

Intelligent Methodologies for Preparing Reference Prices in Brazilian Public Biddings

Eduardo Marques Braga de Faria
faria.eduardo@academico.ufs.br
Universidade Federal de Sergipe
Aracaju, Sergipe, Brasil

Gilton José Ferreira da Silva
gilton@dcomp.ufs.br
Universidade Federal de Sergipe
Aracaju, Sergipe, Brasil

Michel S. Soares
michel@dcomp.ufs.br
Universidade Federal de Sergipe
Aracaju, Sergipe, Brasil

Abstract

Context: This research focuses on building reference prices in Brazilian public tenders, integrating statistical techniques and AI to improve automated decision accuracy and detect issues like overpricing and underpricing. **Problem:** Traditional methods for calculating reference prices, like arithmetic mean and lowest price, often cause distortions in public tenders. This research evaluates how AI can enhance accuracy and transparency in audits. **Solution:** The proposed solution is software that combines statistical algorithms with machine learning to calculate reference prices more robustly. The first version uses statistical methods; the second integrates TensorFlow, expanding irregularity detection. **IS Theory:** Based on Design Science Research, this study develops and evaluates artifacts to solve identified problems, applying scientific techniques to optimize reference price calculations. **Method:** A quantitative experiment using public tender data compares the software's performance with traditional methods, focusing on average deviation and machine learning accuracy. **Summary of Results:** The first software version reduced average deviation to 2.53%, versus 15.58% for traditional methods. The machine learning version achieved 70% accuracy in detecting pricing irregularities, adding an extra verification layer. **Contributions and Impacts in the IS area:** This research contributes to Information Systems by proposing a system that combines statistics and AI, enhancing accuracy and transparency. The solution improves public bidding efficiency and is adaptable to other government and industry areas.

CCS Concepts

• Information systems;

Keywords

Public Bidding, Reference Price, Engineering, Software, Public Administration

1 Introdução

A formação de preços de referência para licitações públicas no Brasil é um dos processos mais críticos para garantir a eficiência, transparência e economicidade na Administração Pública. No entanto, os métodos tradicionalmente empregados, baseados em critérios estatísticos simples, como a média aritmética, mediana ou o menor preço, podem levar a distorções significativas, resultando em sobrepreço ou subpreço.

Contratações feitas com preços distoantes impactam diretamente a qualidade das contratações públicas, gerando potenciais desperdícios de recursos e prejuízos à gestão financeira dos órgãos governamentais. O problema de pesquisa deste trabalho surge a partir desta lacuna: como aprimorar os métodos de cálculo de preços de referência em licitações públicas utilizando abordagens estatísticas avançadas e técnicas de inteligência artificial?

Este trabalho propõe o desenvolvimento de um software baseado em *Spring Boot*, em Java, que incorpora tanto métodos estatísticos tradicionais quanto uma abordagem inovadora que integra algoritmos de Aprendizado de Máquina com o uso de *TensorFlow* e JNI (*Java Native Interface*), pois apesar de a integração do *TensorFlow* com JNI não ser nova em si, a integração do *TensorFlow* com C++ e *SpringBoot* é algo pouco explorado, especialmente no contexto de licitações públicas.

O objetivo geral deste estudo é implementar um sistema capaz de calcular o preço de referência de forma mais precisa, minimizando e fornecendo aos gestores públicos uma ferramenta robusta para melhorar a transparência nas licitações. Os objetivos específicos incluem a criação de duas versões do software: a primeira, utilizando um seletor de algoritmos com tratamentos estatísticos baseados em regras de decisão; e a segunda, mais avançada, que incorpora técnicas de Aprendizado de Máquina para incremento da precisão dos resultados, conforme ilustrado na Figura 1.

A contribuição científica deste trabalho reside na aplicação de técnicas de inteligência artificial que permitem não apenas identificar padrões de comportamento de preços, mas também detectar evidências de sobrepreço ou subpreço com mais de 70% de assertividade, segundo os experimentos realizados com 500 mil preços coletados, conforme evidenciado na Figura 2.

O sistema oferece uma segunda camada de verificação para confirmar a veracidade dos valores de referência sugeridos. Nos experimentos, a primeira versão do software, utilizando apenas o seletor de algoritmos, apresentou um desvio-médio de 2,53% em relação aos valores homologados, em comparação com os 15,58% dos métodos tradicionais empregados pelos órgãos públicos.

