiros tecnológicos pode ser uma estratégia útil e eficiente para resolver problemas semelhantes. A ligação da experiência dessas empresas através de processos de inovação aberta, alianças ou intercâmbios de conhecimentos, permite explorar novas ideias e possíveis soluções.<sup>106</sup> Para maximizar o impacto dessas colaborações, é crucial definir critérios de decisão objetivos para selecionar as soluções existentes com maior potencial e alinhamento com os objetivos da organização.

Além disso, essa estratégia abre oportunidades para desenvolver soluções locais adaptadas às necessidades específicas da região e que cumpram as normas internacionais. Isso não apenas promove a transparência, a equidade e a responsabilidade na implementação da IA, mas também fortalece os ecossistemas regionais. Iniciativas como o fAIr LAC+, impulsionadas pelo Grupo BID, desenvolvem estruturas, ferramentas e melhores práticas. O fAIr LAC+ oferece aconselhamento, treinamento e ferramentas para apoiar países e empreendedores na

<sup>104</sup> Ibidem.

<sup>105</sup> Para mais informações: <<https://code.iadb.org/es/herramientas>>

<sup>106</sup> Departamento de Infraestruturas (INE). *Guia de desenvolvimento de produtos digitais*. [Slides de PowerPoint]. Banco Interamericano de Desenvolvimento (BID).

adoção da IA de forma ética e eficaz. Ferramentas como o fAIr LAC 3S e o fAIr Venture ajudam a construir um portfólio de soluções regionais e ecossistemas fortes.

### Etapa 1, Fase 3

#### Criação de equipes e levantamento das partes interessadas:

Nesta primeira fase, é aconselhável definir uma gestão de projeto e uma equipe interdisciplinar com capacidade para incorporar conhecimentos técnicos, tecnológicos, jurídicos e empresariais no processo para o desenvolvimento e implementação bem-sucedidos da solução. É também aconselhável identificar partes interessadas e potenciais aliados estratégicos.

A identificação dos atores é relevante à medida em que contribui para o dimensionamento e delimitação do problema e possível solução. Permite também entender rapidamente as suas motivações e interesses, bem como a influência que poderão ter no produto a ser projetado e implementado. Em particular, é importante identificar os atores que se beneficiarão da solução de IA, bem como aqueles que terão que alterar o seu funcionamento ou comportamento quando a solução for adotada.<sup>107</sup> É

igualmente importante identificar potenciais aliados estratégicos e patrocinadores do projeto, a fim de avaliar a viabilidade das respectivas alianças ou possíveis apoios para contribuir para o êxito da sua implementação.

Por exemplo, em projetos de transportes, como a implementação de um sistema de gerenciamento de tráfego baseado em IA, a equipe interdisciplinar tem que incluir peritos em planejamento urbano, tecnologia de transportes e regulamentação da mobilidade, bem como operadores e usuários finais, para garantir que a solução é devidamente integrada na infraestrutura existente e responde às necessidades específicas do ambiente urbano.

Por outro lado, em um projeto de energia, como a otimização da rede elétrica através da IA, é essencial envolver especialistas em sistemas de energia, cibersegurança, reguladores do setor de energia e peritos em sustentabilidade. A interação com as diferentes partes interessadas é fundamental, uma vez que os projetos energéticos enfrentam frequentemente desafios únicos relacionados com a estabilidade da rede, a conformidade regulamentar e a aceitação pública das novas tecnologias.

### Etapa 1, Fase 4

#### Abordagem da solução:

É igualmente importante analisar as possíveis alternativas e considerar os critérios para escolher a solução mais adequada. Os elementos de avaliação incluem a análise das soluções existentes, a revisão dos dados disponíveis e dos possíveis modelos a serem desenvolvidos, a análise dos requisitos das ferramentas tecnológicas, a identificação das competências e capacidades e a formulação de considerações éticas, de segurança da informação e de regulamentação setorial.

**A análise de alternativas e a avaliação de critérios são essenciais nos setores de infraestruturas devido à complexidade e ao impacto a longo prazo dos projetos. Neste contexto, a seleção da solução mais adequada implica a consideração de múltiplos fatores, como a eficiência operacional, a sustentabilidade e a resiliência.**

A avaliação das ferramentas tecnológicas é crucial para garantir a adaptabilidade da infraestrutura a futuras inovações. As considerações éticas e de segurança,

<sup>107</sup> Ibidem.

juntamente com o cumprimento da regulamentação setorial, são indispensáveis para minimizar os riscos e garantir o êxito dos projetos a longo prazo.

### Tipo de dados e possíveis modelos a serem desenvolvidos

Nesta fase, é fundamental identificar e analisar as características dos dados a serem utilizados, tais como a sua origem e disposição, ou seja, se são estruturados,<sup>108</sup> semiestruturados<sup>109</sup> ou não estruturados,<sup>110</sup> se são dados abertos, pessoais ou privados. Considerar também o volume de dados,<sup>111</sup> a representatividade, a qualidade,<sup>112</sup> a variabilidade das suas categorias, a relação entre variáveis, a dimensionalidade,

108 Esse tipo de dados tem aspectos definidos como atributos, comprimento, tamanho e são armazenados em bases de dados relacionais, em formato de folha de cálculo ou de tabela (Vélez et al., 2022).

109 Trata-se de dados etiquetados que não têm uma estrutura formal, como os apresentados numa base de dados (Vélez et al., 2022).

110 Dados que não possuem uma estrutura formal e cujo armazenamento é possível em documentos de texto ou pdf, vídeos, imagens, chats de redes sociais e e-mails, entre outros (Vélez et al., 2022).

111 A quantidade de dados necessários varia em função do tipo de modelo a implementar, da complexidade do problema e do número de parâmetros necessários (Vélez et al., 2022).

112 Se estiverem incompletos, desorganizados, sem metadados e com sérios indícios de erros (Vélez et al., 2022).

o equilíbrio nas categorias,<sup>113</sup> a fonte e a periodicidade de atualização e a forma como são extraídos ou coletados. É também importante avaliar o nível de sensibilidade da informação disponível. Por exemplo, assim como referido na fase de considerações éticas, privacidade da informação e segurança informática, é importante determinar se os dados de entrada são de natureza privada ou se têm implicações éticas, pois nestes casos pode ser necessário, nas fases de desenvolvimento, aplicar transformações para proteger a privacidade ou mitigar possíveis vieses ou riscos éticos (Lei Geral de Proteção de Dados Pessoais – LGPD). Desta forma, nesta etapa, é realizada a categorização do tipo de informação para avaliar os riscos e assim determinar o tratamento adequado dos dados em termos de segurança e volume de informação.

A identificação e análise das características dos dados a serem utilizados é uma etapa preliminar fundamental para a implementação da fase de prototipagem e desenvolvimento de soluções, que é descrita na Seção 4.1.2. Assim como referido na descrição desta fase, um elemento central para a escolha do modelo a ser desenvolvido é a análise e implementação

113 Especialmente nos problemas de classificação, é importante que as diferentes classes ou categorias de uma variável sejam equilibradas para que não sejam reproduzidos enviesamentos no treino (Vélez et al., 2022).

do fluxo de dados do projeto, que consiste em uma série de passos articulados através dos quais os dados são extraídos, processados e transformados da sua forma bruta para um estado ideal de treinamento e avaliação de um modelo.

### Identificar e compreender a solução

Com base na análise dos métodos de soluções existentes e na identificação dos dados a serem utilizados e dos possíveis modelos a serem desenvolvidos, é identificado o tipo de solução mais adequado, bem como os seus diferentes componentes. Para definir a solução ideal de acordo com o problema ou necessidade determinada, os diferentes métodos de solução identificados são avaliados com base em critérios como a eficácia na resolução do problema, a viabilidade técnica e financeira, a eficiência operacional, as implicações de aquisição, a necessidade de parcerias ou de desenvolvimento *interno*, o horizonte temporal necessário e os impactos na sustentabilidade e resiliência, entre outros.

Além disso, uma vez que a solução tenha sido identificada, é importante desenvolver um entendimento profundo da solução em termos de sua relação com a estratégia de negócios, sua relação com as operações da organização, quaisquer regulamentações relevantes que devem ser levadas em

consideração, suas vantagens sobre outros tipos de soluções, aspectos contextuais relevantes (políticos, sociais, infraestrutura) e seus objetivos e resultados esperados, entre outros aspectos.

### Ferramentas tecnológicas

Nesta fase, vale também a pena considerar os requisitos que serão necessários em termos de ferramentas tecnológicas para o desenvolvimento e implementação da solução identificada.

A infraestrutura de dados para o desenvolvimento de soluções de IA divide-se em duas funcionalidades: armazenamento e processamento. Estes dois conceitos interagem na (i) infraestrutura de dados, (ii) no ambiente de desenvolvimento de modelos de IA, e (iii) na infraestrutura tecnológica de suporte.

A infraestrutura de dados está relacionada com a forma como a informação está organizada, ou seja, se está estruturada em tabelas relacionais<sup>114</sup> ou em tabelas não

114 As bases de dados relacionais são bases de dados que armazenam informação em tabelas, conhecidas como relações, em que cada tabela é uma coleção de dados organizados em linhas (registros) e colunas (atributos). O que é uma base de dados relacional (sistema de gestão de bases de dados relacionais)? Obtido em: <<https://www.oracle.com/co/database/what-is-a-relational-database/>>

relacionais.<sup>115</sup> Da mesma forma, essa infraestrutura é também composta pelo modelo de engenharia de dados adotado, seja ETL (Extract, Transform and Load)<sup>116</sup> ou ELT (Extract, Load and Transform)<sup>117</sup> e pela infraestrutura de armazenamento de dados, que pode consistir em um data warehouse,<sup>118</sup> em um data lake,<sup>119</sup> ou em uma combinação dos dois, data lakehouse.<sup>120</sup>

115 Esse sistema de base de dados não segue um esquema rígido, em vez de linhas e colunas, utiliza diferentes modelos de armazenamento e recuperação de dados, o que lhe permite melhorar em termos de escalabilidade relativamente às bases de dados relacionais. O que é o NoSQL? Recuperado de: <<https://aws.amazon.com/es/nosql/>>

116 Consiste na combinação de dados de diferentes fontes e na aplicação de regras comerciais, validação e estatísticas para os limpar e ordenar, a fim de os armazenar num repositório centralizado. AWS - O que é Extract, Transform and Load (ETL)? Obtido em: <<https://aws.amazon.com/es/what-is/etl/>>

117 De acordo com a AWS, "a abordagem ELT carrega os dados tal como estão e transforma-os numa fase posterior, dependendo do caso de utilização e dos requisitos analíticos". Recuperado de: <<https://aws.amazon.com/es/compare/the-difference-between-etl-and-elt/>>

118 De acordo com o AWS, um armazém de dados "é um repositório central de informações que podem ser analisadas para tomar decisões mais bem informadas". Recuperado de: <<https://aws.amazon.com/es/what-is/data-warehouse/>>

119 Refere-se a um repositório centralizado dedicado ao armazenamento de informações estruturadas, semiestruturadas e não estruturadas em qualquer magnitude, sem a necessidade de as transformar previamente num esquema predefinido. O que é um Data Lake? Recuperado de: <<https://aws.amazon.com/what-is/data-lake/>>

120 É um casamento entre o armazém de dados e o lago de dados, no sentido em que combina a capacidade de armazenamento de informação bruta com a gestão de dados estruturados e os benefícios de controlo do modelo de armazém de dados. Fonte: Google. O que é um data lakehouse? Recuperado de: <[Em relação ao ambiente de desenvolvimento de modelos de IA, geralmente é necessário tomar decisões sobre a capacidade de processamento e a velocidade com que os modelos serão treinados. Para isso, em projetos de infraestruturas onde são utilizadas imagens, é geralmente contemplada a existência de Unidades de Processamento Gráfico \(GPU\)<sup>121</sup> de forma a suportar as sessões de treino do\(s\) modelo\(s\) de IA em desenvolvimento. O desenvolvimento das GPUs permitiu avanços significativos nos modelos de aprendizagem automática, principalmente na velocidade de processamento em comparação com as CPUs tradicionais, na eficiência energética, uma vez que oferece melhor desempenho por watt em comparação com as CPUs e na possibilidade de implementar processamento paralelo, uma vez que a sua arquitetura foi concebida para realizar várias tarefas simultaneamente.<sup>122</sup>](https://cloud.google.com/discover/what-is-a-data-lakehouse#:~:text=data%20management%20features-,What%20is%20a%20lakehouse%3F,organized%20sets%20of%20structured%20data.)></a>></p>
</div>
<div data-bbox=)

121 GPU (Graphics Processing Unit) é um processador especializado em gráficos e renderização de imagens. No entanto, devido ao seu elevado poder de processamento, tem sido utilizado para efetuar cálculos matemáticos intensivos e processamento paralelo, facilitando o trabalho computacional de formação de modelos complexos de aprendizagem automática. O que é uma GPU? Recuperado de: <[122 NVIDIA. Por que as GPUs são ótimas para IA \(2023, dezembro\). Recuperado de <<https://blogs.nvidia.com/blog/why-gpus-are-great-for-ai/>> & O que é uma GPU? Recuperado de: <](https://www.intel.com/content/www/us/en/products/docs/processors/what-is-a-gpu.html#:~:text=What%20does%20GPU%20stand%20for,video%20editing%2C%20and%20gaming%20applications.></a>></p>
</div>
<div data-bbox=)

Adicionalmente, é fundamental considerar a infraestrutura tecnológica de suporte, que consiste num local físico ou virtual onde será efetuado o armazenamento e processamento dos dados. É essencial definir se este espaço será construído na nuvem, seja ela privada, pública ou híbrida, ou se será alojado em uma infraestrutura local (servidores). Esta escolha terá impacto no tempo de desenvolvimento, nos custos, na segurança e nas competências necessárias da equipe.

Nesse sentido, existem duas principais opções: a utilização de serviços de computação em nuvem ou a utilização de uma solução baseada em uma infraestrutura local, também conhecida como solução “on-premise”. A computação em nuvem corresponde à distribuição de recursos de TI escaláveis e virtualizados sob demanda pela Internet, cujo pagamento é baseado conforme a utilização. Esses serviços, geralmente suportados por servidores distribuídos por todo o mundo, baseiam-se no compartilhamento de recursos físicos subjacentes, que permitem o fornecimento de capacidade de armazenamento, poder de processamento, gerenciamento e acesso à informação, execução de aplicações ou entrega de conteúdo ou serviços, de forma rápida e flexível.<sup>123</sup>

123 O que é a nuvem? Obtido em: <https://azure.microsoft.com/es-es/resources/cloud->

Assim como existem diferentes formas de desenvolver a computação em nuvem, também existem diferentes modelos de negócio para contratar o seu serviço. As opções mais comuns são: Infraestrutura como Serviço (IaaS); Plataforma como Serviço (PaaS); e Software como Serviço (SaaS).<sup>124</sup> O modelo IaaS consiste no serviço de infraestrutura, ou seja, a exploração de máquinas virtuais, armazenamento, processamento e capacidade de rede, para que os clientes as possam configurar de acordo com as suas necessidades. O modelo PaaS centra-se na disponibilização do acesso ao ambiente necessário ao desenvolvimento, gestão e lançamento de aplicações com base na utilização da respectiva infraestrutura de suporte. Por fim, o modelo SaaS consiste no serviço de utilização de soluções finais de acordo com as necessidades dos clientes, sem que estes tenham que gerenciar o *back office* e a manutenção, nem a infraestrutura tecnológica que o suporta (Banco Mundial, 2022; García & Iglesias, 2022).

computing-dictionary/what-is-the-cloud & O que é computação em nuvem? Obtido em: <https://aws.amazon.com/es/what-is-cloud-computing/>

124 IBM. O que são IaaS, PaaS e SaaS? Recuperado de: <https://www.ibm.com/topics/iaas-paas-saas#:~:text=IaaS%2C%20PaaS%20and%20SaaS%20are,types%20of%20cloud%20service%20offerings.>>

Para projetos relacionados com o fornecimento de energia, transporte, água, saneamento e resíduos sólidos, existem algumas vantagens em desenvolver soluções de IA na nuvem:<sup>125</sup>

- **Acessibilidade:** Armazenamento e acesso à informação a partir de qualquer terminal e localização geográfica.
- **Escalabilidade e flexibilidade.** A nuvem suporta com relativa facilidade o aumento do tráfego e dos usuários, bem como a redução, o que faz dela uma infraestrutura que se adapta à dimensão da aplicação.
- **Agilidade no desenvolvimento de produtos.** Isto permite efetuar experiências sobre o tráfego - aumentando e diminuindo a utilização da aplicação - e sobre as funcionalidades da solução.
- **Redução de custos.** O gerenciamento e o planejamento adequados dos recursos de armazenamento, processamento e execução de aplicativos na nuvem permitem uma redução significativa de custos em comparação com uma solução baseada em

125 Ibid.

servidores locais. Isso ocorre porque você só paga pelo que realmente usa, evitando custos associados à infraestrutura ociosa. Outro aspecto a considerar é a sustentabilidade ambiental da solução a ser implementada. De acordo com os cálculos da Microsoft Cloud, a computação em nuvem pode ser mais eficiente do ponto de vista energético - entre 22 e 93% - em comparação com as soluções locais<sup>126</sup> Assim, no início de 2024, o Google Cloud comunicou que 100% da sua demanda anual de eletricidade é atendida por fontes renováveis, enquanto o Microsoft Azure comunicou ser neutro em termos de carbono desde 2012.<sup>127</sup>

- **Capacidade de armazenamento de dados:** A nuvem oferece uma capacidade de armazenamento praticamente ilimitada, adaptável às necessidades da aplicação. Ao contrário da infraestrutura local, em que o espaço pode ser limitado e a sua expansão dispendiosa, a nuvem permite que o armazenamento

seja dimensionado facilmente e sob demanda, facilitando o gerenciamento de grandes volumes de dados sem se preocupar com a infraestrutura subjacente. Isto é especialmente relevante para a eficácia e a precisão das soluções de IA, uma vez que, nestes casos, o desenvolvimento e a formação de modelos tornam necessário o tratamento de grandes volumes de dados.

O modelo *on-premise* refere-se ao fato de a infraestrutura e os recursos onde as aplicações são implementadas serem propriedade da organização e estarem localizados nas suas instalações.<sup>128</sup> Isso permite o controle total do hardware, ou seja, a organização é responsável pelo servidor, montagem, armazenamento, refrigeração do equipamento, UPS,<sup>129</sup> gestão de acessos e backup de dados, entre outros.<sup>130</sup> Essa alternativa é geralmente utilizada para o tratamento de dados sensíveis

que têm proteção especial, uma vez que em alguns casos o regulamento proíbe o armazenamento desses dados fora do país.<sup>131</sup> No entanto, é importante levar em consideração que, apesar de haver um controle direto da infraestrutura, o modelo *on-premise* exige uma estrutura de operação e manutenção constante e tem uma limitação de capacidade, uma vez que o crescimento exige a compra de mais servidores, o que implica mais espaço, consumo de energia e necessidade de refrigeração.

Outra decisão tecnológica relevante é se a solução de IA será desenvolvida internamente ou contratada junto a terceiros. A este respeito, a primeira opção (desenvolvimento interno) tem um maior controle e adaptabilidade de acordo com as necessidades específicas do projeto e geralmente envolve custos mais baixos. No entanto, exige que a organização tenha os conhecimentos e competências necessários. Por outro lado, o desenvolvimento externo pode poupar à organização o trabalho de incorporar ou desenvolver conhecimentos e competências de que a organização não dispõe. No entanto, o custo de desenvolvimento externo é geralmente mais elevado e, em qualquer caso, exigirá uma equipe interna com responsabilidades relevantes, como a

126 Sustentabilidade com simulação on-prem e em nuvem (2022, outubro). Recuperado de: <<https://softwaresim.com/blog/sustainability-with-on-prem-and-cloud-simulation/>>

127 Colmeia. Quem tem a nuvem mais ecológica? A tecnologia de nuvem mais sustentável em 2024. (2024, fevereiro). Recuperado de: <<https://www.hivenet.com/post/who-has-the-greenest-cloud-the-most-sustainable-cloud-tech-in-2024>>

128 Portal TIC (local) (dezembro, 2023). Recuperado de <<https://www.ticportal.es/glosario-tic/on-premise>>

129 UPS (Uninterruptible Power Supply) ou Fonte de alimentação ininterrupta é um dispositivo que fornece energia de reserva a equipamentos eléctricos quando a fonte de alimentação principal falha. USAID. Uninterruptible Power Supplies (Fontes de alimentação ininterrupta). Recuperado de: <<https://www.usaid.gov/energy/powering-health/system-components/uninterruptible-power-supplies>>

130 Portal TIC (local) (dezembro, 2023). Recuperado de: <<https://www.ticportal.es/glosario-tic/on-premise>>

131 Ibidem.

gestão do projeto, a aquisição de informações, a concepção de uma estratégia adequada de integração de sistemas e a atualização subsequente do modelo.

Por último, ao definir as ferramentas tecnológicas para desenvolver a solução baseada na IA, há considerações adicionais relevantes sobre o nível de preparação da organização para utilizar e alavancar essas ferramentas. Essas considerações incluem: (i) o nível de maturidade do negócio e dos processos para a adoção ou utilização das tecnologias, (ii) os riscos associados à sua adoção, incluindo aspectos éticos e legais, (iii) as barreiras existentes à adoção, e (iv) as normas ou regulamentos relacionados com essas tecnologias que devem ser levadas em consideração para o desenvolvimento e implementação da solução.

### Identificação das competências e capacidades necessárias

Assim como referido na descrição da Fase 3 desta Etapa, é desejável que a organização reúna uma equipe interdisciplinar com as competências e capacidades para incorporar os conhecimentos técnicos, tecnológicos, empresariais e jurídicos no processo para o desenvolvimento e implementação bem-sucedidos da solução. Uma vez identificada a solução a ser implementada, podem ser

determinadas as competências técnicas específicas necessárias para construir e aplicar os modelos.