A originalidade científica deste estudo está na implementação de um sistema que combina o potencial de técnicas estatísticas que são consolidadas, com métodos modernos de Aprendizado de Máquina, ampliando a capacidade de auditoria de preços de referência no contexto de licitações públicas. Este trabalho justifica-se pela crescente demanda por maior transparência e controle nos processos de compras públicas no Brasil, especialmente em um cenário onde a utilização de dados abertos e a automação de auditorias se tornam essenciais para evitar fraudes e garantir o uso eficiente dos recursos públicos.

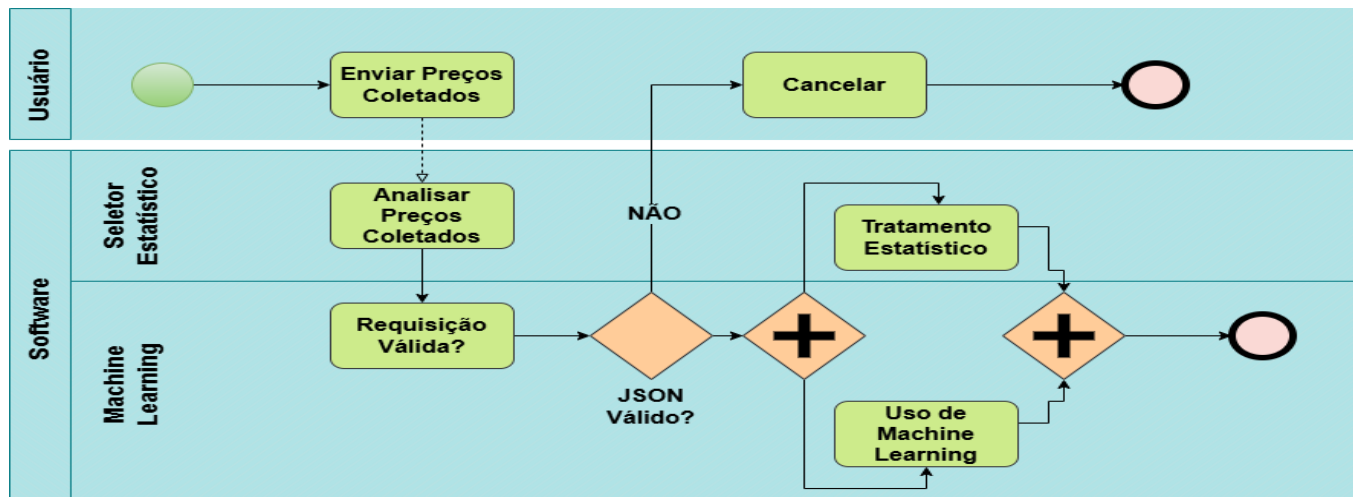


Figura 1: Diagrama BPMN que destaca os principais componentes do software em nível de negócio.

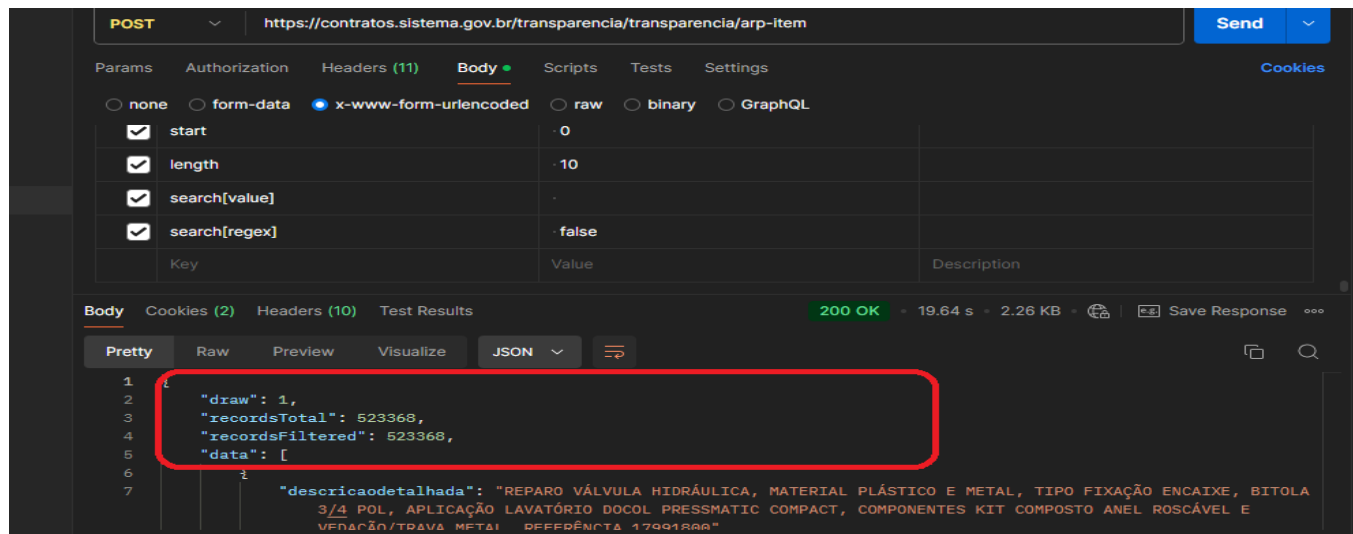


Figura 2: Resposta da requisição feita a portal governamental brasileiro retorna mais de 523 mil itens para análise e treinamento dos dados.

2 Considerações Sobre o Preço de Referência

A licitação é um procedimento administrativo formal utilizado pela Administração Pública para selecionar a proposta mais vantajosa para o contrato de fornecimento de bens, serviços ou realização de obras [20]. Desse modo, a licitação é regida por princípios como igualdade, legalidade e impessoalidade, buscando garantir a obtenção de melhores condições para o setor público e assegurar a transparência e o controle social no processo de contratação.

A licitação também pode ser definida como o procedimento administrativo utilizado pela Administração Pública para garantir a contratação de obras, serviços, compras ou até mesmo alienações, assegurando a seleção da proposta mais vantajosa sob o princípio da isonomia [13]. Assim, a licitação é um instrumento que visa a

promoção da eficiência e da transparência nas aquisições públicas, regido por regras estritas previstas na legislação brasileira.

O preço de referência é um parâmetro fundamental utilizado pela Administração Pública para nortear as contratações de bens e serviços [6]. Esse valor estimado é obtido por meio de pesquisas de mercado, que buscam refletir o cenário econômico atual, evitando tanto a aquisição de itens com preços superfaturados quanto de preços inexequíveis. Nesse contexto, a etapa de formação do preço de referência antecede a fase externa do certame, conforme se nota da Figura 3.

O preço de referência em licitações é calculado a partir da coleta de múltiplos preços de mercado e pode ser definido por três métodos principais: a média aritmética, a mediana ou o menor preço [11].



Figura 3: Etapas da licitação pública no Brasil.

A média considera a soma dos preços coletados, dividida pela quantidade de amostras; a mediana é o valor central de um conjunto de dados ordenados; e o menor preço é utilizado em casos excepcionais, quando os demais valores são muito altos ou inconsistentes.

O cálculo do preço de referência em licitações brasileiras também pode utilizar metodologias alternativas baseadas em critérios estatísticos, como a “cesta de preços aceitáveis” [2]. Esse método busca diversificar as fontes de dados ao invés de se basear apenas em orçamentos de fornecedores, utilizando registros de compras públicas, consultas a sistemas de compras, e outros mecanismos que garantam uma estimativa de preços mais confiável e livre de distorções, evitando o uso exclusivo de médias aritméticas ou cotações superestimadas.

No entanto, as metodologias de formação de preço de referência, como a média, o menor preço e a mediana, possuem vantagens e limitações. A média aritmética é fácil de calcular e oferece um parâmetro equilibrado, mas pode ser distorcida por valores atípicos, o menor preço assegura economia, porém pode resultar em preços inexequíveis e a mediana oferece uma visão mais realista ao excluir os extremos, mas pode não refletir totalmente as variações do mercado [1].

O uso de abordagens alternativas na formação e cálculo do preço de referência em licitações pode trazer melhorias significativas ao promover maior concorrência e reduzir a assimetria de informações entre os participantes [7]. O autor esclarece que técnicas como o parcelamento do objeto e a definição precisa do preço de reserva mitigam práticas colusivas, aumentando a competitividade e assegurando que os valores ofertados sejam mais próximos do real valor de mercado.