Embora a construção dos modelos seja por vezes subcontratada, a sua utilização e manutenção recai sobre o pessoal interno, que, se não estiver capacitado, pode subutilizar o potencial da solução ou nem sequer a utilizar, o que compromete a sustentabilidade do modelo. A experiência do BID no desenvolvimento de soluções de IA em infraestruturas destaca a importância de incluir na equipe profissionais com conhecimentos nas áreas de data science, *machine learning* e tecnologias de informação, bem como incorporar profissionais com conhecimento do negócio. Isso permitirá rever desde a fase de concepção que o modelo responde às necessidades da organização, bem como receber feedback sobre as funcionalidades e resultados do modelo no contexto setorial onde está sendo desenvolvido.

### Considerações éticas, privacidade da informação e cibersegurança

É aconselhável elaborar uma matriz de riscos associados à implementação da futura solução que incorpore riscos éticos, de reputação, regulamentares e ESG (ambientais, sociais e de governação), bem como o seu possível impacto

e plano de mitigação. Do mesmo modo, como mencionado, é relevante identificar se os dados de entrada do modelo são de natureza pessoal, a fim de aplicar algum tipo de transformação, como a anonimização, para proteger a sua privacidade.

Embora este não seja o caso na maioria dos desenvolvimentos de IA nos setores de infraestruturas, é importante analisar se os dados de treinamento do modelo incluem variáveis sensíveis como, por exemplo, a nacionalidade, o gênero ou a etnia. Se essas variáveis existirem, pode não ser adequado removê-las simplesmente do modelo, uma vez que pode haver outras variáveis correlacionadas com elas na base de dados que mantêm os vieses existentes (Mehrabi *et al.*, 2022). Nesses casos, é habitual utilizar metodologias de tratamento especial para este tipo de variáveis<sup>132</sup> de forma a mitigar os possíveis

<sup>132</sup> Estas incluem: (i) técnicas de privacidade diferencial, como a anonimização dos dados (Ponomareva *et al.*, 2023); (ii) ajustamentos da função de perda, reamostragem ou ponderação dos dados; e (iii) debiasing adversarial, que consiste em treinar um modelo de forma a que um adversário (outro modelo) não possa prever o atributo sensível a partir das representações aprendidas. Mahmoudian, Haniyeh. Usando o Debiasing Adversarial para reduzir o viés do modelo (2020, abril). Recuperado de: <<https://towardsdatascience.com/reducing-bias-from-models-built-on-the-adult-dataset-using-adversarial-debiasing-330f2ef3a3b4>>

vieses identificados. Também é importante utilizar como referência os indicadores relacionados com a equidade algorítmica, descritos na Seção 4.1.3.

Em termos de segurança, recomenda-se a avaliação de possíveis vulnerabilidades que possam surgir durante as atividades de desenvolvimento. Como se trata de uma fase inicial, em que a prototipagem ainda não começou, este exercício é útil para interiorizar as medidas de cibersegurança a serem aplicadas.

## Fase 2. Prototipagem e desenvolvimento de soluções

**A prototipagem e o desenvolvimento de soluções** dão lugar à experimentação através de testes funcionais do produto que permitem a aprendizagem e a interação com o mundo real e os usuários. Esta fase é uma componente central da abordagem de *desenvolvimento* e inovação *Agile*, à medida em que, através de tentativa e erro, a solução final é moldada e reforçada.

### Etapa 2, Fase 1

Análise do fluxo de dados e escolha do modelo:

#### Análise do fluxo de dados

Nesta fase, uma vez proposta a solução, um elemento central para a escolha do modelo a ser desenvolvido é a análise do fluxo de dados do projeto. Este fluxo consiste em uma série de etapas articuladas em que os dados são extraídos, processados e transformados da sua forma bruta para um estado ideal para o treinamento e a avaliação do modelo. O objetivo da implementação desse fluxo é preparar os dados para treinamento e colocar o modelo em produção. O processo de gerenciamento de dados envolve várias tarefas envolvidas na identificação, coleta, limpeza, treinamento e avaliação de dados, conhecidas como fluxo de dados ou pipeline. A **Figura 11** apresenta o pipeline com suas principais fases.

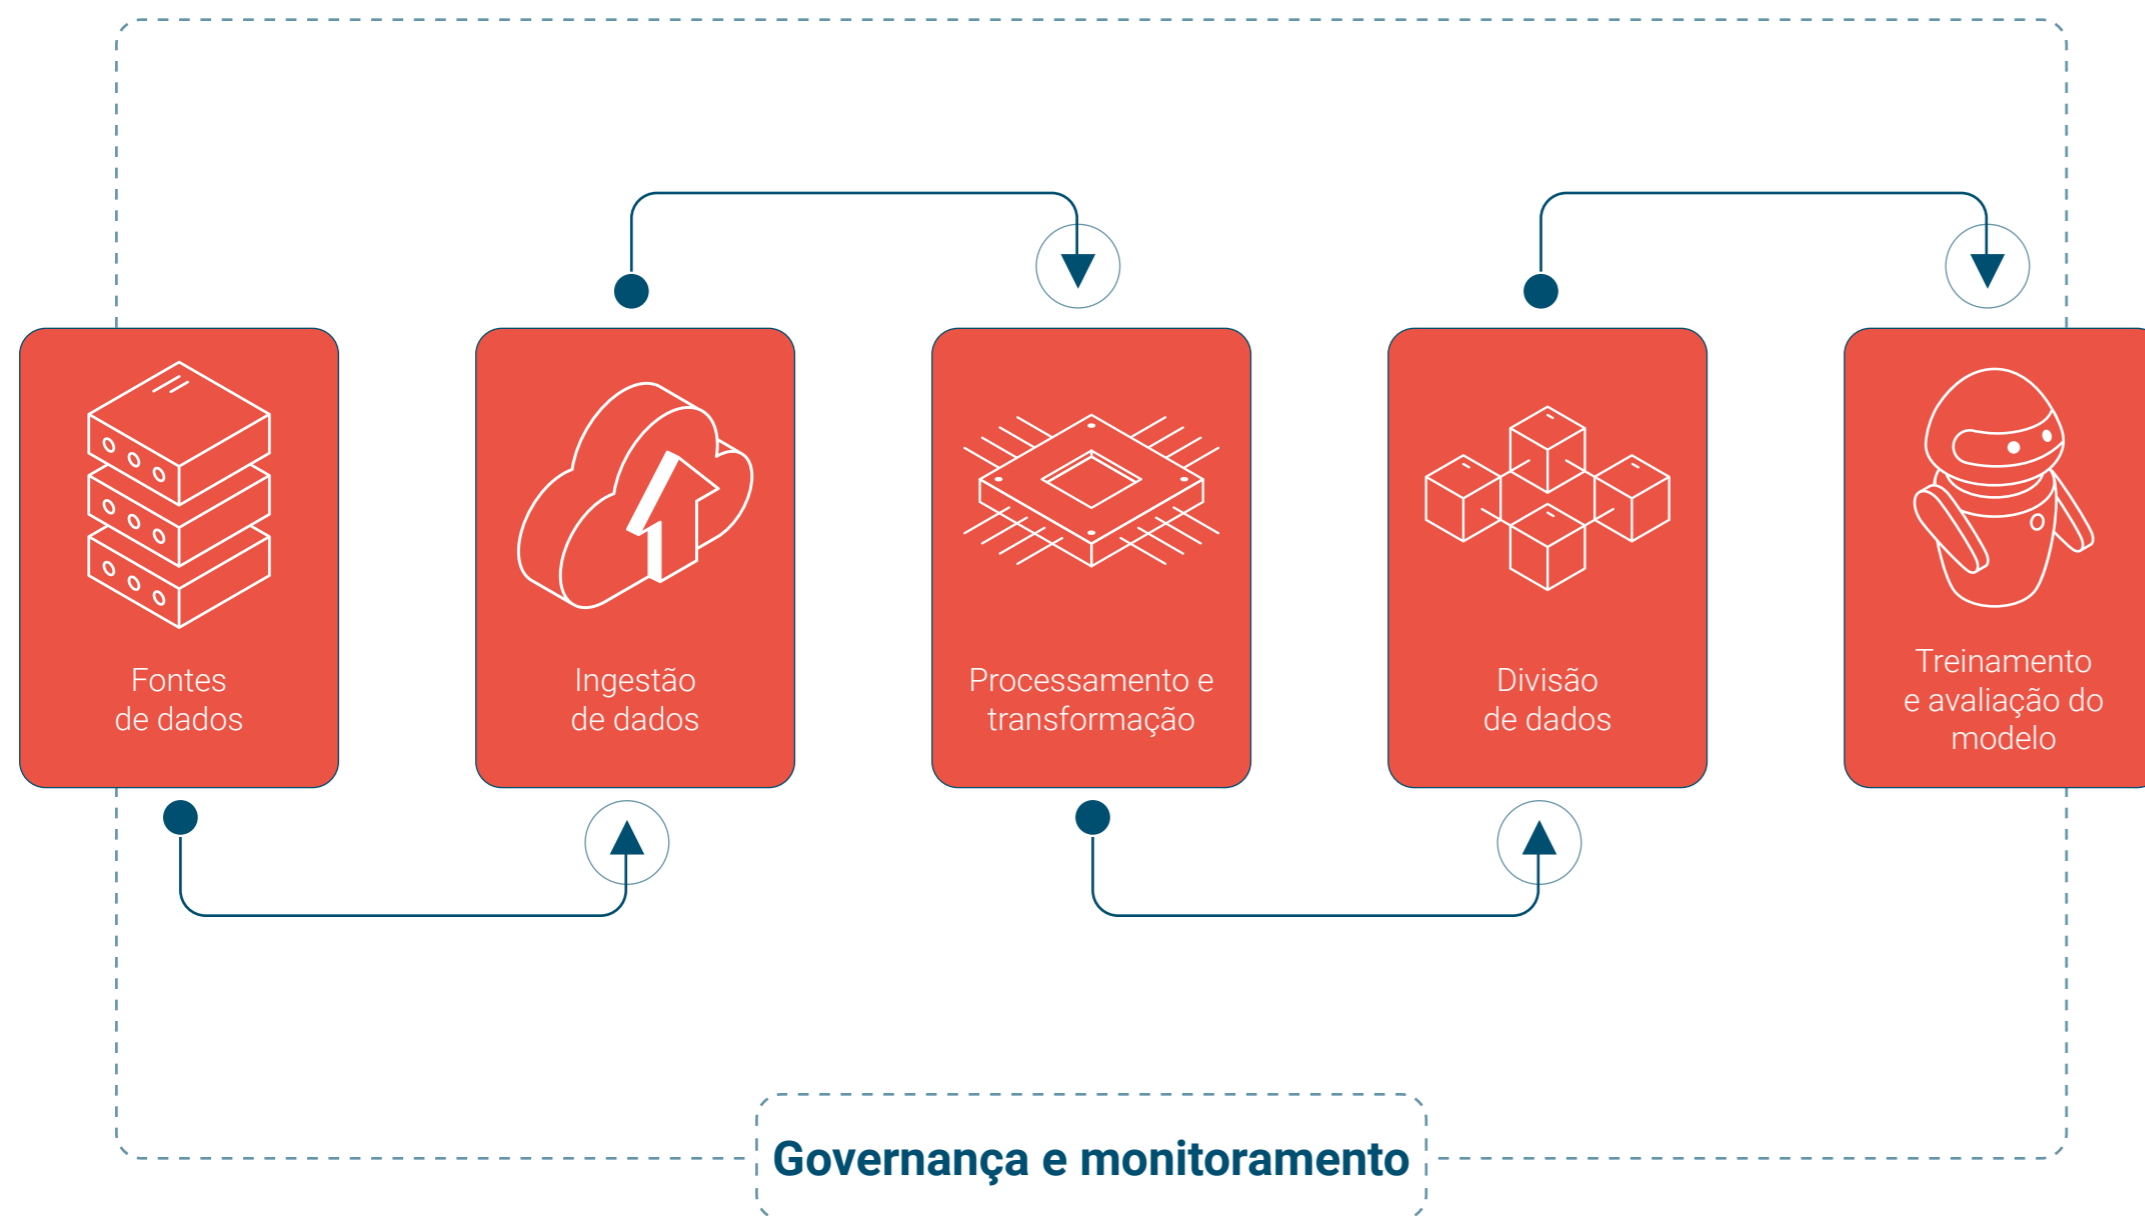
Nos projetos de energia, água, resíduos sólidos e transportes, a **coleta de dados** é crucial para alimentar os modelos de IA. São utilizadas várias tecnologias, como sensores IoT que monitoram o consumo de energia, os níveis de água e os fluxos de tráfego em tempo real, juntamente com sistemas de gerenciamento de

infraestruturas que registram dados históricos sobre padrões climáticos, comportamento dos usuários e manutenção. Além disso, são utilizados drones e satélites para captar imagens e dados geoespaciais.

O processo conhecido como **ingestão de dados** consiste em recolher dados e depois transferi-los para uma base de dados centralizada única, onde possam ser acessados, armazenados e analisados.<sup>133</sup> A coleta de dados pode ser feita através de diferentes mecanismos: (i) dados gerados através de sistemas de informação internos, (ii) dados adquiridos a partir de fontes externas, (iii) dados obtidos a partir de fontes públicas de acesso livre, e (iv) uma combinação dos anteriores. Geralmente, é também nesta fase que se decide se a entidade adotará um modelo do tipo ETL ou ELT. A infraestrutura de armazenamento e gestão de dados também é determinada, como por exemplo, se é um data warehouse, data lake ou data lakehouse.

133 Astera: O que é a ingestão de dados? Obtido em: <[https://www.cognizant.com/es/es/glossary/data-ingestion](https://www.astera.com/es/type/blog/data-ingestion/#:~:text=La%20ingesti%C3%B3n%20de%20datos%20es,lotes%20o%20en%20tiempo%20real.> & Cognizat. Ingestão de dados. Recuperado de <<a href=)>

Figura 11. Condução de dados



Fonte: Adaptação própria baseada em: *A Guide to Data Pipelines (and how to design one from scratch)*. Recuperado de <<https://www.striim.com/blog/guide-to-data-pipelines/>>

Durante **o tratamento e transformação** da informação são normalmente identificadas anomalias, duplicidade de dados, outliers ou ausência de dados, problemas de escala (padronização e normalização), e são realizadas combinações de variáveis, suavização de dados, criação de variáveis dicotômicas, e análises descritivas, univariadas, bivariadas, multivariadas, bem como a sua representação através de modelos de visualização.<sup>134</sup> São consideradas as atividades relacionadas com a limpeza de dados, incluindo a detecção e a imputação de dados ausentes, a normalização de variáveis, a unificação de nomes de colunas e o tratamento de valores atípicos.<sup>135</sup> Pode também proceder-se à anonimização<sup>136</sup> ou pseudonimização<sup>137</sup> da informação, a fim de cumprir as regras e normas de privacidade, se aplicável.

134 Zhong, S. Dominando a análise exploratória de dados (EDA): tudo o que você precisa saber (abril de 2024). Recuperado de: <<https://medium.com/data-and-beyond/mastering-exploratory-data-analysis-eda-everything-you-need-to-know-7e3b48d63a95>>

135 Patel, H. A engenharia de recursos explicada. Recuperado de: <<https://builtin.com/articles/feature-engineering#:~:text=Apr%2029%2C%202024,-Feature%20engineering%20is%20the%20process%20of%20selecting%2C%20manipulating%20and%20transforming,used%20in%20a%20predictive%20model.>>

136 A anonimização da informação é o tratamento de dados pessoais de modo a que não possam ser atribuídos a indivíduos específicos. Fonte: União Europeia. Agência Espanhola de Proteção de Dados (2020). *10 mal-entendidos relacionados com a anonimização*.

137 A pseudonimização da informação é o tratamento de dados pessoais de modo a que não possam ser atribuídos a indivíduos específicos sem a utilização de informações adicionais. Fonte: União Europeia (2016). Regulamento Geral sobre a Proteção de Dados (RGPD). Artigo 4.

Como referido no Capítulo 2, um problema constante nos modelos de classificação é o desequilíbrio entre classes. Isso ocorre quando uma classe tem muito mais dados do que outra, o que pode levar com que o modelo tenha um bom desempenho geral, mas um desempenho fraco na previsão da classe minoritária, que tem menos dados. Nesses casos, a avaliação do modelo leva apenas em consideração o desempenho na classe majoritária (Avalos et al., 2021). Algumas soluções para este problema consistem em aplicar uma subamostragem da classe dominante, ajustando os casos para cima para evitar erros de calibração, a duplicação da classe minoritária ou a modificação dos pesos de ponderação de cada classe para equilibrar a influência de cada classe, entre outras soluções (Ávalos et al., 2021).

#### Escolha do modelo

Nesta fase, é normalmente realizada o **treinamento e a avaliação dos modelos**, a fim de escolher o que melhor se adequa aos objetivos do projeto. Começa-se com um modelo básico e vai aumentando a sua complexidade até identificarmos o modelo ideal. Neste processo, são considerados

fatores como o tipo de problema, a disponibilidade de dados, os requisitos tecnológicos, as restrições de tempo e as limitações orçamentárias.

Uma boa prática consiste em começar com o modelo mais simples e aumentar gradualmente a sua complexidade. No entanto, uma maior complexidade do modelo diminui a compreensão humana dos processos de tomada de decisão, uma capacidade conhecida como **explicabilidade**.<sup>138</sup> No entanto, em várias aplicações de IA, os modelos complexos, como as redes neuronais, têm muitas vezes um desempenho significativamente melhor,<sup>139</sup> pelo que é do interesse da equipe concentrar-se nos objetivos de desempenho e no processo de avaliação das soluções descrito a seguir.

Outro elemento a se considerar na escolha de um modelo é a **natureza do problema**. Como mencionado no Capítulo 2, os problemas abordados pelos modelos de machine learning podem ser agrupados em três categorias principais,

segundo Rebala et al (2019): i) classificação, que busca identificar a categoria ou categorias a que pertence cada elemento analisado; ii) clusterização, que busca encontrar características semelhantes entre os elementos para agrupá-los; e iii) previsão, que consiste em utilizar informações históricas para prever o comportamento futuro da variável alvo. Assim, para a primeira categoria, podem ser utilizados algoritmos como as máquinas de vetores de suporte (SVM), as árvores de decisão, florestas aleatórias, as redes neuronais e as redes neuronais convolucionais (CNN). Para a segunda categoria, podem ser utilizados algoritmos como o K-means, K-medoids, DBSCAN, Hierarchical Clustering e Gaussian Mixture Models (GMM). Para problemas de previsão, são utilizados algoritmos de regressão logística, regressão polinomial, floresta aleatória, LSTM e Xgboost (Extreme Gradient Boosting), entre outros.<sup>140</sup>

O **tipo, quantidade e qualidade da informação** disponível é um fator igualmente relevante na seleção do modelo a ser desenvolvido. Neste sentido, é importante quantificar o volume de informação disponível. Isto implica conhecer a

<sup>138</sup> Hosni, Y. Breve guia para seleção de modelo de aprendizado de máquina (2021, dezembro). Recuperado de: <<https://medium.com/@yousefhosni/brief-guide-for-machine-learning-model-selection-a19a82f8bdcd>>.

<sup>139</sup> Ibidem.

<sup>140</sup> Rebala (2019), McMillan & Varga (2022), Betanzos (2020), Smola & Vishwanathan (2008), Nevala (2027), McKinsey Analytics (2018).

forma como essa informação é armazenada, o mecanismo de acesso e os processos de obtenção. Da mesma forma, é analisado se os dados são estruturados ou não estruturados e se são de natureza qualitativa ou quantitativa.<sup>141</sup>

Um critério adicional para a escolha do modelo é a capacidade computacional necessária para o treinamento. Este critério é conhecido como **tempo e capacidade computacional**. Refere-se à quantidade de recursos exigidos, bem como ao tempo que seria necessário para introduzir o modelo<sup>142</sup> Por exemplo, pode ser mais rápido e mais fácil treinar um modelo de regressão logística do que um modelo de rede neurais de cinco (5) camadas. A complexidade do modelo é diretamente proporcional aos recursos de processamento para o treinamento.

Por outro lado, **os indicadores de desempenho e as métricas de equidade** são dois elementos importantes para a escolha do melhor modelo possível. O primeiro tipo de indicadores informa quão bem o modelo está

na interpretação dos dados que o alimentam e, por conseguinte, a qualidade da resposta ao problema proposto que ele está produzindo.<sup>143</sup> O segundo tipo de métrica, por outro lado, avalia a ausência de viés nos níveis individual e de grupo.

Para a **implementação do modelo selecionado**, são definidos os dados a serem utilizados para o treinamento do modelo. Embora não exista uma regra específica para essa divisão, geralmente 80% dos dados são utilizados para treinamento e 20% para validação. Na medida do possível, o ideal é que o modelo seja testado com informações externas para verificar o seu nível de generalização.

O tipo, quantidade e qualidade da informação disponível é um fator igualmente relevante na seleção do modelo a ser desenvolvido. Neste sentido, é importante quantificar o volume de informação disponível. Isto implica conhecer a forma de como essa informação está armazenada, o mecanismo de acesso e os processos de obtenção. Também é importante analisar se os dados são estruturados ou não

estruturados e se são qualitativos ou quantitativos.<sup>144</sup> Em outras palavras, execute as fases 1, 2 e 3 do *pipeline* de dados descrito na Figura 11.

## Etapa 2, Fase 2

### Design e desenvolvimento da Prova de Conceito e do Produto Mínimo Viável

Depois que as validações iniciais são concluídas e quaisquer dúvidas sobre a funcionalidade da solução potencial são resolvidas, a fase de prototipagem normalmente começa. Eles buscam representar como o produto poderia funcionar e geralmente são testados com usuários em aspectos de funcionalidade e usabilidade para que o feedback permita iterações que melhorem a robustez do produto.<sup>145</sup> Como parte disso, a Prova de Conceito (PoC) é um exercício que valida a viabilidade técnica da ideia, de modo que fique demonstrado do ponto de vista técnico que a proposta é viável ou pelo menos tem suporte teórico ou empírico.<sup>146</sup>

141 Hosni, Y. Breve guia para seleção de modelos de aprendizado de máquina (dezembro de 2021). Recuperado de: <<https://medium.com/@yousefhosni/brief-guide-for-machine-learning-model-selection-a19a82f8bdcd>> Op.cit.

142 Hosni, Y. Breve guia para a seleção de modelos de aprendizagem automática. Op.cit.

143 Btd. 20 critérios-chave para a seleção ideal do modelo de aprendizado de máquina (novembro de 2023). Recuperado de: <<https://medium.com/@baotramduong/machine-learning-criteria-for-model-selection-bca4b9742405>>.

144 Hosni, Y. Breve guia para seleção de modelos de aprendizado de máquina (dezembro de 2021). Recuperado de: <<https://medium.com/@yousefhosni/brief-guide-for-machine-learning-model-selection-a19a82f8bdcd>> Op.cit.

145 Ibidem.

146 Departamento de Infraestruturas (INE). *Guia de desenvolvimento de produtos digitais*.

Este exercício permite saber com relativa rapidez quais os aspectos da solução que devem ser revisados ou modificados. Esses testes são conduzidos em um ambiente controlado, com o apoio de recursos técnicos ou administrativos, conforme necessário.<sup>147</sup>

Exemplos de PoC em projetos de infraestruturas críticas incluem os que podem ser implementados para o desenvolvimento de iniciativas como o monitoramento em tempo real de redes inteligentes para gerenciar o consumo de energia e detectar falhas precoces, a otimização da distribuição de água potável através de sensores na rede para identificar vazamentos, e a manutenção preditiva de infraestruturas de transporte através de drones que inspecionam e previnem o desgaste. Podem também abranger a cibersegurança nas redes de controle, utilizando plataformas de monitoramento para detectar ameaças, e o gerenciamento inteligente dos resíduos nas cidades, utilizando contentores equipados com sensores para otimizar as rotas de coleta. Esses projetos-piloto testam a viabilidade de tecnologias inovadoras antes de serem implementadas em grande escala.

[Slides do PowerPoint]. Banco Interamericano de Desenvolvimento (BID).

147 Prova de conceito (POC). Op.cit.

A este respeito, o BID realizou algumas provas de conceito em infraestruturas, como as relacionadas com a aferição de veículos, a utilização de tecnologia de ponta, a utilização de imagens de satélite para definir a capacidade de tráfego de uma estrada, a utilização de imagens de satélite para calcular a produção de energia distribuída com painéis solares. Algumas destas ideias produziram resultados satisfatórios, enquanto outras encontraram dificuldades em transformá-las em Produto Mínimo Viável (MVP).

Uma vez avaliada a viabilidade técnica com base nos PoC, procede-se à fase de prototipagem onde, por vezes, são testadas versões funcionais específicas, como a plataforma do usuário, para testar a experiência do usuário (UX) e/ou o design do serviço, com o objetivo de identificar prontamente as principais funcionalidades que os usuários e outras partes interessadas irão requerer ou preferir.<sup>148</sup> Nesse processo, um aspeto fundamental é que tanto os membros da equipe que desenvolve o modelo, como os outros membros da área de negócio envolvidos neste desenvolvimento, tenham claro o seu papel no projeto. Por exemplo, é desejável que o Product

148 Departamento de Infraestruturas (INE). *Guia de desenvolvimento de produtos digitais*. [Slides de PowerPoint]. Banco Interamericano de Desenvolvimento (BID).

Owner (PO) esteja envolvido em todas as fases do processo de implantação, uma vez que isso garantirá que o ciclo de desenvolvimento se mantém em sintonia com os requisitos reais dos usuários finais.

A próxima fase da construção da solução é o desenvolvimento do que é conhecido como MVP. Nesta fase, é desenvolvida uma versão básica, porém funcional e estável do produto – neste caso, um modelo treinado com dados reais – para testar hipóteses e avaliar os resultados em relação ao desempenho do modelo, bem como sua resposta às expectativas e necessidades dos usuários. Um ponto a ser destacado no processo de desenvolvimento de um MVP é sua utilidade na adaptação da solução às mudanças do ambiente, pois este produto valida hipóteses de forma relativamente rápida e eficiente, possibilitando assim o desenvolvimento de produtos funcionais que iteram continuamente com base no conhecimento de mercado adquirido pela exposição aos usuários. Da mesma forma, é uma boa ideia verificar se as ferramentas, imagens e conteúdo usados neste produto estão em conformidade com todas as licenças aplicáveis e verificar os custos associados que devem ser considerados.

Por último, se o MVP for desenvolvido por um prestador de serviços externo, deve ser verificada a entrega de todos os

componentes conexos, tais como wireframes, elementos da interface do usuário, sistemas de design e fluxos de trabalho detalhados. Da mesma forma, quando aplicável, acesso e controle sobre os dados, código-fonte e modelos utilizados.

### Etapa 2, Fase 3

#### Princípios éticos e regulação setorial:

Durante as etapas de prototipagem e desenvolvimento da solução, princípios de design associados à transparência, responsabilidade e consideração de aspectos éticos relevantes devem ser considerados. Isso permite que as soluções de IA sejam desenvolvidas no âmbito dos quadros de gestão de riscos existentes,<sup>149</sup> bem como promover uma maior confiança na sua utilização. Da mesma forma, os sistemas de IA interagem com o ambiente, portanto seus processos devem estar em conformidade com as regulamentações do setor.

Nesse sentido, esta etapa inclui uma análise das regulamentações setoriais aplicáveis, dos aspectos legais relevantes dos sistemas

tecnológicos a serem utilizados, das regulamentações existentes de privacidade e proteção de dados e das regulamentações específicas de IA, se houver.

Como mencionado, um dos riscos associados ao desenvolvimento de modelos de IA é que eles podem replicar preconceitos existentes na sociedade e, portanto, seus resultados podem impactar grupos populacionais específicos. Uma forma de afetação pode ocorrer por meio de vieses algorítmicos.<sup>150</sup> Esses vieses incluem vieses de processamento, de confirmação e de exclusão. Os vieses de processamento referem-se a distorções que podem ser introduzidas nos dados antes mesmo de serem utilizados para treinamento do modelo. Os vieses de confirmação são os que ocorrem quando as soluções de IA corroboram estereótipos ou crenças anteriores, e os vieses de exclusão descrevem o que acontece quando determinados grupos

populacionais são sistematicamente excluídos do conjunto de treinamento.<sup>151</sup>

Nesse contexto, a supervisão ética ocorre por meio da identificação e mitigação de vieses, bem como pela aplicação de princípios comportamentais. O *princípio* da transparência nas soluções de IA implica a capacidade de compreender como e por que um modelo de IA toma determinadas decisões. Além disso, deve ser levado em consideração o princípio da *responsabilização*, que se refere à capacidade de atribuir ações e decisões de uma solução baseada em IA a um responsável específico, que é responsabilizado pelos possíveis efeitos desses vieses e incorpora medidas de mitigação.

Outro aspecto que merece destaque diz respeito ao tratamento de informações pessoais ou confidenciais nos casos em que esse tratamento se aplica. Nesse sentido, quando informações com essas características estão disponíveis, um exercício de

149 Departamento de Infraestruturas (INE). *Guia de desenvolvimento de produtos digitais*. [Slides de PowerPoint]. Banco Interamericano de Desenvolvimento (BID).

150 Trata-se de erros sistemáticos e repetitivos num sistema de IA "que criam resultados injustos, como privilegiar um grupo arbitrário de utilizadores em detrimento de outros". Awan, A. A. O que é viés algorítmico (abril de 2024). Recuperado de: <<https://www.datacamp.com/es/blog/what-is-algorithmic-bias>>

151 Awan, A. A. O que é viés algorítmico (abril de 2024). Recuperado de: <<https://www.datacamp.com/es/blog/what-is-algorithmic-bias>>

anonimização<sup>152</sup> ou pseudonimização<sup>153</sup> pode ser realizado para treinar o modelo sem infringir a regulamentação existente sobre dados pessoais. Um exemplo desse tipo de consideração é o tratamento da informação utilizada para o desenvolvimento e implementação da ferramenta Distancia2, uma plataforma tecnológica desenvolvida pelo BID para as cidades, que foi implementada em 46 cidades da ALC durante a pandemia, e cujo objetivo era contribuir para mitigar o risco de contágio em áreas com grandes aglomerações. Essa solução utiliza imagens de vídeo gravadas por câmeras instaladas nas cidades e, através de algoritmos de IA, estima a distância entre pessoas para efeitos de análise e geração de alarmes de saúde pública. Durante a concepção e desenvolvimento desta ferramenta, foi exigido que ela não utilizasse informações privadas dos indivíduos, nem analisasse traços particulares

152 No processo de anonimização dos dados, é criado um novo conjunto de dados único. Independentemente da análise efetuada com ele, não é possível identificar as características pessoais da observação. Agência Espanhola de Proteção de Dados (AEPD). Anonimização e pseudonimização (outubro de 2021). Recuperado de: <<https://www.aepd.es/prensa-y-comunicacion/blog/anonimizacion-y-seudonimizacion>>

153 Durante o processo de pseudo-animação, são criados dois conjuntos de dados, os dados pseudo-anonimizados e os dados para reverter este processo, que devem cumprir todos os regulamentos relevantes. Agência Espanhola de Proteção de Dados (AEPD). Anonimização e pseudonimização (outubro de 2021). Recuperado de: <<https://www.aepd.es/prensa-y-comunicacion/blog/anonimizacion-y-seudonimizacion>>

ou características únicas dos indivíduos. Assim, o modelo implementado limita-se a detectar pessoas de forma anônima e estimar a distância entre elas.<sup>154</sup>

## Etapa 2, Fase 4

Segurança da informação e da tecnologia:

Os modelos de IA enfrentam uma série de desafios de segurança. Os riscos nessa área incluem, por exemplo, a geração de dados de entrada maliciosos ou vazamentos de segurança nas estruturas utilizadas na produção dos modelos.<sup>155</sup> Para evitar esses ataques ou vulnerabilidades, recomenda-se a adoção da abordagem de segurança por design, que integra medidas preventivas de segurança desde a própria concepção do modelo.<sup>156</sup>

Os setores de infraestruturas incluem ativos críticos com elevados níveis de interdependência, o que os torna vulneráveis a

154 Fonte: BID. Distancia2. Recuperado de <<https://fairlac.iadb.org/piloto/distancia2>>

155 Riscos da inteligência artificial na cibersegurança. Recuperado de: <<https://globalt4e.com/riesgos-de-la-inteligencia-artificial-en-ciberseguridad/>>

156 Ibidem.

ciberataques que podem desencadear crises sistêmicas. Nesse sentido, as organizações que implementam soluções de IA nos seus processos devem compreender a relevância da cibersegurança como um elemento fundamental.

Assim sendo, é essencial incorporar uma abordagem de segurança desde a concepção que integre a cibersegurança em toda a cadeia de produção do modelo. Essa abordagem garante um projeto seguro, protocolos de privacidade dos dados, uma arquitetura segura, sensibilização e formação para as vulnerabilidades e testes de segurança contínuos.<sup>157</sup> Relativamente a este último, uma prática comum é a realização de testes de penetração, fuzzing e ataques adversários em modelos de teste e nas fases de pré-produção e produção do modelo.<sup>158</sup>

157 Centro Nacional de Cibersegurança. IA e cibersegurança: o que precisa de saber. Recuperado de: <[https://www.ncsc.gov.uk/guidance/ai-and-cyber-security-what-you-need-to-know#section\\_5](https://www.ncsc.gov.uk/guidance/ai-and-cyber-security-what-you-need-to-know#section_5)>

158 Centro Nacional de Cibersegurança. Diretrizes para o desenvolvimento de sistemas de IA de segurança. Recuperado de: <<https://www.ncsc.gov.uk/collection/guidelines-secure-ai-system-development>>

## Fase 3. Aplicação, controle e avaliação da solução

### A **implementação, manutenção e escalonamento da solução**

inclui geralmente quatro (4) fases, que são: i) avaliação do desempenho; ii) sustentabilidade da solução; iii) auditoria ética e de segurança; e iv) atualização do modelo.

#### Etapa 3, Fase 1

##### Avaliação do desempenho:

Nesta fase, é analisado o desempenho do modelo de IA desenvolvido. Para o efeito, é normalmente definido e implementado um conjunto de métricas para avaliar o desempenho da solução e promover a confiança nos seus resultados. Estas métricas estimam a eficácia de um modelo na execução da sua tarefa específica e na obtenção dos resultados esperados. Esses indicadores servem para vários propósitos, incluindo a medição da exatidão, o ajuste de hiperparâmetros, a facilitação da interpretabilidade e a identificação de sobreajustamento ou subajustamento, entre outros.

Os indicadores de avaliação dependem tanto das características dos dados que estão sendo utilizados como do tipo de problema que está sendo resolvido. Assim, os indicadores de desempenho

mais utilizados para os problemas de classificação<sup>159</sup> são, por exemplo, a Exatidão,<sup>160</sup> a Precisão,<sup>161</sup> a Sensibilidade,<sup>162</sup> a Pontuação F1,<sup>163</sup> o ROC-AUC e o PR-AUC e a Matriz de Confusão.<sup>164</sup> As métricas mais comuns para problemas de

159 Halder, N. Decodificando o sucesso do aprendizado de máquina: avaliando métricas de desempenho com Python (fevereiro de 2024). Recuperado de: <<https://medium.com/gitconnected/decoding-machine-learning-success-evaluating-performance-metrics-with-python-2f98a452bbc4>>

160 **Precisão:** refere-se à “proporção de observações corretamente previstas em relação ao total”. É uma métrica intuitiva e fornece uma medida simples da eficácia do modelo, no entanto, quando há desequilíbrio nos dados, pode ser enganadora (Halder, 2024).

161 **Precisão:** Corresponde à “proporção de observações positivas corretamente previstas em relação ao número total de positivos previstos”. Trata-se de uma métrica muito útil quando o custo de um falso positivo não é baixo (Halder, 2024).

162 **Sensibilidade (Recall):** Refere-se à “proporção de observações positivas corretamente previstas em relação a todas as observações de classes verdadeiras”. Trata-se de uma métrica muito útil quando existe um custo elevado associado à obtenção de um falso negativo (Halder, 2024).

163 **F1 Score:** Corresponde à média ponderada dos indicadores *Precision* e *Recall*. Essa métrica é adequada quando existe um equilíbrio entre os dois indicadores, especialmente em categorias desequilibradas (Halder, 2024).

164 A **matriz de confusão** é uma representação tabular das categorias previstas e reais que permite ao investigador identificar com relativa facilidade os tipos de erros cometidos pelo modelo. Neste tipo de matriz, podem ser identificados os seguintes componentes: verdadeiros positivos (TP), que são os casos corretamente identificados como positivos; verdadeiros negativos (TN), que são os casos corretamente identificados como negativos; falsos positivos (FP), que são os casos negativos incorretamente identificados como positivos; falsos negativos (FN), que são os casos positivos incorretamente identificados como negativos. Em termos gerais, as linhas representam as categorias ou classes reais, as colunas representam as classes previstas pelo modelo, a diagonal principal mostra as previsões corretas e os elementos fora da diagonal referem-se a erros. Para mais informações, ver: <<https://www.sciencedirect.com/topics/engineering/confusion->

regressão<sup>165</sup> são: Erro Absoluto Médio (MAE),<sup>166</sup> Erro Quadrático Médio (MSE),<sup>167</sup> Raiz do Erro Quadrático Médio (RMSE),<sup>168</sup> Coeficiente de Determinação ( $R^2$ ),<sup>169</sup> Erro Percentual Absoluto Médio (MAPE),<sup>170</sup> e Coeficiente de Determinação Ajustado ( $R^2$  ajustado)<sup>171</sup>.

matrix#:~:text=A%20confusion%20matrix%20represents%20the,by%20model%20as%20other%20class.>.

165 Halder N. Decoding Machine Learning Success: Evaluating Performance Metrics with Python. Op.cit.

166 **Erro médio absoluto (MAE):** A “média das diferenças absolutas entre os valores previstos e os valores efetivos”. Essa métrica dá uma ideia do desvio das previsões (Halder, 2024).

167 **Erro quadrático médio (EQM):** Corresponde à média das diferenças quadráticas entre os valores previstos e os valores efetivos. O MSE penaliza mais os erros maiores do que o MAE, o que pode ser uma vantagem ou uma desvantagem, consoante o caso (Halder, 2024)

168 **Raiz do erro quadrático médio (RMSE):** É a raiz quadrada do erro quadrático médio ou MSE, que permite obter um indicador na mesma escala que os valores originais (Halder, 2024).

169 **Coeficiente de determinação ( $R^2$ ):** Representa a proporção da variância da variável-alvo ou dependente que é explicada pelos preditores ou variáveis independentes. Corresponde à bondade do ajuste dessas previsões (Halder, 2024).

170 **Erro Percentual Absoluto Médio (MAPE):** mede a média dos erros absolutos entre as previsões do modelo e os valores reais, expressos em percentagem dos valores reais.

171 **Coeficiente de Determinação Ajustado ( $R^2$  ajustado):** Corresponde a um ajuste de  $R^2$  de acordo com o número de preditores existentes no modelo. Fonte: Investopedia. Obtido de: <<https://www.investopedia.com/ask/answers/012615/whats-difference-between-rsquared-and-adjusted-rsquared.asp#:~:text=Adjusted%20R%2Dsquared%20is%20a,model%20by%20less%20than%20expected>>

Não é habitual utilizar um único parâmetro para determinar a eficácia de um modelo de IA, embora o desempenho mínimo esperado seja uma exatidão superior a 50%. Ao avaliar o desempenho de um modelo, considera-se normalmente a sua função de custo, que mede a distância entre o resultado do modelo e a realidade.<sup>172</sup> O objetivo é normalmente minimizar essa distância, o que é feito através de um algoritmo conhecido como *gradiente descendente*. É aconselhável otimizar o modelo a partir de pontos aleatórios nos dados e ajustar a taxa de aprendizagem do modelo durante o treinamento para garantir que os resultados obtidos sejam consistentes.<sup>173</sup>

172 Compreender as funções de custo na aprendizagem automática: tipos e aplicações (2023). Recuperado de <<https://medium.com/@anishnama20/understanding-cost-functions-in-machine-learning-types-and-applications-cd7d8cc4b47d>> & Fundamentos de aprendizado de máquina (i): Funções de custo e descida de gradiente. (2017, novembro). Obtido em <https://towardsdatascience.com/machine-learning-fundamentals-via-linear-regression-41a5d11f5220> & Gradient Descent for Dummies. (2021, maio). Recuperado de: <https://raed-asdi.medium.com/gradient-descent-for-dummies-1eda90f269b> & para mais informações, consulte: <<https://www.sciencedirect-com.ezproxy.uniandes.edu.co/topics/engineering/gradient-descent>>.

173 Ibidem.

Dessa forma, em função do tipo de problema que o modelo está resolvendo, são selecionadas métricas de desempenho para identificar os pontos fortes e fracos dos algoritmos utilizados. De igual modo, recomenda-se a utilização de mais do que um indicador para obter uma avaliação mais robusta e pormenorizada do modelo.

### Etapa 3, Fase 2

#### Estratégia de sustentabilidade da solução:

Esta fase refere-se ao conjunto de ações que devem ser tomadas para que a solução, uma vez desenvolvida, seja utilizada e atualizada continuamente na organização. Nesse sentido, um fator chave de sucesso na implementação da IA é a vontade institucional de garantir a sustentabilidade da solução, entendida como a capacidade de adotar a solução, integrá-la nos processos existentes e assegurar os recursos humanos, tecnológicos e financeiros necessários à sua utilização contínua. Em alguns casos, isso pode exigir uma mudança na cultura institucional em relação ao desenvolvimento e à adoção de inovações tecnológicas.

Nesta fase, é aconselhável implementar uma iniciativa de comunicação sobre a existência da ferramenta, o seu funcionamento e os resultados que gera. Na mesma

linha, é aconselhável avaliar e comunicar o retorno do investimento relacionado com a adoção da solução, de forma a dar feedback sobre o processo de desenvolvimento e implementação, e promover a sua adoção e continuidade. Pode também ser importante que as áreas da empresa interiorizem que a IA ajuda a reduzir os custos de investimento e de funcionamento. Dessa forma, os custos do projeto podem ser considerados como um investimento, e os fluxos futuros podem ser assegurados, permitindo um orçamento adequado para a manutenção e a melhoria contínua.

Da mesma forma, é importante criar ou fortalecer uma cultura de experimentação e aprendizado contínuo, possibilitando a inovação com uma abordagem ágil dentro da organização e ajudando a garantir a sustentabilidade da adoção de soluções. Experimentos controlados, juntamente com feedback direto do usuário, iteram mais rapidamente e, por fim, produzem resultados mais impactantes.<sup>174</sup> Erros no final de um projeto são mais dispendiosos do que o crescimento por meio de pequenos experimentos, não apenas em termos de tempo e recursos, mas também em

174 Departamento de Infraestruturas (INE). *Guia de desenvolvimento de produtos digitais*. [Slides de PowerPoint]. Banco Interamericano de Desenvolvimento (BID).

termos de motivação da equipe. Nesse sentido, implementar um programa de transferência de conhecimento é fundamental para garantir que o projeto continue a iterar, que o modelo continue sendo ajustado ao longo dos seus vários estágios e que as diferentes áreas relacionadas ao problema assumam a responsabilidade pela solução. O treinamento da equipe ajudará a garantir que o projeto seja totalmente utilizado e continuamente atualizado.