Estatisticamente, em uma amostra assimétrica, o primeiro quartil (Q1) será sempre inferior à mediana, pois divide os primeiros 25% dos dados, enquanto a mediana representa o valor central da amostra e da mesma forma, a média harmônica será sempre inferior à média aritmética, especialmente em dados com grandes variações, pois a média harmônica dá maior peso aos valores menores [10]. Isso evidencia que o uso do primeiro quartil ao invés da mediana pode ser vantajoso para evitar distorções, assim como a média harmônica oferece uma estimativa mais conservadora do valor de referência.

A distribuição normal é uma ferramenta estatística para modelar a variabilidade dos dados e permite que a maioria dos valores se concentre em torno da média, com uma dispersão simétrica [9]. No contexto de licitações, a aplicação de um algoritmo personalizado

baseado na distribuição normal pode oferecer uma estimativa mais robusta, considerando as flutuações de preços e eliminando outliers, proporcionando maior precisão e confiabilidade ao processo de formação do preço. Os métodos se resumem na Tabela 1.

Abordagens Estatísticas		
Abordagem Tradicional	Abordagem Proposta	Observação (Amostras Assimétricas)
Média Aritmética (MA)	Média Harmônica (MH)	Sempre, MH <MA
Mediana (Md)	Primeiro Quartil (Pq)	Sempre, Pq <Md
Menor Preço (Mp)	Distribuição Normal (DN)	Sempre, DN <Mp

Tabela 1: Quadro comparativo de abordagens para cálculo do preço de referência em licitações brasileiras

Ainda no ramo estatístico, a Lei de Benford é uma ferramenta utilizada para detectar anomalias em conjuntos de dados numéricos e sugere que, em muitos tipos de dados naturais, os primeiros dígitos seguem uma distribuição específica, com o dígito “1” aparecendo com maior frequência [5]. Sua aplicação em licitações é importante para evitar distorções no valor de referência, pois desvios dessa distribuição podem indicar superfaturamento ou manipulação de preços.

3 Trabalhos Relacionados

Ramos et al. [21] destaca que a integração da Lei de Benford com Inteligência Artificial (IA) evidenciou-se eficaz na análise de dados eleitorais e pode ser adaptada para auditorias públicas. Essas iniciativas demonstram como algoritmos de Aprendizado de Máquina podem robustecer a fiscalização, integrando estatísticas avançadas e verificações automáticas. Nesse sentido, a presente proposta aprimora essa linha ao aferir preços de referência e mitigar sobrepreço e subpreço, e reforça a relevância de soluções híbridas, unindo análise estatística e IA para otimizar a conformidade nas compras públicas.

Rocha et al. [22] traz um exemplo de aplicação de IA em auditoria contínua que emite alertas sobre compras públicas suspeitas. Enquanto o trabalho dos autores focaliza a detecção de possíveis fraudes em tempo real, o presente trabalho inova ao empregar técnicas estatísticas avançadas e aprendizado de máquina para gerar preços de referência, ampliando a identificação de sobrepreço e subpreço. Essa nova perspectiva complementa a simples emissão de alertas ao oferecer um parâmetro de valor embasado em dados, reforçando a transparência no processo. Assim, a proposta apresentada agrega robustez ao controle em licitações, indo além do monitoramento contínuo de riscos.

Brasil [2] enfatiza o aprimoramento dos métodos de cálculo de preços de referência para compras públicas, com destaque para medicamentos. O autor explora alternativas às práticas tradicionais, como a média aritmética, introduzindo métodos como a “média saneada” (MS) e o “coeficiente de variação” para tratar de distorções nos dados coletados. Segundo o autor, excluem-se os dados maiores ou menores do que o limite máximo, para mais ou para menos,

equivalente à média aritmética multiplicada por duas vezes o desvio-padrão da amostra, conforme Equação 1:

$$MS = \bar{X} \pm 2 * S \quad (1)$$

Cox [4] discute a importância do orçamento estimativo nas licitações públicas, destacando que a precisão desse orçamento afeta diretamente a eficiência e a economicidade das contratações e abordando as dificuldades normativas e práticas que rotineiramente a administração pública enfrenta ao estimar o valor de futuros contratos, sugerindo métodos para aprimorar a elaboração dos orçamentos, como a utilização de múltiplas fontes de dados e análises mais robustas.