### Etapa 3, Fase 3

#### Auditoria ética e de segurança:

Este componente concentra-se na avaliação *ex post* da solução para identificar possíveis vulnerabilidades de segurança da informação e para garantir que os resultados não perpetuem estereótipos sociais que possam ser discriminatórios em relação a determinados grupos populacionais. A existência de sistemas automatizados de tomada de decisões gera desafios éticos e morais na definição das regras que esse sistema segue. Consequentemente, é necessário dispor de mecanismos de controle adequados, como a auditoria algorítmica (Villagrán, 2022). Embora a maioria dos modelos utilizados no setor de infraestrutura não seja habitualmente treinada com dados sensíveis, é uma boa prática realizar auditorias éticas e de segurança, principalmente nos casos em que são identificados

possíveis alertas relativos a enviesamentos ou ao tratamento de informações sensíveis.

Um dos mecanismos de controle e cumprimento das normas éticas definidas na própria concepção do modelo tem a ver com a “equidade de grupo”, que se refere à identificação dos grupos populacionais que podem ser prejudicados pelos resultados do modelo.<sup>175</sup> Este conceito, de acordo com as melhores práticas, é quantificado através de métricas de disparidade que procuram examinar e comparar o comportamento de grupos em diferentes indicadores de desempenho através de proporções ou diferenças.<sup>176</sup> Da mesma forma, existem métricas gerais de enviesamento de grupo,<sup>177</sup> como a Paridade Demográfica (PD),<sup>178</sup> a Igualdade de Oportunidades (EO),<sup>179</sup> ou a Paridade

Estatística (SP);<sup>180</sup> e métricas de enviesamento individual,<sup>181</sup> como os Indicadores de Probabilidades Iguais (EOdds)<sup>182</sup> e a Calibração,<sup>183</sup> entre outras.

Finalmente, nos processos de auditoria algorítmica é aconselhável, além de documentar os procedimentos e registar as pessoas que deles participam, adotar protocolos de intervenção no modelo quando as avaliações de equidade algorítmica não são aprovadas (Pombo et al. 2020; Torres et al., 2021; Villagrán, 2022).

175 Microsoft. Modelo de desempenho e equidade (fevereiro de 2024). Recuperado de: <<https://learn.microsoft.com/es-es/azure/machine-learning/concept-fairness-ml?view=azureml-api-2>>

176 Ibidem.

177 Gomedede, E. Métricas de justiça no aprendizado de máquina (setembro de 2023). Recuperado de: <<https://medium.com/the-modern-scientist/fairness-metrics-in-machine-learning-8c3777b48a9c>>

178 Testa “se a probabilidade de uma previsão positiva é igual em todos os grupos demográficos” (Gomedede, 2023).

179 Determina se, em todos os grupos, a taxa de verdadeiros positivos é equivalente, tendo assim como objetivo a redução do número de falsos negativos (Gomedede, 2023).

180 Assegura uma distribuição equitativa dos resultados positivos esperados entre os grupos (Gomedede, 2023).

181 Métricas de equidade na aprendizagem automática. Op.cit.

182 Garante que, em todos os grupos, as taxas de verdadeiros positivos são equivalentes às taxas de falsos positivos (Gomedede, 2023).

183 Este indicador avalia se as probabilidades previstas reflectem com precisão a probabilidade de ocorrência de um evento. Uma vez que um modelo mal calibrado tende a reproduzir decisões enviesadas, a calibração é um elemento a ter em conta (Gomedede, 2023).

### Etapa 3, Fase 4

Manutenção, atualização e expansão da solução:

Essa fase refere-se às atividades associadas a novos desenvolvimentos, atualizações e manutenção do modelo, de acordo com as necessidades existentes. O escalonamento do modelo pode aumentar o seu impacto na organização. Por outro lado, as alterações no ambiente, nos usuários e nos dados que alimentam o modelo geram a necessidade de revisão, exigindo o ajustamento dos seus parâmetros ou de reciclagem com novas informações.

O modelo desenvolvido e implementado ao longo do tempo pode perder a sua precisão em função de alterações estruturais no mercado ou na sociedade. Podem também ocorrer ligeiras alterações no comportamento das variáveis que o alimentam, nas suas propriedades estatísticas e até nos canais de coleta de informações, tornando-se necessário retreiná-lo com novas informações.<sup>184</sup>

<sup>184</sup> Entendendo a deriva de dados e a deriva de modelo: deteção de deriva em python. Recuperado de: <<https://www.datacamp.com/tutorial/understanding-data-drift-model-drift>>

Este fenómeno é conhecido por **model drift**, uma vez que se pode verificar uma **degradação do desempenho do modelo de aprendizagem automática implementado**.<sup>185</sup> Para estar atento a este fenómeno, é importante dispor de um **processo contínuo de controle de qualidade e de monitoramento do desempenho do modelo para detectar desvios em relação aos indicadores obtidos na fase inicial de produção**,<sup>186</sup> bem como **para permitir a incorporação de novos dados de entrada para antecipar as mudanças no ambiente**.

Do mesmo modo, é importante manter documentadas as alterações efetuadas tanto no modelo como na interface com a qual o usuário interage, caso existam. Nesse sentido, o controle de versões permite a colaboração entre os diferentes programadores, facilita a rastreabilidade das modificações, permite navegar com relativa agilidade entre versões para recuperar parte de uma solução do passado,

<sup>185</sup> Nicoomanesh A. (2024). Deriva do modelo: identificação e monitorização da deriva do modelo na engenharia e produção de aprendizagem automática Recuperado de: <<https://medium.com/@anicomanesh/model-drift-identifying-and-monitoring-for-model-drift-in-machine-learning-engineering-and-0f74b2aa2fb0>>.

<sup>186</sup> Ibidem.

contribui para a resolução de conflitos entre alterações simultâneas do código e favorece a auditoria algorítmica, entre outros.

Finalmente, em projetos que envolvem *aprendizagem automática*, a escalabilidade é entendida como a capacidade do sistema para incorporar aumentos significativos nos volumes de dados, aumentar a sua eficiência e eficácia, bem como suportar cargas de trabalho maiores sem afetar o seu desempenho.<sup>187</sup> Neste sentido, a escalabilidade de uma solução de IA envolve diferentes dimensões, incluindo os dados, o modelo e a infraestrutura.<sup>188</sup> Assim, no que diz respeito à dimensão da informação, à medida que a aplicação evolui, a quantidade de informação aumenta, à medida que mais dados são envolvidos no processo de retreinar, validar e testar novas versões do modelo.<sup>189</sup> Por sua vez, o modelo também pode variar em tamanho

<sup>187</sup> Censius. Escalabilidade do ML. Recuperado de: <[https://www.openteams.com/scalable-infrastructure-for-mlops-ensuring-high-performance-and-efficiency/](https://censius.ai/wiki/ml-scalability#:~:text=Machine%20learning%20scalability%20refers%20to,users%20residing%20at%20global%20locations.> & OpenTeams. Infraestrutura escalável para MLOps: garantindo alto desempenho e eficiência (2023, junho). Recuperado de <<a href=)>

<sup>188</sup> Ibidem.

<sup>189</sup> Ibidem.

e complexidade, exigindo assim mais capacidade de computação. Daqui resulta a necessidade de infraestruturas escaláveis para responder às novas necessidades de armazenamento - cada vez mais informação - e de processamento - modelos mais complexos com mais parâmetros -<sup>190</sup> que possam surgir. A escalabilidade da solução pode ser conseguida através de ações como a implementação de um sistema de monitoramento de desempenho que alerte quando o modelo está ficando desatualizado, a utilização de *cloud computing* para poder escalar as plataformas tecnológicas em tempo hábil, a utilização de processamento paralelo,<sup>191</sup> ou através da execução de tarefas em contêineres do tipo Docker<sup>192</sup> para tornar a operação dos modelos mais eficiente.<sup>193</sup>

<sup>190</sup> Ibidem.

<sup>191</sup> Paramaisinformações,consultar:Processamentoparalelo.Recuperadode:<[<sup>192</sup> O que é o Docker? Recuperado de <<https://aws.amazon.com/es/docker/>>](https://www.techtarget.com/searchdatacenter/definition/parallel-processing#:~:text=Parallel%20processing%20is%20a%20method,time%20to%20run%20a%20program.></a></p>
</div>
<div data-bbox=)

<sup>193</sup> Censius. ML Scalability. Obtido em: < [https://www.openteams.com/scalable-infrastructure-for-ml-ops-ensuring-high-performance-and-efficiency/](https://censius.ai/wiki/ml-scalability#:~:text=Machine%20learning%20scalability%20refers%20to,users%20residing%20at%20global%20locations.></a> & OpenTeams. Infraestrutura escalável para MLOps: garantindo alto desempenho e eficiência (2023, junho). Recuperado de <<a href=)>

## 4.2

### Princípios recomendados para o desenvolvimento de soluções de IA

Por fim, e de acordo com as considerações apresentadas na seção anterior, tendo em vista as vantagens da abordagem ágil de desenvolvimento e inovação para a implementação de soluções de IA em setores de infraestruturas, recomenda-se que um conjunto de nove (9) princípios seja considerado ao longo do processo de desenvolvimento e implementação da solução, conforme descrito abaixo.

- **Compreender o problema e a relevância da IA para a sua solução:** Este princípio baseia-se na ideia de que é desejável primeiro entender o problema antes de pensar em como resolvê-lo. Nesse sentido, é importante definir e delimitar o problema ou a necessidade a ser solucionado, para que o problema seja claro, conciso, baseado em evidências e se refira a uma situação solucionável. Depois que o problema for identificado e compreendido, será essencial avaliar a adequação do uso da IA na solução, com base nos benefícios, custos e implicações para a organização do uso dessa tecnologia. Nesse sentido, o foco dos projetos de IA

deve estar na resolução do problema específico a ser resolvido, e não na tecnologia em si.

- **Concepção e desenvolvimento centrados no usuário:** Este princípio baseia-se em colocar o usuário como a força convergente no desenvolvimento da solução. Isso implica conhecer as características das pessoas ou entidades que irão utilizar o modelo, quais serão as principais utilizações, que motivações têm, em que processos irão interagir os resultados do modelo, entre outros. Para isso, é necessário interagir com o usuário no âmbito da criação do produto, com o objetivo de identificar as suas necessidades, motivações e expectativas na utilização.
- **Desenvolvimento ágil:** Refere-se à capacidade de criar produtos de forma dinâmica e iterativa, e de adaptar os produtos em resposta à mudanças. Este princípio compreende uma série de quadros<sup>194</sup> e metodologias<sup>195</sup> que permitem que o desenvolvimento de produtos

<sup>194</sup> Alguns exemplos são: Scrum, Kanban e Extreme Programming (Agile Alliance).

<sup>195</sup> São exemplos: programação em pares, desenvolvimento orientado para os testes e planeamento de sprints (Agile Alliance).

através da iteração, da experiência e da colaboração se adapte com relativa facilidade às mudanças do usuário, do mercado e mesmo da empresa responsável pelo produto ou serviço.<sup>196</sup>

- **Aproveitamento dos dados:** Este princípio vai além do uso de informações em processos. Exige uma transformação da organização<sup>197</sup> para pensar, gerenciar e comunicar os seus processos produtivos, maximizando a informação disponível. Para isso, é essencial dispor de informação de qualidade,<sup>198</sup> ou seja, que seja completa, consistente e verdadeira, sob pena de os resultados do modelo carecerem de confiabilidade e robustez.
- **Utilização de padrões abertos e inovação:** Este princípio baseia-se na criação de conhecimentos na comunidade.

196 Agile Alliance, O que é Agile? Obtido de: <[https://learn.microsoft.com/es-es/devops/plan/what-is-agile-development](https://www.agilealliance.org/agile101/#:~:text=Agile%20is%20the%20ability%20to,an%20uncertain%20and%20turbulent%20environment.> & Microsoft.What is Agile development (outubro, 2023). Retrieved from <<a href=)>

197 Para tal, é importante, numa primeira fase, identificar o nível de maturidade da organização em termos de análise de dados, uma vez que a implementação do projeto deve ser gradual.

198 Os problemas de qualidade dos dados podem dever-se a múltiplos fatores, como erros humanos, técnicos ou de recolha de dados.

Baseia-se no pressuposto de que uma abordagem aberta ao desenvolvimento e à inovação maximiza os recursos e o impacto das soluções que são implementadas.<sup>199</sup>

- **Utilização de modelos fundamentais de uso livre:** Como já foi referido, os modelos fundacionais (FM), também conhecidos como modelos pré-treinados ou de uso geral, são redes neuronais de aprendizagem profunda treinadas com grandes quantidades de dados e compostas por um número significativo de parâmetros, que realizam diferentes tarefas gerais, como a geração de texto e imagens, a compreensão de diferentes línguas humanas e a manutenção de conversas em linguagem natural, entre outras.<sup>200</sup> Algumas das vantagens de utilizar este tipo de modelos<sup>201</sup> no desenvolvimento de um sistema próprio

199 Por um lado, existem as plataformas de código aberto, como o Qgis ou o R. Mas, por outro lado, há projetos já implementados que decidem partilhar o seu repositório, incluindo as bibliotecas utilizadas e o código fonte, como por exemplo o BID faz através do “Code for Development”.

200 O que são modelos fundacionais? Recuperado de: <<https://aws.amazon.com/es/what-is/foundation-models/>>

201 Alguns exemplos são: BERT-Bidirectional Encoder Representations from Transformers-(<<https://github.com/google-research/bert>>); GPT-Generative Pre-trained Transformer-(<<https://github.com/openai/gpt-2>>); RoBERTa-A Robustly Optimized BERT Pertaining Approach-(<<https://github.com/facebookresearch/fairseq/tree/main/examples/roberta>>); T5-Text to Text Transfer Transformer-(<<https://github.com/google-research/text-to-text-transfer-transformer>>); XLNet

têm a ver com a redução do tempo de desenvolvimento, a otimização dos recursos, a adaptabilidade através de afinações, a escalabilidade horizontal e vertical e o crescimento da comunidade, entre outras.<sup>202</sup>

- **Relevância da ética, da privacidade e da segurança:** Este princípio refere-se a três conceitos principais. O primeiro diz respeito à aplicação de princípios éticos na concepção e estruturação de modelos de IA. O segundo conceito refere-se à privacidade dos dados. A este respeito, uma boa concepção de modelos deve garantir que os dados dos usuários são tratados de forma segura e que a sua privacidade é respeitada, evitando a utilização indevida ou o acesso não autorizado. Por último, o terceiro conceito é a segurança do sistema. Trata-se de atenuar os riscos cibernéticos que surgem quando os modelos de IA são aplicados a infraestruturas críticas, como nos setores de energia, de transportes, de água e de saneamento.

(<<https://github.com/zihangdai/xlnet>>); e YOLO-You Only Look Once-(<<https://github.com/ultralytics/yolov5>>).


202 3 Formas de adaptar um Modelo de Fundação para atender às suas necessidades específicas. Recuperado de: <<https://kili-technology.com/large-language-models-llms/three-ways-to-adapt-an-llm-model-to-suit-your-ml-needs>>

- **Escalabilidade:** Este princípio é prospectivo e consiste na concepção e implementação de um sistema capaz de crescer à medida das necessidades. A escalabilidade do sistema deve ser função de aspectos como a quantidade de dados que o modelo requer, a capacidade de processamento e armazenamento e o tipo e frequência das interações que terá com os usuários.
- **Sustentabilidade:** Por fim, este princípio aponta a relevância de que as soluções de IA implementadas sejam efetivamente adotadas nas organizações, que gerem impactos relevantes nas mesmas, e que os recursos sejam garantidos para que possam continuar sendo utilizados a médio e longo prazos.



## CONCLUSÕES E RECOMENDAÇÕES

A Inteligência Artificial está emergindo como uma tecnologia de uso geral, comparável a marcos históricos como a máquina a vapor, a eletricidade, a computação e a Internet, graças à sua capacidade de transformar profundamente múltiplos setores e dimensões da sociedade. O seu desenvolvimento e implementação proporcionam oportunidades significativas para a transformação digital em setores-chave de infraestruturas, como a energia, o transporte, a água e o saneamento e os resíduos sólidos. Estes setores, sendo sistemas complexos organizados em redes, com múltiplos intervenientes e uma elevada intensidade de capital físico e de dados, têm um grande potencial para se beneficiar do impacto transformador dessa tecnologia. Considerando as oportunidades que a IA oferece no setor de infraestrutura, é importante que as organizações implementem metodologias robustas de desenvolvimento e inovação que sejam consistentes com seus objetivos e alinhadas com as melhores práticas.



O BID tem apoiado governos e organizações em áreas de infraestruturas na concepção, prototipagem, desenvolvimento e implementação de soluções de IA que contribuíram para melhorar o desempenho dos processos, a integração regional e a qualidade dos serviços prestados aos cidadãos. O Departamento de Infraestruturas e Energia do BID tem liderado utilização da IA, acompanhando os seus clientes na pilotagem e adoção de soluções desenvolvidas tanto por entidades públicas como pelo setor privado. Ao mesmo tempo, juntamente com o IDB Lab, promoveu a criação de soluções inovadoras do setor empresarial da região, com o objetivo de melhorar a prestação de serviços públicos e criar oportunidades de desenvolvimento.

Levando-se em consideração a revisão das práticas internacionais e as considerações apresentadas ao longo do documento, apresenta-se a seguir um conjunto de recomendações para o sucesso do desenvolvimento e implementação de soluções baseadas em IA nos setores de infraestruturas na ALC. Essas recomendações são destinadas a quem projeta e implementa essas soluções, formuladores de políticas públicas da região e empreendedores ou equipes que inovam nessa área.

## Recomendações gerais

- Ao implementar soluções digitais em setores de infraestruturas, concentre-se no problema a ser resolvido e não na tecnologia em si. Para fazer isso, defina e restrinja o problema ou a necessidade de modo a que seja claro, conciso, baseado em provas e se refira a uma situação solucionável. Uma vez identificado e compreendido o problema, avalie a pertinência da utilização da IA na solução, com base nos benefícios, custos e implicações para a organização da utilização dessa tecnologia. Dessa forma, recomenda-se que a aplicação da IA nestas soluções se concentre em casos ou componentes em que a sua utilização seja relevante, útil e viável do ponto de vista operacional, financeiro e legal.
- Implementar metodologias ágeis de desenvolvimento e inovação da IA permitindo iterações rápidas, ajustes contínuos e adaptação flexível a alterações e melhorias nos modelos, processos e requisitos dos usuários.
- Incorporar provas de conceito, protótipos e projetos-piloto na metodologia de desenvolvimento para testar e afinar a solução antes da sua implementação em grande escala. Isso permitirá a identificação e a incorporação de

tecnologias e funcionalidades específicas de acordo com necessidades e requisitos específicos.

- Desenvolver estruturas organizacionais que permitam a adoção de soluções tecnológicas baseadas em IA. O sucesso do seu desenvolvimento e implementação dependerá em grande parte do comprometimento e apoio da alta administração, da existência de líderes internos ou “campeões” que conduzam o processo e da consolidação de uma cultura aberta à inovação, à mudança, à experimentação e ao trabalho em equipe. Da mesma forma, a participação e o comprometimento de toda a equipe operacional são essenciais para garantir o uso sustentado e o benefício contínuo da ferramenta ao longo do tempo.
- Diagnosticar o estado das capacidades do pessoal para compreender as oportunidades e os riscos da IA, para gerenciamento dos dados e para participar no desenvolvimento e na aplicação de soluções baseadas na IA. Com base nesses diagnósticos, conceber e implementar programas relevantes de formação e transferência de conhecimentos.

- Examinar a viabilidade financeira da adoção de soluções baseadas na IA, levando-se em consideração os custos associados, especialmente em termos de formação de modelos e processamento de dados, bem como a possível evolução destes custos em função da fase do projeto. Considerar também os custos associados à implementação de projetos de IA, incluindo os custos relacionados com o gerenciamento da mudança, o desenvolvimento de competências e a sustentabilidade dos modelos a longo prazo.
- Identificar e definir o retorno do investimento (ROI) da adoção de soluções baseadas em IA para justificar a sua implementação. Isso implica avaliar os benefícios tangíveis e intangíveis, como a redução dos custos operacionais, o aumento da eficiência, a melhoria da tomada de decisões e a otimização dos processos. Ao estabelecer indicadores mensuráveis de sucesso ligados a objetivos estratégicos, garante-se que as soluções tecnológicas proporcionam um valor real e sustentado a longo prazo, facilitando a escalabilidade e a aceitação.
- Prestar especial atenção às questões éticas, de privacidade e de segurança desde as fases iniciais da concepção de soluções baseadas em IA. Isso significa

incorporar princípios éticos como a transparência, a equidade e a responsabilidade no desenvolvimento de modelos para garantir que as soluções não perpetuem preconceitos ou discriminem determinados grupos. Além disso, será necessário garantir a proteção dos dados pessoais, cumprir a regulamentação em vigor em matéria de privacidade e estabelecer mecanismos de segurança robustos que minimizem os riscos de vazamentos ou de acesso não autorizado. A implementação destas medidas desde o início não só reforça a confiança na tecnologia, como também protege a organização de potenciais riscos legais e de reputação a longo prazo.

- Documentar e disseminar lições aprendidas e estudos de caso bem-sucedidos para promover a compreensão da IA no setor público e convencer mais formuladores de políticas sobre as oportunidades que essa tecnologia oferece.
- Considerar as experiências de outras regiões na implementação de soluções de IA em setores de infraestrutura, com o objetivo de obter conhecimento e contribuições para fortalecer o planejamento e a execução de políticas e projetos para promover a adoção de IA.

## Recomendações na fase de identificação de oportunidades e planejamento de soluções

- Definir os dados necessários, caso ainda não estiverem definidos, identificar as fontes disponíveis - sensores, contadores inteligentes, câmeras de vídeo, sistemas SCADA, redes de transporte ou de distribuição, entre outros - e estabelecer uma arquitetura de dados e esquemas de governança ideais. Esses elementos garantem a coleta e o gerenciamento adequado de dados críticos, como os fluxos de tráfego, o consumo de água ou de energia e o estado das infraestruturas. Prestar especial atenção à qualidade, segurança e disponibilidade dos dados durante o desenvolvimento e a implementação é fundamental para conseguir operações eficientes e sustentáveis, otimizar a tomada de decisões e cumprir a regulamentação local. Além disso, diferenciar, desde o início, a utilização de dados de sistemas e redes sem implicações para a privacidade dos dados dos usuários e de outras pessoas, em que a proteção dos dados e a cibersegurança são fundamentais.
- Identificar e avaliar, desde a concepção, os requisitos das ferramentas tecnológicas e das infraestruturas de dados para o desenvolvimento de soluções de IA, especialmente

em relação às capacidades de armazenamento e processamento. A respeito disso, evitar a dependência exclusiva de fornecedores específicos e considerar o valor oferecido pelos serviços de computação em nuvem devido à sua eficiência, flexibilidade, agilidade e escalabilidade.

- Avaliar e identificar o quadro operacional ideal para o desenvolvimento da solução de IA. O desenvolvimento interno implica custos mais baixos e a aprendizagem mantém-se dentro da organização. Por sua vez, os esquemas de terceirização fornecem o conhecimento técnico e a experiência necessária para desenvolver a solução em tempo hábil, bem como prazos de desenvolvimento mais curtos. Trabalhar com consultores internos permite uma colaboração estreita e personalizada, enquanto a ligação entre empresas especializadas pode trazer o benefício do acesso a uma equipe diversificada e polivalente.
- Considerar a possibilidade de colaborar com *startups* tecnológicas representa uma opção valiosa para o desenvolvimento de soluções baseadas em IA para setores de infraestruturas. Na ALC, existe um ecossistema crescente de *startups* especializadas no gerenciamento da água, resíduos sólidos, transportes e energia que oferecem soluções inovadoras adaptadas aos desafios locais.

Trabalhar com essas *startups* pode trazer agilidade, novas perspectivas e tecnologias de ponta, além de facilitar a implementação de soluções mais personalizadas e flexíveis. Essa colaboração reduz os prazos de desenvolvimento, ao mesmo tempo que promove o crescimento do ecossistema empresarial regional.

- Considerar, para a composição das equipes, profissionais com as competências necessárias para o sucesso do desenvolvimento e implementação da solução. Neste âmbito, avaliar a existência de competências em *data science*, *machine learning* e desenho e gestão da arquitetura tecnológica. Da mesma forma, incorporar profissionais com conhecimento do negócio, que possam validar, desde a fase de desenho, que o modelo responde às necessidades da organização, e fornecer feedback valioso sobre as funcionalidades e resultados no contexto específico do setor.
- Identificar as partes interessadas que serão relevantes para o êxito da adoção da solução. Nesse contexto, é útil estabelecer a ligação entre potenciais parceiros ou patrocinadores que possam ajudar a garantir a viabilidade da implantação. Os governos locais e os agentes reguladores são também importantes atores para promover a adoção e obter um maior impacto com a utilização dessas soluções.

- Examinar desde o início os riscos éticos, reputacionais e regulamentares, entre outros, associados ao desenvolvimento e adoção da solução, avaliar o seu potencial impacto e estabelecer um plano para a sua mitigação. No caso de utilização de informação sensível, avaliar a implementação das metodologias de tratamento especial deste tipo de variáveis e dos indicadores de equidade algorítmica indicados no Capítulo 4.

## Recomendações na fase de desenvolvimento de protótipos e soluções

- Analisar o fluxo de dados do projeto para garantir que os dados sejam adequados, limpos e estão prontos para serem utilizados na formação e produção de um modelo de IA ou de *aprendizagem automática*. Esse processo identifica potenciais problemas com as fontes de dados, garantindo a sua integração eficiente, e otimiza as fases de processamento e transformação dos dados. Além disso, ao estruturar corretamente o fluxo de dados, a qualidade do modelo é melhorada, os erros são minimizados e o tempo e os custos associados às correções subsequentes são reduzidos, o que aumenta a probabilidade de sucesso na implementação da solução.

- Avaliar a representatividade da população nos conjuntos de dados e verificar se é necessário consentimento para seu processamento. Nos casos em que os dados são insuficientes, avaliar a adoção de técnicas como o aumento de dados para treinar modelos de IA de forma eficaz.
- Considerar os critérios propostos para a seleção de modelos: a natureza do problema, o tipo e a qualidade da informação, a capacidade computacional, os indicadores de desempenho e a explicabilidade, entre outros. Iniciar com modelos simples e aumentar a sua complexidade à medida das necessidades. Isso facilitará a concepção, o desenvolvimento e a experimentação, permitirá incorporar ajustes à medida que se obtém informação sobre o desempenho e o feedback dos usuários e evitará o desperdício de recursos de computação.
- Compreender a importância do desenvolvimento de provas de conceito, protótipos e produto mínimo viável, como espaços de experimentação, aprendizagem e feedback para a melhoria contínua da solução.
- Dar especial importância ao desenvolvimento de interfaces amigáveis, que facilitem a utilização das

aplicações pelos membros da organização, incluindo, quando aplicável, o pessoal não especializado.

- Implementar processos permanentes de supervisão ética e de segurança da informação desde a concepção. Isso implica monitorizar continuamente a utilização dos dados, a privacidade dos usuários e prevenir possíveis enviesamentos nos modelos. Além disso, estabelecer medidas de segurança sólidas para proteger as informações sensíveis contra ciberataques ou acesso não autorizado.

## Recomendações na fase de implementação, manutenção e aumento de escala da solução

- Definir e implementar indicadores de desempenho, como os descritos no Capítulo 4, para avaliar o desempenho da solução, bem como a eficácia do modelo na execução da sua tarefa específica e na obtenção dos resultados esperados.
- Efetuar auditorias algorítmicas que forneçam informações relevantes para garantir que os modelos funcionam como esperado e que não geram resultados com implicações

éticas indesejáveis. A este respeito, a validação dos modelos deve incluir mecanismos de resposta para os casos em que os resultados não são os esperados.

- Dar importância à explicabilidade e transparência dos modelos. A capacidade de explicar como os modelos funcionam e com base em que tomam decisões é essencial para a responsabilização e a confiança nas soluções de IA. Isso é especialmente crítico no setor público, devido ao uso de recursos estatais, às exigências de responsabilização e às implicações das soluções implementadas no bem-estar da população.
- Implementar estratégias de comunicação sobre a existência da ferramenta, o seu funcionamento e os resultados que gera para a organização.
- Avaliar e comunicar o retorno do investimento relacionado com a adoção das soluções, de forma a dar feedback sobre o processo de desenvolvimento e implementação, e a promover a adoção e continuidade dessas soluções. Na mesma linha, é importante que as áreas da empresa interiorizem que a IA é de grande utilidade para avaliar hipóteses de mercado e reduzir custos de investimento ou operacionais. Isso garantirá

fluxos futuros que permitirão um orçamento adequado para a sua manutenção e melhoria contínua.

- Consolidar uma cultura de experimentação e aprendizagem contínua que permita a inovação em qualquer área da organização, e que contribua para garantir a sustentabilidade da adoção de soluções. Nesse sentido, a implementação de um programa de transferência de conhecimento é fundamental para que o projeto continue a iterar, para que o modelo continue a ser ajustado nas suas diferentes fases e para que as diferentes áreas relacionadas com o problema assumam a responsabilidade pela solução.
- Ter um processo contínuo de controle de qualidade e monitoramento do desempenho do modelo que detecte desvios nos resultados e permita a incorporação de novos dados de entrada para antecipar mudanças no ambiente.
- Manter a documentação das alterações ao modelo e à interface do usuário. Isso garante um acompanhamento claro das alterações, facilita a colaboração entre equipes e permite identificar rapidamente o impacto dos ajustes no desempenho do sistema e na experiência do usuário. Para garantir uma documentação eficaz,

recomenda-se a utilização de ferramentas de controle de versões para registrar e acompanhar todas as alterações feitas ao código. Além disso, as plataformas de colaboração podem ser utilizadas para criar uma base de conhecimento centralizada onde as equipes possam descrever minuciosamente as atualizações, as melhorias e as justificativas das alterações. A respeito disso, é importante estruturar a documentação em seções claras, incluindo datas, versões e descrições técnicas, para que qualquer membro da equipe possa facilmente consultar e compreender o histórico de alterações.

- Assegurar a flexibilidade técnica e organizacional que permita a adaptação das soluções mudanças no ambiente, bem como às novas regulamentações aplicáveis.
- Implementar ações para permitir a escalabilidade da solução, tais como a implementação de um sistema de monitoramento do desempenho para alertar quando o modelo estiver ficando desatualizado, aproveitar a utilização da computação em nuvem para dimensionar as plataformas em tempo hábil e a utilização de opções tecnológicas para tornar o funcionamento do modelo mais eficiente.

As organizações dos setores de infraestruturas críticas na ALC têm uma oportunidade única de avançar na implantação da inteligência artificial como meio de acelerar a sua transformação digital e obter resultados melhores em termos de eficiência operacional, produtividade, satisfação dos usuários, sustentabilidade e contribuição para o desenvolvimento econômico e social dos países. Para alcançar estes benefícios, é vital que os tomadores de decisão compreendam plenamente o potencial e as implicações da IA, bem como as oportunidades oferecidas por casos de utilização reais e soluções para problemas existentes. Além disso, esses líderes devem familiarizar-se com as metodologias recomendadas para o desenvolvimento e a inovação da IA e considerar as principais questões identificadas para o desenvolvimento e a adoção de soluções de IA.



# ANEXOS

## **Anexo 1.** **Revisão dos marcos regulatórios da IA na ALC**

Um elemento relevante a ser considerado para a implementação bem-sucedida de soluções baseadas em IA nos setores de infraestrutura é o marco regulatório aplicável. Esse anexo apresenta uma revisão dos marcos regulatórios na ALC relacionados ao desenvolvimento e à adoção dessas tecnologias. Especificamente, é feita uma análise comparativa dos principais elementos dos regulamentos de proteção de dados na região, bem como dos desenvolvimentos específicos que os países implementaram em termos de regulamentos e diretrizes para o desenvolvimento e adoção da IA.



Ao adotar regulamentações e padrões de IA, cada país pode influenciar o nível de desenvolvimento dessas tecnologias em nível nacional (TMG, 2020). De fato, as estruturas regulatórias determinam as oportunidades potenciais que a adoção antecipada e oportuna da IA pode trazer para indivíduos, empresas e sociedade, bem como os riscos associados à privacidade e potenciais práticas discriminatórias, entre outros. Além disso, as estruturas regulatórias podem priorizar a implementação de alguns dos princípios considerados fundamentais para a IA, como justiça, privacidade, responsabilidade e transparência.

O objetivo deste anexo é apresentar uma análise dos marcos regulatórios sobre IA e proteção de dados em onze países da região, em aspectos que possam ter implicações para o desenvolvimento de soluções baseadas nessa tecnologia nos setores de infraestruturas. O conjunto de países analisados é composto por: Argentina, Brasil, Chile, Colômbia, Costa Rica, Equador, México, Panamá, Peru, República Dominicana e Uruguai. Como mencionado nesta seção, a maioria dos desenvolvimentos regulamentares relacionados com a IA nos países da região foram implementados principalmente no campo da privacidade e da proteção de dados. Além disso, alguns governos abordaram as implicações éticas

da utilização dessa tecnologia através da formulação de princípios, diretrizes ou recomendações, em vez de emitirem regulamentos específicos. Ademais, uma prática de política pública comum na região é a formulação de planos ou estratégias nacionais destinadas a desenvolver os fatores que permitem a adoção dessa tecnologia nos governos e nos diferentes setores da economia.

### Marcos regulatórios para a proteção de dados na IA

Uma área da regulamentação crucial para o desenvolvimento e a implementação de soluções baseadas na IA são os regimes de proteção de dados dos países. Esses regimes definem as regras sobre a geração, o acesso, a coleta, o gerenciamento, o armazenamento e o tratamento de dados (TMG, 2020), que são a contribuição fundamental para desenvolvimentos baseados na IA. O **Quadro 1** apresenta um resumo dos principais elementos dos marcos regulatórios existentes em matéria de proteção de dados nos onze países da região analisados. Alguns dos elementos considerados, que podem ser determinantes para o desenvolvimento de soluções baseadas na IA, são a existência de requisitos relativos ao consentimento dos titulares dos dados, o registro em bases de dados, o processamento de dados por meio

de terceiros, a avaliação do impacto na privacidade, as restrições às transferências internacionais de dados e os requisitos de localização de dados.

**Quadro 1.** Marcos regulatórios da proteção de dados na América Latina

País	Principal lei de proteção de dados	Consentimento da pessoa em causa	Registo na base de dados	Tratamento de dados por conta de terceiros	Obrigações de avaliação do impacto na privacidade	Restrições à transferência internacional de dados	Requisito de localização de dados
<b>Argentina</b>	Lei 25.326 de 2000	Sim	Sim	Sim	Não	Lista de países	Setor financeiro, contabilístico e laboral
<b>Brasil</b>	Lei 13.709 de 2018	Sim	Não	Sim	Sim	Lista de países	Informações estatais, públicas e financeiras
<b>Chile</b>	Lei 19.628 de 1999 Lei 20.575 de 2012	Sim	Sim	Sim	Não	NE	Setor bancário
<b>Colômbia</b>	Lei 1581 de 2012	Sim	Sim	Sim	Não	Lista de países	Setor da defesa
<b>Costa Rica</b>	Lei 8.968 de 2011 Regulamento 37.554-JP de 2013 da Lei	Sim	Sim	Sim	Sim	Não	NE

País	Principal lei de proteção de dados	Consentimento da pessoa em causa	Registo na base de dados	Tratamento de dados por conta de terceiros	Obrigações de avaliação do impacto na privacidade	Restrições à transferência internacional de dados	Requisito de localização de dados
<b>Equador</b>	Lei Orgânica de 2021	Sim	Sim	Sim	Sim	Lista de países	Dados sensíveis do Estado e da segurança nacional (Lei Fintech)
<b>México</b>	Nova lei federal DOF 05-07-2010	Sim	Não	Sim	Sim	NE	Em casos de segurança nacional e de informação pública
<b>Panamá</b>	Lei 81 de 2019	Sim	Não	Sim	Sim	Lista de países	NE
<b>Peru</b>	Lei 29.733 de 2011	Sim	Sim	Sim	Não	Lista de países	Não
<b>República Dominicana</b>	Lei 172 de 2013	Sim	Não	Sim	Não	Lista de países	NE
<b>Uruguai</b>	Lei 18.331 de 2008	Sim	Sim	Sim	Sim	Lista de países	Para os riscos da administração central e da regulamentação setorial, como a banca

Fonte: EY (2023), IAPP Research and Insights (2024), & Centro LATAM Digital (2022), Baker McKenzie - atualizado entre dezembro de 2023 e janeiro de 2024, Asamblea Nacional República del Ecuador (2022).

NE: Não

Como se pode verificar, todos os onze países analisados têm regimes de proteção de dados em vigor através de leis nacionais. Os primeiros países a implementarem tais regimes foram o Chile e a Argentina em 1999 e 2000, enquanto o Equador é o país mais recente a implementar tal regime, em 2021. Em todos esses países, os regimes exigem o consentimento do titular dos dados como medida de proteção de dados. No entanto, há circunstâncias em que o consentimento não é exigido nestes países. Algumas delas estão associadas ao fato de os dados serem acessíveis ao público, anonimizados ou tratados para efeitos de requisitos legais, entre outros (EY, 2023).

Por outro lado, sete dos onze países analisados exigem o registro das bases de dados junto da respectiva autoridade, bem como a apresentação de relatórios conexos em uma base regular (EY, 2023). Os países com essa exigência são a Argentina, o Chile, a Colômbia, a Costa Rica, o Equador, o Peru e o Uruguai. No caso do Chile, esse registro é exigido para a informação coletada por entidades públicas.

Outro aspeto analisado no quadro regulamentar da proteção de dados é a autorização do tratamento de dados por meio de terceiros. Em todos os onze países analisados, esse tratamento é permitido. Em alguns países, como a Argentina

e a Costa Rica, aspectos como a finalidade e o cumprimento de determinadas condições são fundamentais, enquanto noutros, como o Equador, o âmbito do tratamento deve ser determinado contratualmente (EY, 2023).

Além disso, as estruturas regulatórias de proteção de dados exigem a implementação de exercícios de avaliação de impacto na privacidade. Essa obrigação exige que o responsável pelo tratamento de dados ou o seu responsável legal pelo tratamento efetue uma avaliação relativamente à proteção desses dados à luz dos riscos associados a aspetos como direitos e liberdades (Comissão Europeia, 2012). Essa exigência existe em seis dos onze países da região analisados: Brasil, Costa Rica, Equador, México, Panamá e Uruguai.

Por último, os marcos regulatórios de proteção de dados da região incluem considerações sobre a transferência internacional de dados e, em alguns casos, existem determinados requisitos de localização de dados em territórios nacionais. Pelo menos oito países da região incorporaram restrições à transferência internacional de dados, segundo as quais essas transferências só podem ser feitas para aqueles com níveis semelhantes ou superiores de proteção de dados (EY, 2023), e definiram uma lista de países para os

quais os dados podem ser transferidos. Outros países, como a Costa Rica, não têm tais restrições, enquanto o Chile e o México não as especificam. Por outro lado, em países como a Argentina, o Brasil, o Chile, a Colômbia, o Equador, o México e o Uruguai existem requisitos de localização de dados em setores específicos, como os setores financeiro e da defesa, ou em relação a dados do Estado. No Peru não existem tais restrições, enquanto na Costa Rica, Panamá e República Dominicana as leis não especificam tais restrições.

## Marcos regulatórios em matéria de IA

O segundo dos marcos regulatórios considerados é o da IA na região.<sup>203</sup> Em particular, é apresentada uma análise dos desenvolvimentos que os países implementaram nas normas ou diretrizes de IA sobre aspectos éticos, proteção de dados, transparência, bem como políticas ou normas específicas de IA. O **Quadro 2** apresenta os resultados da análise para os nove países onde foram identificados desenvolvimentos específicos nas normas ou diretrizes de IA. A existência de tais normas ou diretrizes é prova do nível de esforço na procura de um equilíbrio entre a inovação que a IA traz e os

203 Revisão própria com base em Accessnow (2024), OCDE-CAF (2022) e TMG (2020).

potenciais riscos que lhe estão associados (IAPP Research and Insights, 2024).

Como pode se verificar, em seis dos nove países selecionados, foram identificadas normas ou orientações relacionadas com aspectos éticos da IA. É o caso da Argentina, do Chile, da Colômbia, da Costa Rica, do México e do Peru. Em cada um desses países existem diretrizes ou normas centradas nos aspectos éticos. Existem também documentos dedicados a aspectos éticos, como a *Formulação ética de projetos de ciência de dados no Chile* e o *Quadro ético para a IA* na Colômbia, bem como um documento produzido por agências públicas, o INTEL e o BID sobre a importância de ter diretrizes éticas na IA na Costa Rica, e um decreto com uma seção sobre a utilização ética da IA no Peru. Outros guias têm seções sobre elementos éticos a considerar, propostas éticas ou requisitos éticos para concursos em países como a Argentina, o Chile, a Colômbia e o México.

Além disso, em seis países, foram identificadas regras ou orientações específicas de proteção de dados para soluções de IA, que são adicionais às mencionadas nos marcos regulatórios para a proteção de dados na IA (**Quadro 1**). Os países com tais documentos são: Argentina, Brasil, Chile,

Colômbia, México e Uruguai. No caso da Argentina, do Brasil, do Chile e do México, esses documentos são anexos a uma norma, seções específicas com orientações e sugestões dentro de documentos oficiais ou publicações das entidades responsáveis. Outros tipos de documentos emitidos por países como o Brasil, a Colômbia, o México e o Uruguai incluem processos participativos, documentos produzidos pela sociedade civil e *sandboxes* associados à proteção de dados.

Por outro lado, os padrões ou diretrizes de transparência para soluções de IA foram identificados em três países da região: Argentina, Chile e Colômbia. Nesses casos, somente na Argentina foi encontrado um documento específico para o programa de transparência, enquanto no Chile esses guias fazem parte das diretrizes gerais, e na Colômbia a referência aos aspectos de transparência faz parte de uma seção de um roteiro de IA.

Por fim, foi identificada a existência de políticas ou regulamentações específicas de IA em oito países da região. Especificamente, no Brasil, Chile e Peru, as estratégias de IA foram elevadas ao nível de regulamentação – uma portaria no Brasil, um decreto no Chile e uma lei no Peru – enquanto nos outros países, essas estratégias e roteiros estão contidos em documentos de políticas.