O trabalho de Castro e Ribeiro [8] aborda a definição do valor de referência em licitações públicas realizadas por pregão eletrônico na Comissão Nacional de Energia Nuclear (CNEN) e estuda os processos de 202 pregões realizados entre 2012 e 2016, e conclui que a definição mais precisa do valor de referência ocorre quando o menor preço da pesquisa de mercado é utilizado.

Souza [12] investiga a eficácia e economicidade das licitações realizadas pela Procuradoria-Geral do Trabalho após a mudança na metodologia de pesquisa de preços. O estudo conclui que a adoção de métodos como o coeficiente de variação (CV), calculado conforme a Equação 2, e a eliminação de valores inexequíveis e exorbitante gerou um incremento no percentual de descontos obtidos, o que demonstra sua viabilidade para otimizar o uso de recursos público.

$$CV = \frac{\sqrt{S^2}}{\bar{X}} * 100 \quad (2)$$

Zambrano e Colamarco [26] exploram as diferenças entre os orçamentos de referência e os preços finais em licitações de obras públicas no Equador. Utilizando o algoritmo *Naïve Bayes*, os autores analisaram uma amostra de contratos de 2008 a 2019, identificando 15 combinações de variáveis com uma probabilidade de 70% ou mais de que o preço final ultrapasse em 15% o valor contratado. O estudo é útil ao antecipar variações nos valores de contratos em licitações públicas e pode ser reimplementado em um sistema baseado em *TensorFlow* e *Spring Boot*, como no presente trabalho.

O trabalho de Cunha e Bugarin [3] aplica a Lei de Benford à auditoria das obras de reforma do Aeroporto Internacional de Minas Gerais. A aplicação dessa técnica resultou na identificação de até 86% do sobrepreço total com uma amostra menor que a normalmente utilizada em auditorias tradicionais, conforme Equação 3, potencializando a precisão no uso de *TensorFlow* no presente trabalho para auditoria de preços.

$$P(d) = \log_{10}\left(1 + \frac{1}{d}\right) \quad (3)$$

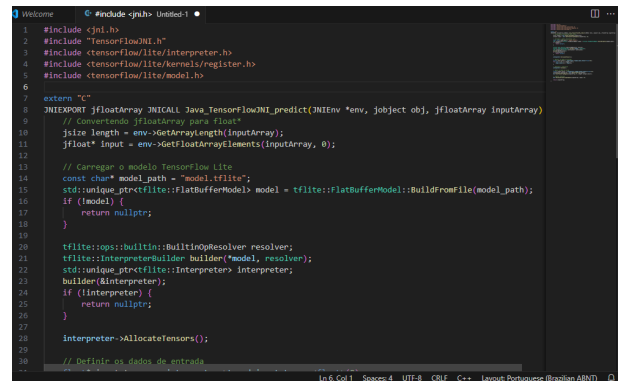
Guayuan et al. [15] apresentam um esquema para o desdobramento automático de APIs usando *Jenkins*, *Spring Boot*, e o *WSO2 API Manager*. Os autores mostram como o uso de uma arquitetura de microserviços pode centralizar a administração de APIs, facilitando a gestão e garantindo segurança ao ciclo de vida de APIs REST. O estudo revela que essa abordagem reduz significativamente o tempo de implantação e minimiza os erros humanos ao automatizar o registro de APIs em sistemas de grande escala quando se combina o *Jenkins* e o *Spring Boot*.

Lu et al. [19] propõem um sistema de desembrulhamento inteligente chamado AutoD, baseado na camada de interface nativa do Java (JNI). O sistema visa resolver problemas de extração de funções em aplicativos de *blockchain* reforçados para proteger contra ataques que visam roubar chaves e dados sensíveis. Esse estudo destaca como o uso de JNI, integrado ao *Spring Boot* e *TensorFlow*, pode permitir maior controle sobre a segurança e desempenho, aplicando-se ao presente trabalho na auditoria e elaboração de preços de referência em licitações.

Ullah et al. [25] propõem um sistema de detecção de replicação e clonagem de aplicativos Android em mercados de IoT (Internet das Coisas) usando *edge computing* e *deep learning* com *TensorFlow*. O sistema, chamado Droid-IoT, utiliza técnicas de tokenização e balanceamento de dados para identificar e prevenir a publicação de versões piratas de aplicativos em diversos mercados. Isso evidencia é possível melhorar a detecção de irregularidades nos preços de referência em licitações públicas, promovendo maior confiabilidade e segurança no processo de auditoria.