**Quadro 2.** Marcos regulatórios da IA na América Latina

País	Normas ou orientações sobre soluções de IA nos seguintes domínios			
	Aspectos éticos	Proteção de dados	Transparência	Políticas ou normas específicas da IA
<b>Argentina</b>	<i>Recomendaciones para una IA confiable</i> (Gabinete do Chefe de Gabinete e Secretariado para a Inovação Pública, 2023)	<i>Programa para a transparência e proteção dos dados pessoais na utilização da IA - anexo à Resolução</i> (Agência de Acesso à Informação Pública, 2023)		<i>Plano Nacional de Inteligência Artificial</i> (Presidência da Nação, 2019)
<b>Brazil</b>	ND	<i>Análise preliminar do projeto de Lei 2338</i> (ANDP, <sup>1</sup> 2023) <hr/> <i>Consulta pública sobre a caixa de areia regulamentar da AI</i> (ANDP <sup>1</sup> e CAF, 2023) <sup>1</sup>	ND	<i>Estratégia nacional de AI</i> (Portaria, 2021)
<b>Chile</b>	<i>Formulação ética de projetos de ciência de dados</i> (Divisão de Governo Digital do Chile, Universidade Adolfo Ibáñez e Laboratório do BID, 2022). <hr/> <i>Bases Tipo de concurso para projetos de IA com requisitos éticos</i> (Dirección de Compras y Contratación Pública - ChileCompra, 2023).	<i>Orientações para a utilização de ferramentas de IA no setor público</i> (Ministério Secretariado da Presidência e Ministério da Ciência, Tecnologia, Conhecimento e Inovação, 2023).		<i>Política nacional de IA</i> (Decreto, 2021)

País	Normas ou orientações sobre soluções de IA nos seguintes domínios			
	Aspectos éticos	Proteção de dados	Transparência	Políticas ou normas específicas da IA
<b>Colômbia</b>	<p><i>Quadro ético para a IA</i> (Governo da Colômbia, CAF e BID, 2021)</p> <p><i>Roteiro de desenvolvimento e implementação da IA</i> (Minciências, 2024)</p>	<p><i>Privacidade em projetos de IA</i> (SIC<sup>2</sup>, Governo da Colômbia e Conselho Consultivo Presidencial para Assuntos Econômicos e Transformação Digital, 2020).</p>	<p><i>Roteiro de desenvolvimento e implementação da IA</i> (Minciências, 2024)</p>	<p><i>Política nacional para a transformação digital e inteligência artificial</i>–Documento CONPES (DNP, 2019)</p>
<b>Costa Rica</b>	<p><i>Apoio à utilização responsável e ética da IA</i> (MICITT, CINDE, BID e INTEL, 2021)</p>	ND	ND	ND
<b>México</b>	<p><i>Iniciativa para a regulamentação da ética IA PAN - em curso</i> (Inácio de Loyola, 2023)</p> <p><i>Agenda Nacional Mexicana para a Inteligência</i> (Coligação IA2030MX, 2020)</p>	<p><i>Recomendações para o tratamento de dados pessoais Utilização da AI</i> (INAI<sup>3</sup>, 2022)</p>	ND	<p><i>Estratégia IA-MX</i> (Coordenação da Estratégia Nacional para o Digital, 2018).</p>

País	Normas ou orientações sobre soluções de IA nos seguintes domínios			
	Aspectos éticos	Proteção de dados	Transparência	Políticas ou normas específicas da IA
Peru	<i>Estratégia nacional de IA</i> (Ministério do Governo e da Transformação Digital e Presidência do Conselho de Ministros, 2021)	ND	ND	<i>Lei que promove a utilização da IA para o desenvolvimento</i> (Lei, 2023)
	<i>Quadro de Confiança Digital - Utilização ética das tecnologias e dos</i> (Decreto, 2020)			
República Dominicana	ND	ND	ND	<i>Estratégia Nacional de IA</i> (OGTIC, Direção Executiva do Gabinete de Inovação e Desenvolvimento Digital, 2023)
Uruguai	ND	<i>Estratégias de IA e de dados - participação do público no processo</i> (AGESIC, CAF e UNESCO, 2023-2024)	ND	<i>Estratégia de IA para a administração pública digital</i> (AGESIC, Presidência, 2019)

Fonte: Accessnow (2024), OCDE-CAF (2022), & TMG (2020).

Nota: Não inclui projetos de legislação.

<sup>1</sup> ANDP: Autoridade Nacional de Proteção de Dados do Brasil.

<sup>2</sup> SIC: Superintendencia de Industria y Comercio de Colombia.

<sup>3</sup> INAI: Instituto Nacional Mexicano para a Transparência, o Acesso à Informação e a Proteção dos Dados Pessoais.

## Recomendações políticas

Os formuladores de políticas da ALC têm um papel significativo a desempenhar na consolidação de estruturas políticas e regulatórias que permitam e promovam a adoção da IA nos setores de infraestrutura. A seguir, são apresentadas cinco linhas de ações principais nas quais os governos da região podem avançar na consolidação dessas estruturas facilitadoras. Essas linhas de ação baseiam-se na revisão de experiências internacionais, em entrevistas com especialistas no desenvolvimento e implementação desse tipo de soluções e na revisão comparativa dos marcos regulatórios de IA na ALC, cujos principais resultados são apresentados no Anexo.

### Estruturas regulatórias modernas, eficientes e estáveis para dados e IA

As estruturas regulatórias dos países em matéria de proteção de dados e IA configuram ambientes políticos que podem permitir ou inibir o desenvolvimento e a adoção dessa tecnologia em setores econômicos, incluindo o setor de infraestruturas. Em termos gerais, essas estruturas configuram-se como facilitadores quando promovem simultaneamente a consecução de objetivos políticos diferentes e aparentemente contraditórios, como a privacidade

e a segurança de informações sensíveis e o avanço da inovação tecnológica como fator de competitividade, produtividade e transformação digital. Estruturas regulamentares robustas permitem atingir equilíbrios em que estes dois objetivos podem ser atingidos simultaneamente e, desse modo, induzindo assim as sociedades a caminharem em direção a estados de bem-estar social aprimorados.

No caso dos regimes de proteção de dados, que existem na maioria dos países da região, é importante que os países avancem na modernização desses regimes sem incorporar restrições adicionais ao tratamento de dados que não sejam apoiadas por provas, bem como requisitos de localização de dados, além dos casos sensíveis ou de segurança nacional, que podem criar obstáculos à adoção de serviços em nuvem para o desenvolvimento e implementação de soluções de IA em setores econômicos, incluindo infraestruturas.

Da mesma forma, na medida em que a adoção generalizada da IA nos setores econômicos é um fenômeno relativamente recente, os governos devem desenvolver espaços de aprendizagem e experimentação sobre as implicações regulamentares dessa adoção, antes de definir quadros legislativos ou marcos regulatórios específicos e rígidos que possam incorporar barreiras a essa implantação. Nesse

sentido, uma abordagem inicial de *soft law* baseada na formulação de diretrizes e orientações para a implementação responsável dessa tecnologia é uma boa prática, tal como a maioria dos países da região implementou. Outra prática a ser considerada é a implementação de sandboxes regulatórios para adoção de IA — como foi feito em vários casos internacionais para o setor financeiro — em setores altamente regulamentados, incluindo alguns em infraestrutura.

### Quadros regulamentares setoriais que permitem a inovação

Na mesma linha, para avançar na adoção da IA em setores de infraestrutura, é aconselhável que os marcos regulatórios setoriais desses setores não incorporem elementos que possam restringir ou desestimular a inovação voltada para objetivos como o avanço da eficiência e da produtividade, ou a incorporação de novos modelos de negócios. Por exemplo, nos setores em que estão presentes serviços de utilidade pública (energia, água e saneamento), a rigidez da regulamentação tarifária pode gerar desincentivos à implementação de iniciativas destinadas a reduzir custos. No setor de transportes, a regulamentação tradicional pode criar barreiras à incorporação de novas modalidades de serviços, como aquelas baseadas em plataformas tecnológicas. Nesse sentido, aconselha-se aos formuladores de políticas

públicas desses setores a consolidação de quadros políticos flexíveis que reconheçam a inovação tecnológica como um fator de desenvolvimento setorial.

### Políticas eficazes para o desenvolvimento do capital humano e das capacidades setoriais

Conforme observado ao longo do documento, a capacitação é um fator essencial na adoção da IA nos setores de infraestrutura da região. Por um lado, algumas organizações em setores tradicionais, como transporte ou água e saneamento, tradicionalmente adotam inovações tecnológicas tardiamente, de modo que a implementação de soluções baseadas em IA impõe desafios de capacidade cultural e técnica para o desenvolvimento e a implementação desses tipos de soluções. Por outro lado, organizações nos setores de infraestrutura geralmente precisarão de novas capacidades, conjuntos de habilidades e mudanças culturais para abraçar e aproveitar as oportunidades oferecidas por uma tecnologia emergente recentemente adotada e amplamente utilizada, como a IA. Nesse sentido, é de vital importância que os governos implementem políticas eficazes de desenvolvimento de capital humano e capacidade que contribuam para fechar as lacunas na adoção dessa tecnologia pelos países. Para tanto, o apoio ao ensino

superior, a colaboração público-privada na capacitação e os programas nacionais de preparação da força de trabalho para a adoção da IA podem ter um impacto significativo nesses setores.

### Promoção de ecossistemas de inovação tecnológica

A adoção de IA em setores econômicos como infraestrutura também é impulsionada por ecossistemas locais de inovação tecnológica, compostos por diversos atores, como empreendedores, empresas de tecnologia, setor privado, academia e governo, e suas inter-relações, que aceleram a dinâmica de inovação que impulsiona o desenvolvimento de soluções tecnológicas baseadas em IA para esses setores. Os governos têm um papel relevante na promoção desses ecossistemas, definindo e implementando políticas públicas que abordem os determinantes de seu desenvolvimento, incluindo regulamentação, financiamento, capital humano, infraestrutura tecnológica e comércio, entre outros.

Além disso, o Estado desempenha um papel propulsor da inovação tecnológica como comprador de tecnologia, por meio da implementação de novas modalidades de compras públicas, como programas inovadores de compras públicas. Esses programas também podem ser estendidos

às empresas de serviços públicos (concessionárias de serviços públicos) com participação de capital estatal.

### Comunicação de oportunidades, melhores práticas e histórias de sucesso

Por fim, os governos da região estão promovendo a adoção de IA em setores, incluindo infraestrutura, por meio de políticas e iniciativas que comunicam e informam as partes interessadas econômicas sobre as oportunidades de aumento da produtividade, competitividade e bem-estar por meio da adoção de IA, bem como sobre as melhores práticas e histórias de sucesso em seus países e internacionalmente. Da mesma forma, a existência de marcos regulatórios modernos para a segurança digital e diretrizes sobre o uso responsável da IA e aspectos éticos relacionados podem contribuir para fortalecer a confiança desses atores e cidadãos no uso e adoção dessa tecnologia.

## Anexo 2.

# Metodologia das entrevistas

Tipo de entrevistas	Objetivo e âmbito de aplicação	Duração	Médio	Perfil dos entrevistados	Número de entrevistas	Data das entrevistas
Semiestruturada. <sup>204</sup> Foi seguido o <i>Guia de Entrevista</i> apresentado a seguir. Perguntas adicionais também foram feitas de acordo com as particularidades de cada entrevista e o perfil de cada entrevistado.	Conhecer a perspectiva dos entrevistados sobre o potencial da IA para os setores de infraestrutura, e as principais considerações e recomendações para a adoção bem-sucedida dessa tecnologia nesses setores na ALC. Além disso, conhecer as lições aprendidas com a experiência dos entrevistados em casos específicos de desenvolvimento dessas soluções.	30 - 60 minutos	Virtual com a presença de funcionários do BID.	Membros das equipes técnicas do BID, clientes e partes interessadas externas com experiência no desenvolvimento e implementação de tecnologias emergentes e soluções de IA.	17	Março e abril de 2024

204 Longhurst, R. (2003). "Entrevistas semiestruturadas e grupos de discussão. *Key Methods in Geography*.

## Guia de entrevista

**Informações sobre o caso em análise**

- Qual é o problema/necessidade que a solução procura resolver e como foi o processo de compreensão e diagnóstico desse problema/necessidade?
- Em que consiste a solução implementada e quais são os seus principais objetivos e características?
- Que tipo de modelo(s) de IA foi(foram) implementado(s) no desenvolvimento da solução e com que tipo de dados? Como foram tomadas as decisões sobre a escolha do(s) modelo(s) e dos dados a utilizar?
- Que vantagens/desvantagens gostaria de salientar do modelo de IA utilizado em termos dos seus atributos (por exemplo, usabilidade, escalabilidade, testabilidade, interpretabilidade, adaptabilidade, exatidão/desempenho, segurança)?
- Descreva sucintamente o processo de desenvolvimento e implementação da solução.
- Que intervenientes internos e externos do BID estiveram envolvidos no desenvolvimento e na implementação da solução e como foi a interação com eles?
- Quais os progressos ou resultados alcançados até à data na aplicação desta solução? Qual o nível de apropriação da solução por parte dos beneficiários?
- Quais os desafios ou dificuldades que a equipe encontrou no desenvolvimento e implementação da solução e como os abordou/resolveu?
- Quais são as principais lições aprendidas com o desenvolvimento e a implementação desta solução, que poderiam ser úteis para reforçar os processos de desenvolvimento e implementação de soluções de IA neste setor no futuro?

**Compreender o potencial da IA nas infraestruturas**

- Na sua opinião, quais são as principais oportunidades e vantagens que a adoção da IA pode trazer para os setores de infraestrutura na ALC?
- Além da solução acima referida, você tem conhecimento de outros desenvolvimentos ou soluções de IA no setor (transportes, energia, água ou saneamento) a nível mundial ou na ALC que tenham um elevado potencial?

## Guia de entrevista

**Considerações sobre a adoção da IA nas infraestruturas**

- Com base na sua experiência, quais são os principais fatores de sucesso para o desenvolvimento e a adoção de soluções de IA no setor (Transportes, Energia, Água ou Saneamento) na ALC?
- Com base na sua experiência, quais são as principais partes interessadas que devem ser consideradas no desenvolvimento e adoção de soluções de IA no setor (Transportes, Energia, Água ou Saneamento) na ALC, e como devem ser efetivamente envolvidas nestes processos?

Perguntas adicionais facultativas:

- Com base na sua experiência, quais são as principais considerações éticas que devem ser mantidas para o desenvolvimento e a adoção de soluções de IA no setor (transportes, energia, água ou saneamento) na ALC?
- Com base na sua experiência, quais são as principais considerações legais, regulamentares ou institucionais que devem ser mantidas para o desenvolvimento e a adoção de soluções de IA no setor (transportes, energia, água ou saneamento) na ALC?
- Com base na sua experiência, quais são as principais considerações técnicas, de processamento de dados e de segurança que devem ser mantidas para o desenvolvimento e a adoção de soluções de IA no setor (transportes, energia, água ou saneamento) na ALC?
- Com base na sua experiência, quais são as principais considerações em matéria de reforço das capacidades que devem ser mantidas para o desenvolvimento e a adoção de soluções de IA no setor (transportes, energia, água ou saneamento) na ALC?

**Recomendações para os decisores políticos**

- Quais você considera serem os principais gargalos que os países da ALC devem abordar para o desenvolvimento e a implementação bem-sucedidos de projetos de IA em setores de infraestrutura?
- Quais são as principais recomendações que faria aos decisores políticos da região para promover o desenvolvimento e a implementação bem-sucedidos de projetos de IA nos setores de infraestrutura?

## Referências

- Abdalla, A. N., Nazir, M. S., Tao, H., Cao, S., Ji, R., Jiang, M., & Yao, L. (2021). Integração do sistema de armazenamento de energia e fontes de energia renováveis com base na inteligência artificial: uma visão geral. *Journal of Energy Storage*, 40, 102811. <https://doi.org/10.1016/j.est.2021.102811>
- Accessnow (2024). Radiografia regulatória: onde, o que e como a inteligência artificial está sendo regulada na América Latina.
- Ahmad, T., Zhu, H., Zhang, D., Tariq, R., Bassam, A., Ullah, F., AlGhamdi, A. S., & Alshamrani, S. S. (2022). Sistemas Energéticos e inteligência artificial: Aplicações da indústria 4.0. *Energy Reports*, 8, 334-361. <https://doi.org/10.1016/j.egy.2021.11.256>
- Alarcón, A. (2018). Perdas elétricas: três tendências tecnológicas que podem ajudar a resolver o problema. Blogs do BID. Disponível em: <https://blogs.iadb.org/energia/es/perdidas-electricas-tres-tendencias-tecnologicas-que-pueden-ayudar-a-resolver-el-problema/>
- Alvarez, O., Díaz Echeverría, A., Pérez, N.A., Sánchez Campos, A., & Bordiu Garcia-Ovies, C. Roteiro para a transformação digital do setor da energia na América Latina e no Caribe. Nota técnica IDB-TN-02833. Banco Interamericano de Desenvolvimento (BID). <http://dx.doi.org/10.18235/0005215>
- Arch, A., Cortijo, R., Romero, E., Canga, E., Furrer, P., Woodhouse, S., Dulle, H., & Koller, T. (2020). A revolução digital da energia hidrelétrica nos países da América Latina. Nota técnica nº IDB-TN-01761. Banco Interamericano de Desenvolvimento (BID). <http://dx.doi.org/10.18235/0001989>
- Assembleia Nacional da República do Equador (2022). Lei Orgânica para o desenvolvimento, regulação e controle dos serviços financeiros tecnológicos (Lei Fintech).
- Ávalos, R. S., González, F., & Ortiz, T. (2021). Uso responsável da IA para políticas públicas: Manual de ciência de dados. Publicações do BID. <https://doi.org/10.18235/0002876>
- Banco Mundial (2020). *Inteligência Artificial no Setor Público*. <https://documents1.worldbank.org/curated/en/746721616045333426/pdf/Artificial-Intelligence-in-the-Public-Setor-Summary-Note.pdf>
- Baker McKenzie (2024). Global Data Privacy and Cybersecurity Handbook (Atualizado entre dezembro de 2023 e janeiro de 2024). <https://resourcehub.bakermckenzie.com/en/resources/global-data-privacy-and-cybersecurity-handbook/comparison?j=1dd6a01b-0da5-46a1-b9a1-59a294a80f85&n=Global+Data+Privacy+and+Cybersecurity+Handbook>
- Banerjee, S., Kabir, Md. M., Khadem, N. K., & Chavis, C. (2020). Localizações ideais para estações de bikeshare: uma nova abordagem espacial baseada em GIS. *Transportation Research Interdisciplinary Perspectives*, 4, 100101. <https://doi.org/10.1016/j.trip.2020.100101>. <https://doi.org/10.1016/j.trip.2020.100101>
- Barrero, V., & Bou, O. (2020). Preparação para a segurança cibernética no setor elétrico na América Latina: Diagnóstico, recomendações e guia de boas práticas. Banco Interamericano de Desenvolvimento (BID). <http://dx.doi.org/10.18235/0002344>
- Basani, M. (2023). O poder do ChatGPT para desenvolver políticas públicas inovadoras. Blogues do BID. Disponível em: <https://blogs.iadb.org/agua/es/aprovechar-el-poder-de-chatgpt-para-elaborar-politicas-publicas-innovadoras/>
- Basani, M. (2023). Tecnologias inteligentes de resíduos sólidos: Onde estamos e para onde vamos? Blogues do BID. Disponível em: <https://blogs.iadb.org/agua/es/tecnologias-inteligentes-de-residuos-solidos-donde-estamos-y-hacia-donde-vamos/>
- Bedi, J., & Toshniwal, D. (2019). Estrutura de aprendizagem profunda para prever a demanda de eletricidade. *Applied Energy*, 238, 1312-1326. <https://doi.org/10.1016/j.apenergy.2019.01.113>
- Bengio, Y., LeCun, Y., & Hinton G. (2021). Aprendizagem profunda para IA. *Communications of the ACM*, 64(7), 58-65. <http://dx.doi.org/10.1145/3448250>
- Código de Desenvolvimento do BID (n.d.). Trampas Barceló. <https://code>
- IDB (2021). Laura Robot Algorithmic Audit: Estudo sobre o sistema Laura para prever o risco de deterioração clínica. Banco Interamericano de Desenvolvimento (BID). <http://dx.doi.org/10.18235/0003919>
- BID (2024). Transformação digital da gestão de resíduos sólidos: inovação na recolha de resíduos, inteligência empresarial e tecnologias digitais para a transição da gestão de resíduos para a circularidade na América Latina e no Caribe.
- BID para a ALC. Acuadata. Recuperado de: <<https://fairlac.iadb.org/piloto/acuadata>>. Entrevistas com funcionários da EPMAPS e do BID.
- BID para a ALC. Pavimenta2. Obtido de: <<https://fairlac.iadb.org/piloto/pavimenta2>>
- BID para a ALC. Víasegura <<https://fairlac.iadb.org/piloto/viasegura>>
- BID. (2022, 17 de março). VíaSegura: soluções digitais para a segurança viária. [Vídeo]. YouTube. <https://www.youtube.com/watch?v=zTKE1yqwriI>
- BID. (2023, 28 de abril). VíaSegura: Tecnologia para salvar vidas [Vídeo]. YouTube. <https://www.youtube.com/watch?v=pUnPVxPqhY4>
- BID. (2023, 18 de agosto). Pavimenta2: a última tecnologia para estradas na América Latina e no Caribe [Vídeo]. YouTube. <https://www.youtube.com/watch?v=cuOw4OPIKgl>
- BID. (2023, fevereiro 24). Webinar Inteligência Artificial para criar e disseminar Políticas Públicas [Vídeo]. YouTube. <https://www.youtube.com/watch?v=zB1P9p9pR00> (40:21, 46:17 e 50:28).
- BID. Energizados, uma ferramenta para automatizar a detecção de fraudes elétricas. <https://blogs.iadb.org/energia/es/energizados-la-deteccion-de-fraudes-electricos/>
- BID. Energizado. <<https://fairlac.iadb.org/piloto/energizados>>

29. BID. Pavimenta2: Acelerando a transformação digital do setor de transporte na América Latina e no Caribe (2022, setembro). Recuperado de: <<https://blogs.iadb.org/transporte/es/pavimentados-acelerando-la-transformacion-digital-del-sector-transporte-en-america-latina-y-el-caribe/>>
30. BID. Pavimenta2: infraestruturas digitais ao serviço do património rodoviário (2023, agosto). Recuperado de: <<https://blogs.iadb.org/transporte/es/pavimenta2-infraestructura-digital-al-servicio-de-los-ativos-viales/>>
31. LICITAÇÃO. Pavimentado. Obtido de: <<https://code.iadb.org/es/herramientas/pavimentados>>
32. BID. ViaSegura - Sumário Executivo. <[https://resources.irap.org/Key-documents/Resumen\\_ejecutivo\\_VíaSegura.pdf?\\_gl=1\\*19gnjtl\\*\\_ga\\*MTA2Njc3NDI5MC4xNzEwODY3Mjc1\\*\\_ga\\_HK6PSM29PR\\*MTcxMDg2NzI3NC4xLjEuMTcxMDg2NzZmNS4wLjAuMA....](https://resources.irap.org/Key-documents/Resumen_ejecutivo_VíaSegura.pdf?_gl=1*19gnjtl*_ga*MTA2Njc3NDI5MC4xNzEwODY3Mjc1*_ga_HK6PSM29PR*MTcxMDg2NzI3NC4xLjEuMTcxMDg2NzZmNS4wLjAuMA....)>
33. BID. Viasegura <<https://code.iadb.org/es/herramientas/viasegura>>
34. BID. ViaSegura: Inteligência Artificial aplicada para melhorar a segurança rodoviária - Brochura <[https://resources.irap.org/Key-documents/VíaSegura\\_iRAP.pdf?\\_gl=1\\*19gnjtl\\*\\_ga\\*MTA2Njc3NDI5MC4xNzEwODY3Mjc1\\*\\_ga\\_HK6PSM29PR\\*MTcxMDg2NzI3NC4xLjEuMTcxMDg2NzZmNS4wLjAuMA..](https://resources.irap.org/Key-documents/VíaSegura_iRAP.pdf?_gl=1*19gnjtl*_ga*MTA2Njc3NDI5MC4xNzEwODY3Mjc1*_ga_HK6PSM29PR*MTcxMDg2NzI3NC4xLjEuMTcxMDg2NzZmNS4wLjAuMA..)>
35. Boukerche, A., Tao, Y., & Sun, P. (2020). Métodos de previsão do fluxo de tráfego veicular baseados em inteligência artificial para apoiar sistemas de transporte inteligentes. *Computer Networks*, 182, 107484. <https://doi.org/10.1016/j.comnet.2020.107484>
36. Bowles, C., Chen, L., Guerrero, R., Bentley, P., Gunn, R., Hammers, A., Dickie, D. A., Hernández, M. V., Wardlaw, J., & Rueckert, D. (2018). Aumento de GAN: Aumento de dados de treinamento usando redes adversárias generativas. <https://doi.org/10.48550/arXiv.1810.10863>
37. Brynjolfsson, E., Li, D., & Raymond, L. R. (2023). *IA generativa no trabalho* (Documento de trabalho 31161). National Bureau of Economic Research. <https://doi.org/10.3386/w31161>
38. Brzezinski, I. A. (2023). Integrando soluções inovadoras em serviços de água e saneamento: Lições de projetos-piloto de inovação na América Latina e no Caribe. *Publicações do BID*. <https://doi.org/10.18235/0005236>
39. Buda, M., Maki, A., & Mazurowski, M. A. (2018). Um estudo sistemático do problema de desequilíbrio de classe em redes neurais convolucionais. *Redes Neurais*, 106, 249-259. <https://doi.org/10.1016/j.neunet.2018.07.011>.
40. Calatayud, A., Benítez, C., Leaño, J.M., Agosta, R., Blas, F., Goytia, C., Guilera, S., Riobó Patino, A., Navas Duk, C., Freytes, C., & Rodríguez Tourón, F. (2020). Veículos Autônomos: Uma revisão da literatura sobre o seu impacto na mobilidade nas cidades da região. Nota Técnica BID-TN-1929. Banco Interamericano de Desenvolvimento (BID). <http://dx>.
41. Calatayud, A., Benítez, C., Leaño, J.M., Agosta, R., Blas, F., Goytia, C., Guilera, S., Riobó Patino, A., Navas Duk, C., Freytes, C., & Rodríguez Tourón, F. (2020). Veículos autônomos: resultados da pesquisa Delphi sobre seu impacto e adoção em cidades da América Latina e do Caribe. Nota Técnica BID-TN-1930. Banco Interamericano de Desenvolvimento (BID). <http://dx>.
42. Calatayud, A., Katz, R. (2019). Supply Chain 4.0: Melhores práticas internacionais e roteiro para a América Latina. Banco Interamericano de Desenvolvimento (BID). <http://dx.doi.org/10.18235/0001956>
43. Calatayud, A., Katz, R., & Riobó, A. (2022). Impulsionando a transformação digital do transporte na América Latina e no Caribe. *Publicações do BID*. <https://doi.org/10.18235/0004233>
44. Calatayud A., Riobó A., Irigoyen J., Basani M., Unzueta A., Katz R. (2022). *Estratégia de transformação digital para o setor de infraestrutura e energia 2021-2025*. Documento de discussão nº IDB-DP-00935. Banco Interamericano de Desenvolvimento (BID).
45. Calatayud A., Rivas M., Camacho J., Beltrán C., Ansaldo M., Café E. (2023). Transporte 2050: O caminho para a descarbonização e a resiliência climática na América Latina e no Caribe. Banco Interamericano de Desenvolvimento.
46. Calatayud, A., Sánchez González, S., Bedoya Maya, F., Giraldez Zúñiga, F., & Márquez, J. M. (2021). *Congestionamento urbano na América Latina e no Caribe: Características, custos e mitigação*. Banco Interamericano de Desenvolvimento. <https://doi.org/10.18235/0003149>
47. Castelli, M., Groznik, A., & Popovič, A. (2020). Previsão dos preços da eletricidade: uma abordagem de aprendizado de máquina. *Algorithms*, 13(5), 119. <https://doi.org/10.3390/a13050119>
48. Centro Digital LATAM (2022). Perspectivas de Política de Concorrência e Proteção de Dados Pessoais para a América Latina.
49. Cevallos, A., Latorre, L., Alicandro, G., Wanner, Z., Cerrato, I., Zarate, J. D., Alvarez, J., Villacreses, K., Pfeifer, M., Gutierrez, M., Villanueva, V., Rivera-Fournier, A., Riobó, A., Pombo, C., Puerto, F., & Rodríguez Breuning, J. (2023). Relatório técnico: IA generativa. *Publicações do BID*. <https://doi.org/10.18235/0005105>
50. Chan, W. C., Wan Ibrahim, W. H., Lo, M. C., Suaidi, M. K., & Ha, S. T. (2020). Sustentabilidade do transporte público: um exame do comportamento do usuário para o aplicativo de rastreamento GPS em tempo real. *Sustainability*, 12(22), 9541. <https://doi.org/10.3390/su12229541>
51. Chen, H., Chen, A., Xu, L., Xie, H., Qiao, H., Lin, Q., & Cai, K. (2020). Uma arquitetura CNN de aprendizado profundo aplicada na análise inteligente de infravermelho próximo da poluição da água para recursos de irrigação agrícola. *Agricultural Water Management*, 240, 106303. <https://doi.org/10.1016/j.agwat.2020.106303>
52. Chen, P., Wang, B., Wu, Y., Wang, Q., Huang, Z., & Wang, C. (2023). Monitoramento da qualidade da água do rio urbano com base no método de aprendizado de máquina auto-otimizado usando dados de sensoriamento remoto de várias fontes. *Ecological Indicators*, 146, 109750. <https://doi.org/10.1016/j.ecolind.2022.109750>
53. Chung S., Zhang Y. (2023). Aplicações de Inteligência Artificial em Sistemas de Distribuição Elétrica: Progresso e Perspectiva Pós-Pandemia. *Appl. Sci.* 2023, 13(12), 6937.

54. Comissão Econômica para a América Latina e o Caribe - CEPAL (2011). Caracterização do déficit de infraestruturas econômicas na América Latina e no Caribe.
55. Comissão Europeia (2012). Proposta de Regulamento do Parlamento Europeu e do Conselho relativo à proteção das pessoas singulares no que diz respeito ao tratamento de dados pessoais e à livre circulação desses dados (Regulamento Geral sobre a Proteção de Dados). <https://eur-lex.europa.eu/LexUriServ/LexUriServ.do?uri=COM:2012:0011:FIN:ES:PDF>
56. Gabinete de Assessoria Presidencial para os Assuntos Econômicos e a Transformação Digital (2020). *Projetos, procedimentos e serviços de transformação digital para os cidadãos*.
57. Daigger G.T., Voutchkov, N., Lall U., & Sarni, W. (2019). O Futuro da Água: Uma coleção de ensaios sobre tecnologias «disruptivas» que podem transformar o setor da água nos próximos 10 anos. Documento de discussão nº IDB-DP-657. Banco Interamericano de Desenvolvimento (BID). <http://dx.doi.org/10.18235/0001666>
58. Del Real, A. J., Dorado, F., & Durán, J. (2020). Previsão da demanda de energia usando aprendizado profundo: aplicações para a rede francesa. *Energies*, 13(9), 2242. <https://doi.org/10.3390/en13092242>
59. Deloitte (2023). A IA no mundo - Estudo de caso: O gêmeo digital dá a San Diego opções para resolver o congestionamento do tráfego. <https://www2.deloitte.com/us/en/insights/industry/public-sector/global-government-ai-case-studies.html/%20-%20digital-twin-gives-san-diego.html/#digital-twin-gives-san-diego>
60. Deloitte (2023). A IA no mundo - Estudo de caso: O chatbot da Autoridade da Água e Eletricidade do Dubai responde a questões de clientes em muitas plataformas. <https://www2.deloitte.com/us/en/insights/industry/public-sector/global-government-ai-case-studies.html/#transport-canada-uses-ai-to>
61. Deloitte (2023). A IA no mundo - Estudo de caso: Transport Canada utiliza a IA para identificar cargas de risco. <https://www2.deloitte.com/content/dam/Deloitte/us/Documents/deloitte-analytics/us-ai-institute-ai-dossier-full-report.pdf>
62. Deloitte (2023). A IA no mundo - Estudo de caso: as cidades dos EUA utilizam a análise para distribuir os limpa-neves e os caminhões do lixo de forma eficiente. <https://www2.deloitte.com/us/en/insights/industry/public-sector/global-government-ai-case-studies.html/#us-cities-use-analytics-to>
63. Instituto de IA da Deloitte (2023). The AI Dossier. <https://www2.deloitte.com/content/dam/Deloitte/us/Documents/deloitte-analytics/us-ai-institute-ai-dossier-full-report.pdf>
64. Deloitte - Instituto de IA (2021). O Dossiê IA.
65. Desai, R., Jadhav, A., Sawant, S., & Thakur, N. (2021). *Deteção de acidentes usando técnicas de ML e IA*.
66. Dyba T., Dingsoyr (2009). O que sabemos sobre o desenvolvimento ágil de software? IEEE Software.
67. Engelhardt, S., McClelland, J. & Collet, S. (n.d.). O que a IA generativa pode fazer pelos serviços públicos. <https://www.sap.com/insights/viewpoints/what-generative-ai-can-do-for-utilities.html>
68. Centro Eno para os Transportes (2023). Compreender a IA e os transportes. <https://enotrans>.
69. EY (2023). Proteção de dados pessoais na América Latina - Guia de referência rápida.
70. Fan, M., Hu, J., Cao, R., Ruan, W., & Wei, X. (2018). Uma revisão sobre o projeto experimental para remoção de poluentes no tratamento de água com o auxílio da inteligência artificial. *Chemosphere*, 200, 330-343. <https://doi.org/10.1016/j.chemosphere.2018.02.111>
71. Féry, G. (2022). *The Digital Journey of Water and Sanitation Utilities in Latin America and The Caribbean: What is at Stake and How to Begin*. Documento de discussão nº IDB-DP-00972. Banco Interamericano de Desenvolvimento (BID).
72. Fórum Econômico Mundial - WEF (2012). *Infraestruturas estratégicas: passos para definir prioridades e fornecer infraestruturas de forma eficaz e eficiente*. Elaborado em colaboração com a PwC
73. Fuller, A., Fan, Z., Day, C., & Barlow, C. (2020). Gêmeo digital: tecnologias capacitadoras, desafios e pesquisa aberta. *IEEE Access*, 8, 108952-108971. *IEEE Access*. <https://doi.org/10.1109/ACCESS.2020.2998358>
74. Fundação Bunge y Born (2021). Deteção automatizada de lixões a céu aberto: Inteligência artificial, satélites e políticas públicas. [https://www.fundacionbyb.org/\\_files/ugd/2aae47\\_03757f467e384554b8d88ffd26c60af3.pdf](https://www.fundacionbyb.org/_files/ugd/2aae47_03757f467e384554b8d88ffd26c60af3.pdf)
75. Fundación Bunge y Born (n.d.). Detección De Basurales Y Microbasurales A Cielo Abierto. <https://www.fundacionbyb.org/basurales>
76. Galo, J., Di Martino, E., Velásquez Bermúdez, J. M., & Delgadillo Gomez, A. (2023). *Tecnologias de Inteligência Artificial (IA) na manutenção de ativos do setor elétrico*. Banco Interamericano de Desenvolvimento. <https://doi.org/10.18235/000490>
77. Gámiz E., Argelíj A. O futuro da analítica nas redes elétricas: gêmeos digitais. eSmartcity.es. Disponível em: <https://www.esmartcity.es/comunicaciones/comunicacion-futuro-analitica-redes-electricas-digital-twins>
78. García A., Iglesias E. (2018). *Computação em nuvem: oportunidades e desafios para o desenvolvimento econômico sustentável na América Latina e no Caribe*. Banco Interamericano de Desenvolvimento.
79. García De Soto, B., Bumbacher, A., Deublein, M., & Adey, B. T. (2018). Previsão de acidentes de trânsito rodoviário usando modelos de redes neurais artificiais. *Infrastructure Asset Management*, 5(4), 132-144. <https://doi.org/10.1680/j.inam.17.00028>.
80. Ghenai, C., Husein, L. A., Al Nahlawi, M., Hamid, A. K., & Bettayeb, M. (2022). Tendências recentes das tecnologias de gêmeos digitais no setor de energia: uma revisão abrangente. *Sustainable Energy Technologies and Assessments*, 54, 102837. <https://doi.org/10.1016/j.seta.2022.102837>

81. Giraldo, M.C., Ríos, C., Alarcón, A., Snyder, V., Echevarría, C., Riobo, A., Hallack, M. & Irigoyen, J.L. (2022). Energizado: os benefícios de uma ferramenta baseada em metodologias de aprendizado de máquina para facilitar a detecção de furto de energia elétrica. Nota técnica BID-TN-2444. Banco Interamericano de Desenvolvimento (BID). <http://dx.doi.org/10.18235/0004178>
82. Gomedede, E. Métricas de justiça na aprendizagem de máquinas (2023). Recuperado de <<https://medium.com/the-modern-scientist/fairness-metrics-in-machine-learning-8c3777b48a9c>>
83. Grady, S. A., Hussaini, M. Y., & Abdullah, M. M. (2005). Colocação de turbinas eólicas utilizando algoritmos genéticos. *Renewable Energy*, 30(2), 259-270. <https://doi.org/10.1016/j.renene.2004.05.007>
84. Granada, I., Pinto, A.M., & Castro, B. (2018). Pilotos de inovação em transportes públicos sem custos para os países? Sim, é possível. Blogues do BID. Disponível em: <https://blogs.iadb.org/transporte/es/innovacion-en-el-transporte-publico-sin-costo-alguno-para-los-paises-si-es-posible/>
85. Granata, F., Papirio, S., Esposito, G., Gargano, R., & De Marinis, G. (2017). Algoritmos de Aprendizagem de Máquina para a Previsão de Indicadores de Qualidade de Águas Residuais. *Água*, 9(2), 105. <https://doi.org/10.3390/w9020105>
86. Greyparrot AI (2024). Recuperado de: <https://www.greyparrot.ai/how-it-works>
87. Greyparrot AI (2024b). Recuperado de: <https://www.greyparrot.ai>
88. Greyparrot AI & CIMVI (Consórcio Intermunicipal do Médio Vale do Itajaí). Inteligência de resíduos Garantir que as embalagens nunca se tornem resíduos.
89. Gschwender, A., Munizaga, M., & Simonetti, C. (2016). Utilização de dados de cartões inteligentes e GPS para política e planejamento: O caso do Transantiago. *Research in Transportation Economics*, 59, 242-249. <https://doi.org/10.1016/j.retrec.2016.05.004>
90. Guerra, P. (2023). Inteligência Artificial: Rumo a uma economia circular e eficiência na gestão de resíduos. Blogues do BID. Disponível em: <https://blogs.iadb.org/agua/es/inteligencia-artificial-hacia-una-economia-circular-y-la-eficiencia-en-la-gestion-de-residuos/>
91. Guerra, P. (2023). A revolução digital chegou para transformar a forma como vemos e gerimos os nossos resíduos. Blogues do BID. Disponível em: <https://blogs.iadb.org/agua/es/innovacion-tecnologica-en-la-gestion-de-residuos-solidos-la-revolucion-digital-que-ha-llegado-para-transformar-el-modo-en-que-vemos-y-manejamos-nuestros-residuos/>
92. Guresen, E., & Kayakutlu, G. (2011). Definição de redes neurais artificiais em comparação com outras redes. *Procedia Computer Science*, 3, 426-433. <https://doi.org/10.1016/j.procs.2010.12.071>
93. Gutiérrez Puebla, J., Benítez, C., García Palomares, J. C., Romanillos Arroyo, G., Rubinstein, E., Leañó, J. M., Ribeiro, K. M., Scholl, L., Moya Gómez, B., & Condeço Melhorado, A. (2020). Como aplicar Big Data no planejamento de transportes: *O uso de dados GPS na análise da mobilidade urbana*. Banco Interamericano de Desenvolvimento. <https://doi.org/10.18235/0002487>
94. Gutiérrez Puebla, J., Benítez, C., Leañó, J. M., García Palomares, J.C., Melhorado, A., Mojica, C., Schnoll, L., Adler, V., Vera, F., Moya Gómez, B., Romanillos, G. (2019). *Como aplicar Big Data no planejamento dos transportes urbanos: A utilização de dados de telemóveis na análise da mobilidade*. Documento de discussão nº IDB-TN-1773. Banco Interamericano de Desenvolvimento (BID).
95. Gutiérrez, M.C., Pérez Jaramillo, D., & Riobó, A. (2019). Veículos autônomos: potencial e riscos para a América Latina e o Caribe. Banco Interamericano de Desenvolvimento (BID). <http://dx.doi.org/10.18235/0001686>
96. Halder, N. Decodificando o sucesso do aprendizado de máquina: avaliando métricas de desempenho com Python (2024). Recuperado de <<https://medium.com/gitconnected/decoding-machine-learning-success-evaluating-performance-metrics-with-python-2f98a452bbc4>>
97. Hammid, A. T., Sulaiman, M. H. B., & Abdalla, A. N. (2018). Previsão da produção de energia de pequenas centrais hidrelétricas na barragem do Lago Himreen (HLD) usando rede neural artificial. *Alexandria Engineering Journal*, 57(1), 211-221. <https://doi.org/10.1016/j.aej.2016.12.011>. <https://doi.org/10.1016/j.aej.2016.12.011>
98. Heidarpanah, M., Hooshyaripor, F., & Fazeli, M. (2023). Previsão diária do preço da eletricidade utilizando modelos de inteligência artificial no mercado iraniano da eletricidade. *Energia*, 263, 126011. <https://doi.org/10.1016/j.energy.2022.126011>
99. Heymann F., Quest H., Lopez Garcia T., Ballif C., Galus M. (2024). Revisão de 40 anos de inteligência artificial aplicada a sistemas de energia - Uma perspectiva taxonômica. *Energia e IA 15 (2024) 101322*.
100. Hermosilla, M., Alarcón, N. G., Pombo, C., Ávalos, R. S., Denis, G., & Aracena, C. (2021). Uso responsável da IA para políticas públicas: um manual para formulação de projetos. Publicações do BID. <https://doi.org/10.18235/0003631>
101. Hong J., Chu Z., & Wang Q. (2011). Transport infrastructure and regional economic growth: evidence from China. *Transportation* 38, 737-752.
102. Hsu, J.-Y., Wang, Y.-F., Lin, K.-C., Chen, M.-Y., & Hsu, J. H.-Y. (2020). Diagnóstico de falhas de turbinas eólicas e manutenção preditiva por meio de controle estatístico de processos e aprendizado de máquina. *IEEE Access*, 8, 23427-23439. <https://doi.org/10.1109/ACCESS.2020.2968615>
103. IAPP Research and Insights (2024). Global AI Law and Policy Tracker.
104. IEEE-USA (2017). Investigação, Desenvolvimento e Regulamentação da Inteligência Artificial. Declaração de posição do IEEE-USA.
105. Índice Latino-Americano de Inteligência Artificial (n.d). Índice Latino-Americano de Inteligência Artificial. <https://indicelatam>.
106. Infosys BPM. (2024). Casos de utilização alimentados por IA para o setor da energia e dos serviços públicos. <https://www.infosysbpm.com/blogs/energy-utilities/ai-powered-use-cases-energy-utilities-setor.html>

107. Fundo Monetário Internacional (FMI). (2016). Perspectivas econômicas regionais. Hemisfério Ocidental. Gerenciando Transições e Riscos. Capítulo 5: Infraestruturas na América Latina e no Caribe.
108. iRAP. ViaSegura. <<https://irap.org/es/rap-tools/light-ratings/viasegura/>>
109. Irigoyen J., Mayorga N. (2024). Infraestruturas críticas na América Latina e no Caribe: tecnologias revolucionárias. Blogs do BID. Disponível em: <https://blogs.iadb.org/energia/es/infraestructura-critica-en-america-latina-y-el-caribe-tecnologias-que-estan-cambiando-el-juego>
110. Irigoyen J., Tulande, N., & Daza, E. (2023). Inteligência artificial, facilitador para um setor competitivo. Blogues do BID. Disponível em: <https://blogs.iadb.org/energia/es/inteligencia-artificial-habilitador-para-un-sector-competitivo/>
111. IWA (2020). Água Digital: Soluções de Inteligência Artificial para o Setor da Água. <https://iwa-network>.
112. Jevinger, Å., Zhao, C., Persson, J. A., & Davidsson, P. (2024). Inteligência artificial para melhorar os transportes públicos: um estudo de mapeamento. *Public Transport*, 16(1), 99-158. <https://doi.org/10.1007/s12469-023-00334-7>
113. Jiwattanakupaisarn P., Noland R., & Graham D. (2012). Produtividade marginal da expansão da capacidade das auto-estradas. *Journal of Transport Economics and Policy*. 46 (3), 33-347.
114. Johannesen, N. J., Kolhe, M., & Goodwin, M. (2019). Avaliação relativa de ferramentas de regressão para previsão de demanda de energia elétrica em área urbana. *Journal of Cleaner Production*, 218, 555-564. <https://doi.org/10.1016/j.jclepro.2019.01.108>
115. Jordon, J., Szpruch, L., Houssiau, F., Bottarelli, M., Cherubin, G., Maple, C., Cohen, S. N., & Weller, A. (2022). Synthetic Data-What, why and how? (arXiv:2205.03257). arXiv. <http://arxiv.org/abs/2205.03257>
116. Kuhlmann, A., Mehlum, E., & Moore, J. (2021). Aproveitar a inteligência artificial para acelerar a transição energética. Fórum Econômico Mundial. [https://www3.weforum.org/docs/WEF\\_Harnessing\\_AI\\_to\\_accelerate\\_the\\_Energy\\_Transition\\_2021.pdf](https://www3.weforum.org/docs/WEF_Harnessing_AI_to_accelerate_the_Energy_Transition_2021.pdf)
117. Kumar, K., & Saini, R. (2021). Aplicação de Inteligência Artificial para a Otimização da Geração de Energia Hidrelétrica. *EAI Endorsed Transactions on Industrial Networks and Intelligent Systems*, 8(28), 170560. <https://doi.org/10.4108/eai.6-8-2021.170560>
118. Laplante, P., & Amaba, B. (2021). Inteligência Artificial em Sistemas de Infraestruturas Críticas. *Computador*, 54(10). <https://doi.org/10.1109/MC.2021.3055892>
119. Latorre, L., Rego, E., Leo, L. D., & Gutiérrez, M. (2024). Relatório tecnológico: Gêmeos digitais. Publicações do BID. <https://doi.org/10.18235/0013166>
120. Laubshtein, Y. (2023). Protegendo a infraestrutura de água e saneamento contra ameaças cibernéticas: um estudo de segurança cibernética para a América Latina e o Caribe. Banco Interamericano de Desenvolvimento (BID). <http://dx.doi.org/10.18235/0004876>
121. Lehe, L. (2019). Preços de congestionamento no centro da cidade na prática. *Transportation Research Part C: Emerging Technologies*, 100, 200-223. <https://doi.org/10.1016/j.trc.2019.01.020>
122. Lekidis, A., Anastasiadis, A. G., & Vokas, G. A. (2022). Inspeção de infraestrutura de eletricidade usando IA e UAVs baseados em plataforma de borda. *Energy Reports*, 8, 1394-1411. <https://doi.org/10.1016/j.egy.2022.07.115>
123. Levy, A., Yépez-García, A., Hallack, M., Snyder, V. e Ji, Y. (2018). Documento de enquadramento do setor da energia. BID
124. Li, F. (2023). The worlds I see: Curiosity, Explorations, and Discovery at the Dawn of AI (Os mundos que vejo: curiosidade, explorações e descobertas no início da IA).
125. Li, Y. (2023). O estado da arte no diagnóstico de falhas em transformadores com inteligência artificial e análise de gases dissolvidos: uma revisão da literatura.
126. Li T., Li L., Wang S., Dehghanian P. (2020). Inteligência Artificial para identificação de topologia em tempo real em sistemas de distribuição de energia. Universidade George Washington.
127. Liu, X., Miao, X., Jiang, H., & Chen, J. (2020). Revisão da análise de dados na inspeção visual de linhas de energia com uma discussão aprofundada da tecnologia de aprendizado profundo. *Revisões anuais em controle*, 50, 253-277. <https://doi.org/10.1016/j.arcontrol.2020.09.002>
128. Lopez Conde, M., & Twinn, I. (2019). Como a inteligência artificial está a tornar o transporte mais seguro, mais limpo, mais fiável e eficiente nos mercados emergentes. *EMCompass*. <https://www.ifc.org/content/dam/ifc/doc/mgrt/emcompass-note-75-ai-making-transport-safer-in-emerging-markets.pdf>
129. Lu, Y., Shen, M., Wang, H., Wang, X., Van Rechem, C., & Wei, W. (2024). *Aprendizado de máquina para geração de dados sintéticos: uma revisão*. <https://arxiv.org/html/2302.04062v6>
130. Luu, T.T., Le, H., Vu, M., Nguyen, B. (2023). Aplicação de IA para triagem de resíduos sólidos no Sul Global. <https://sdgs.un.org/sites/default/files/2023-05/A41%20-%20Thien-An%20Tran%20Luu%20-%20AI%20Application%20for%20Solid%20Waste%20in%20the%20global%20south.pdf>
131. Manners-Bell, J. (2019). O futuro da logística. Nota técnica IDB-TN-1658. Banco Interamericano de Desenvolvimento (BID). <http://dx.doi.org/10.18235/0001729>
132. Maroju, R. G., Choudhari, S. G., Shaikh, M. K., Borkar, S. K., & Mendhe, H. (2023). Aplicação da Inteligência Artificial na Gestão da Água Potável: Uma Revisão Narrativa. *Cureus*, 15(11), e49344. <https://doi.org/10.7759/cureus.49344>
133. McKinsey Analytics (2018). *Um guia executivo para a IA*.
134. McKinsey & Company (2023). O utilitário habilitado para IA: reconectar para vencer na transição energética.

135. McMillan, L., Varga, L. (2022). Uma revisão da utilização de métodos de inteligência artificial em sistemas de infraestruturas. *Engineering Applications of Artificial Intelligence*, Volume 116. <https://www.sciencedirect.com/science/article/pii/S0952197622004626>
136. Mehrabi, N., Morstatter, F., Saxena, N., Lerman, K., & Galstyan, A. (2022). *Uma pesquisa sobre viés e justiça no aprendizado de máquina*. *ACM Computing Surveys*, 54(6), 1-35 <https://doi.org/10.1145/3457607>
137. Microsoft - Streebo Inc (2024). Utility Chatbot - Solução de chatbot de IA para empresas de energia e serviços públicos com base no Microsoft Copilot e GPT. <https://appsource.microsoft.com/en-us/product/web-apps/streeboinc1674035040438.utility-chatbot?tab=overview>
138. Minatta A., Basani, M. (2022). Ecosistema de inovação no setor da água, saneamento e resíduos sólidos na América Latina e no Caribe: Pesquisa e modelo de vinculação. Nota técnica nº IDB-TN-2565. Banco Interamericano de Desenvolvimento (BID).
139. Minatta A., & Basani, M. (2023). *Como a regulamentação pode impulsionar a inovação? Habilitando a regulamentação para a inovação no setor de água, saneamento e resíduos sólidos na América Latina e no Caribe*. Nota técnica nº IDB-TN-2689. Banco Interamericano de Desenvolvimento (BID).
140. Minatta A., Basani, M., & Shaki G. (2022). *Gestão da inovação dos prestadores de serviços de água, saneamento e resíduos sólidos na América Latina e no Caribe: Laboratório de Inovação*. Nota técnica nº IDB-TN-02513. Banco Interamericano de Desenvolvimento (BID).
141. Minatta, A., & Basani, M. (2020). Inovação em água, saneamento e resíduos sólidos: Diagnóstico, perspectivas e oportunidades para a América Latina e o Caribe. Nota Técnica No. IDB-TN-01974. Banco Interamericano de Desenvolvimento (BID). <http://dx.doi.org/10.18235/0002514>
142. MODESHIFT (2023). Qual é o futuro da Inteligência Artificial IA nos transportes?
143. Mohammad, A., & Mahjabeen, F. (2023). Revolucionando a Energia Solar: O Impacto da Inteligência Artificial nos Sistemas Fotovoltaicos. 2(1).
144. Mohri, M., Rostamizadeh, A., & Talwalkar, A. (2018). *Foundations of Machine Learning*, segunda edição. MIT Press.
145. Molero G., Poveda Reyes S., Kumar A., García-Jimenez E., Chiara M., Santarremigia F. (2021). *Soluções computacionais baseadas em redes bayesianas para hierarquizar e prever fatores que influenciam a equidade de gênero no sistema de transporte: quatro casos de uso*. *Sustentabilidade* 2021 13 (20)
146. Moszoro M. (2021). *The Diret Employment Impact of Public Investment*. Documento de trabalho do FMI, WP/21/131.
147. Mounce, S. R., Boxall, J. B., & Machell, J. (2010). Development and Verification of an Online Artificial Intelligence System for Detection of Bursts and Other Abnormal Flows (Desenvolvimento e Verificação de um Sistema de Inteligência Artificial Online para a Detecção de Explosões e Outros Caudais Anormais). *Journal of Water Resources Planning and Management*, 136(3), 309-318. [https://doi.org/10.1061/\(ASCE\)WR.1943-5452](https://doi.org/10.1061/(ASCE)WR.1943-5452).
148. Navia Díaz, M. d. R., Bohórquez, J. F., Aguilera, J. C., Orejarena, S. S., Manosalva Castaneda, O. L., Corzo, C. M., Rodríguez, S., Romero Burgos, M. F. (2024). Gestão da mudança no setor da água potável e do saneamento na Colômbia. <https://publications.iadb.org/es/la-gestion-del-cambio-en-el-sector-de-agua-potable-y-saneamiento-de-colombia>
149. Nestor, S. (2023). IA no setor das infraestruturas: o que nos reserva o futuro? *Revista Infrastructure*. <https://infrastructuremagazine>.
150. Nevala K. (2017). *A cartilha de aprendizado de máquina*. SAS Best Practices.
151. Nolan, B. (2023). A IA está a fazer o trabalho de 250 pessoas numa empresa de energia e a satisfazer os clientes melhor do que os trabalhadores formados, diz o CEO. <https://www.businessinsider.com/ai-work-automation-octopus-energy-greg-jackson-2023-5>
152. Nova, K. (2023). Sistemas de gestão de água habilitados para IA: Uma análise dos componentes do sistema e interdependências para a conservação da água.
153. NVIDIA. (2022). Principais casos de uso de IA para empresas de serviços públicos. <https://resources>.
154. OCDE (2019). *Inteligência Artificial na Sociedade*. OCDE. <https://doi.org/10.1787/eedfee77-en>
155. OCDE (2019). Visão geral dos princípios de IA da OCDE. <https://oecd.ai/en/ai-principles>
156. OCDE (2023). AI language models: *Technological, socio-economic and policy considerations* (OECD Digital Economy Papers 352; OECD Digital Economy Papers, Vol. 352). <https://doi.org/10.1787/13d38f92-en>
157. OCDE (2023). Perspectivas econômicas para a América Latina 2023. Investir no desenvolvimento sustentável. Resumo.
158. OECD-CAF (2022). O uso estratégico e responsável da inteligência artificial no setor público da América Latina e do Caribe. *OECD Public Governance Reviews*, OECD Publishing, Paris, <https://doi.org/10.1787/1f334543-en>.
159. Patterson, J., & Gibson, A. (2017). *Aprendizagem profunda: uma abordagem do praticante*. O'Reilly Media, Inc.
160. Pieterston, W., Batista, D., Rosas-Shady, D., & Franco, A. (2023). A transformação digital dos serviços públicos de emprego na América Latina e no Caribe. Publicações do BID. <https://doi.org/10.18235/0005084>
161. Pirika (n.d.). Takanome: Pesquisa sobre a distribuição do lixo. <https://corp.pirika.org/en/service/takanome/>
162. Pombo, C., Cabrol, M., Alarcón, N. G., & Ávalos, R. S. (2020). fAIr LAC: Adoção ética e responsável da Inteligência Artificial na América Latina e no Caribe. Publicações do BID. <https://doi.org/10.18235/0002169>

163. Pombo C., Gupta R., Stankovich M. (2018). Serviços sociais para cidadãos digitais: Oportunidades para a América Latina e o Caribe. Banco Interamericano de Desenvolvimento - BID.
164. Ponomareva N., Hazimeth H., Kurakin A., Xu Z., Denison C., McMahan H., Vassilvitskii S., Chien S., Thakurta A. (2023). *Como fazer DP-fy ML: um guia prático para aprendizado de máquina com privacidade diferencial* Journal of Artificial Intelligence Research 77 (2023).
165. Pourdaryaei, A., Mohammadi, M., Mubarak, H., Abdellatif, A., Karimi, M., Gryazina, E., & Terzija, V. (2024). Um novo quadro para a previsão do preço da eletricidade através de técnicas de auto-atenção de várias cabeças e baseadas na CNN no mercado competitivo da eletricidade. *Expert Systems with Applications*, 235, 121207. <https://doi.org/10.1016/j.eswa.2023.121207>
166. Pourdaryaei, A., Mokhlis, H., Illias, H. A., Kaboli, S. Hr. A., Ahmad, S., & Ang, S. P. (2019). RNA híbrida e algoritmo de busca cooperativa artificial para prever o preço da eletricidade de curto prazo no mercado de eletricidade desregulado. *IEEE Access*, 7, 125369-125386. <https://doi.org/10.1109/ACCESS.2019.2938842>
167. Rebala, G., Ravi, A., & Churiwala, S. (2019). *Uma introdução ao aprendizado de máquina*. Springer International Publishing. <https://doi.org/10.1007/978-3-030-15729-6>
168. Rennie, G., Hartnett, K., Reyes, V., Siegert, D. e Sandoval, D. (2020). *Análise de lacunas e oportunidades de inovação no setor de energia na América Latina e no Caribe*. BID
169. Rendón Rodríguez, J. R., Hernández, E., & Del Río, H. (2020). Nova geração de modelos de transporte através do uso de big data: O caso de San Salvador. Banco Interamericano de Desenvolvimento. <https://doi.org/10.18235/0002130>
170. Rodrigues, F., Markou, I., & Pereira, F. C. (2019). Combinando séries temporais e dados textuais para a previsão da procura de táxis em áreas de eventos: Uma abordagem de aprendizagem profunda. *Information Fusion*, 49, 120-129. <https://doi.org/10.1016/j.inffus.2018.07.007>
171. Romanillos, G., Moya-Gómez, B., Zaltz-Austwick, M., & Lamíquiz-Daudén, P. J. (2018). O pulso da cidade ciclável: Visualizando as rotas GPS do sistema de compartilhamento de bicicletas de Madri e o fluxo de ciclismo. *Journal of Maps*, 14(1), 34-43. <https://doi.org/10.1080/17445647.2018.1438932>
172. Runge, J., & Zmeureanu, R. (2021). Uma revisão das técnicas de aprendizagem profunda para prever o uso de energia em edifícios. *Energias*, 14(3), 608. <https://doi.org/10.3390/en14030608>
173. Sameen, M., & Pradhan, B. (2017). Previsão da gravidade de acidentes de trânsito com redes neurais recorrentes. *Ciências Aplicadas*, 7(6), 476. <https://doi.org/10.3390/app7060476>
174. Santos, D., Saias, J., Quaresma, P., & Nogueira, V. B. (2021). Abordagens de Machine Learning para Análise de Acidentes de Trânsito e Previsão de Hotspots. *Computadores*, 10(12), 157. <https://doi.org/10.3390/computers10120157>
175. Sarni, W., Sheehan, J., & Cox, T. (2023). *The Digital Journey of Water and Sanitation Utilities in the Caribbean: Current State and Opportunities*. Documento de discussão nº IDB-DP-01046. Banco Interamericano de Desenvolvimento.
176. Sergiienko, B. (2024). IA generativa na indústria da energia e nos serviços públicos: soluções de próxima geração para um futuro mais verde. <https://masterofcode>.
177. Senthil kumar, A. R., Goyal, M. K., Ojha, C. S. P., Singh, R. D., & Swamee, P. K. (2013). Aplicação de redes neurais artificiais, lógica difusa e algoritmos de árvores de decisão para modelação do fluxo de água em Kasol, na Índia. *Water Science and Technology*, 68(12), 2521-2526. <https://doi.org/10.2166/wst.2013.491>
178. Sharma, A., Kosasih, E., Zhang, J., Brintrup, A., & Calinescu, A. (2022). Gêmeos digitais: teoria e prática do estado da arte, desafios e questões de investigação em aberto. *Journal of Industrial Information Integration*, 30, 100383. <https://doi.org/10.1016/j.jii.2022.100383>
179. *Journal of Industrial Information Integration*, 30, 100383. <https://doi.org/10.1016/j.jii.2022.100383>
180. Smola A., Vishwanathan S.V.N. *Introduction to Machine Learning (Introdução à aprendizagem automática)*. Cambridge University Press.
181. Stankovich, M., Hasanbeigi, A., & Neftenov, N. (2020). Uso de tecnologias 4RI em água e saneamento na América Latina e no Caribe. Publicações do BID. <https://doi.org/10.18235/0002343>
182. Sutton, R. S., & Barto, A. G. (2018). *Aprendizagem por reforço*, segunda edição: uma introdução. MIT Press.
183. Taylor, L., & Nitschke, G. (2017). Melhorando o aprendizado profundo usando aumento de dados genéricos (arXiv: 1708.06020). arXiv. <https://doi.org/10.48550/arXiv.1708.06020>
184. Talbott, S. (2024). Como a IA está iluminando o setor da energia. <https://www.salesforce.com/blog/ai-in-energy/>
185. Tempest, O. (2023). Aproveitamento da IA para otimização e sustentabilidade na indústria da água e das águas residuais. Entrevista com Adam Cartwright, Diretor Global de Estratégia Industrial para a Indústria da Água na Siemens AG. <https://smartwatermagazine>.
186. TMG (2020). Revisão das políticas e desenvolvimentos da América Latina sobre Inteligência Artificial. <https://www.tmgtelecom.com/wp-content/uploads/2020/07/TMG-Informe-de-Desarrollo-de-Políticas-de-IA.pdf>
187. Torres, C. S. R., Sánchez, C. B., & Narita, T. (2021). Autoavaliação ética da IA para atores do ecossistema empreendedor: Um guia de aplicação. Publicações do BID. <https://doi.org/10.18235/0003269>
188. Turing, A. (1950). Machinery and Intelligence. *Mind: A Quarterly Review of Psychology and Philosophy*, 59(236), 433-460.
189. UNESCO (2019). Estudo preliminar sobre a Ética da Inteligência Artificial - Biblioteca Digital da UNESCO. <https://unesdoc.unesco.org/ark:/48223/pf0000367823>

190. UNESCO (2022). Recomendação sobre a ética da inteligência artificial. Organização das Nações Unidas para a Educação, a Ciência e a Cultura (UNESCO).
191. Vanijirattikhan, R., Khomsay, S., Kitbutrawat, N., Khomsay, K., Supakchukul, U., Udomsuk, S., Suwatthikul, J., Oumtrakul, N., & Anusart, K. (2022). Detecção de vazamento acústico baseado em IA em sistemas de distribuição de água. *Resultados em Engenharia*, 15, 100557. <https://doi.org/10.1016/j.rineng.2022.100557>
192. Valenciaport, F. (2020). Manual dos portos inteligentes: Estratégia e roteiro. Publicações do BID. <https://doi.org/10.18235/0002384>
193. Vasudevan, M., Townsend, H., Dang, Nhi, T., O'Hara, A., Burnier, C., & Ozbay, K. (2020). Identificação de aplicações de transporte do mundo real usando inteligência artificial (IA): Resumo da aplicação potencial de IA no transporte. <https://rosap.ntl.bts.gov/view/dot/50651>
194. Vélez, M. I., Gómez Santamaría, C., & Osorio Sanabria, M. A. (2022). *Conceitos fundamentais e utilização responsável da inteligência artificial no setor público*. Relatório 2 [workingPaper]. CAF. <https://scioteca.caf.com/handle/123456789/1921>
195. Villagrán, M. A. (2022). Auditoria algorítmica para sistemas de apoio à decisão. Publicações do BID. <https://doi.org/10.18235/0004154>
196. AI Viewer (2021). Bots de IA no setor dos serviços públicos: a solução de que necessita. <https://www.visor.ai/blog/ai-bots-in-the-utilities-sector/>
197. Wang, P. (2019). Sobre a definição de inteligência artificial. *Journal of Artificial General Intelligence*, 10(2), 1-37. <https://doi.org/10.2478/jagi-2019-0002>
198. Wang, J., Mall, S., & Perez, L. (2017). A eficácia do aumento de dados na classificação de imagens usando aprendizado profundo.
199. Wipro (2019). 3 maneiras pelas quais a IA melhorará as experiências dos clientes de serviços públicos. <https://www.wipro.com/blogs/anjan-lahiri/3-ways-ai-will-improve-utility-customers-experiences/>
200. Banco Mundial (2022). *Migração do governo para ecossistemas de nuvem: Multiple Options, Significant Benefits, Manageable Risks*. Banco Mundial, Washington, DC.
201. Yang, Z., Franz, M. L., Zhu, S., Mahmoudi, J., Nasri, A., & Zhang, L. (2018). Análise da demanda de táxi de Washington, DC, usando GPS e dados de uso da terra. *Journal of Transport Geography*, 66, 35-44. <https://doi.org/10.1016/j.jtrangeo.2017.10.021>
202. Zhang, H., Davigny, A., Colas, F., Poste, Y., & Robyns, B. (2012). Estratégia de gestão de energia baseada em lógica difusa para edifícios comerciais que integram sistemas fotovoltaicos e de armazenamento. *Energy and Buildings*, 54, 196-206. <https://doi.org/10.1016/j.enbuild.2012.07.022>
203. Zhang, Y. & Cheng L. (2023). The role of transport infrastructure in economic growth: empirical evidence in the UK. *Transport Policy* 133 (2023) 2023-233.
204. Zhang, Q., Li, Z., Snowling, S., Siam, A., & El-Dakhakhni, W. (2019). Modelos preditivos para previsão de fluxo de águas residuais com base na análise de séries temporais e rede neural artificial. *Water Science and Technology*, 80(2), 243-253. <https://doi.org/10.2166/wst.2019.263>
205. Zhou, M., Zhang, Y., Wang, J., Xue, T., Dong, Z., & Zhai, W. (2023). Detecção de falhas de estações de tratamento de águas residuais com base em um método de máquina de aprendizado extremo de kernel aprimorado. *Water*, 15(11), 2079. <https://doi.org/10.3390/w15112079>