Kalita et al. [17] propõem um novo modelo de aprendizado profundo baseado em uma rede neural convolucional (CNN) para diagnóstico de câncer de mama. O modelo foi implementado em um aplicativo Android utilizando *TensorFlow Lite*. A aplicação de modelos de *deep learning*, em combinação com *TensorFlow* em interface nativas como JNI, pode ser uma solução promissora para a geração de preços de referência em licitações, processando dados em tempo real com eficiência em recursos limitados.

Lee [18] propõe uma técnica de análise de programas JNI que automatiza a extração de resumos semânticos de funções em C para facilitar a interação entre Java e C. Isso sugere que a análise automática de código JNI pode melhorar a integração de algoritmos nativos em sistemas *Spring Boot*, proporcionando maior eficiência e precisão na geração de preços de referência em licitações. Nesse contexto, o software objeto deste trabalho teve de implementar trechos em C++, de modo a integrar o *Tensorflow* com o *SpringBoot*, conforme ilustrado na Figura 4.



```

1 //include
2 #include <jni.h>
3 #include "TensorFlowJNI.h"
4 #include <tensorflow/lite/interpreter.h>
5 #include <tensorflow/lite/kernels/register.h>
6 #include <tensorflow/lite/model.h>
7
8 extern "C"
9 JNIEXPORT jlong JNICALL Java_TensorFlowJNI_predict(JNIEnv *env, jobject obj, jlongArray inputArray)
10 // Convertendo jlongArray para float*
11 jsize length = env->GetArrayLength(inputArray);
12 float* input = env->GetFloatArrayElements(inputArray, 0);
13
14 // Carregando o modelo TensorFlow Lite
15 const char* model_path = "model.tflite";
16 std::unique_ptr<tf::FlatBufferModel> model = tf::FlatBufferModel::BuildFromFile(model_path);
17 if (!model) {
18     return nullptr;
19 }
20
21 tf::Interpreter::Builder builder(*model, resolver);
22 tf::Interpreter::Builder builder(*model, resolver);
23 std::unique_ptr<tf::Interpreter> interpreter;
24 builder->Build(&interpreter);
25 if (!interpreter) {
26     return nullptr;
27 }
28
29 interpreter->AllocateTensors();
30
31 // Definindo os dados de entrada

```

Figura 4: Integração do *Tensorflow* no *Spring Boot*.

4 Metodologia

A fim de realizar testes sobre a eficácia e efetividade dos métodos estatísticos alternativos propostos à cotação de preços, foram aplicados testes em nível de software, com a comparação dos preços estimados em licitações com os preços efetivamente contratados.

Essa diferença entre preço estimado e preço contratado é muito importante, pois permite evidenciar o grau de acurácia do preço de referência, pois se tal diferença for elevada, há fortes evidências de distorções na pesquisa de preços. Assim, os preços estimados com as metodologias do presente trabalho demonstraram ser mais próximos aos valores homologados, em comparação com as estimativas feitas pelas próprias entidades públicas brasileiras em seus processos de licitação.

O ganho de produtividade com o uso de técnicas de Aprendizado de Máquina também foi posto à prova, com o uso de testes com o *framework Tensorflow*, mas ainda é uma abordagem que carece de melhorias. Desse modo, os tipos de metodologia, o modo e o *modus operandi* de realizar os métodos do presente trabalho são mais bem esclarecidos e evidenciados nas subseções seguintes.

4.1 Justificativa das Escolhas Metodológicas

O *Spring Boot* é uma ferramenta que facilita o desenvolvimento de APIs REST ao fornecer um ecossistema modular para a criação de sistemas distribuídos com alta produtividade [16]. Isso é essencial para a construção de uma API que gera preços de referência em licitações e, com essa abordagem, é possível desacoplar a lógica de cálculo e as regras de negócio, garantindo escalabilidade e fácil manutenção da API.

Nesse contexto, o *Spring Boot* é um *framework* essencial para o desenvolvimento de APIs, devido à sua capacidade de simplificar a configuração e automação de aplicações e possibilita a construção de sistemas modulares, escaláveis e com integração facilitada, graças ao suporte a microsserviços [14]. Isso permite desenvolver ferramentas robustas para atender às necessidades específicas do setor público, como a criação de uma API destinada à geração de preços de referência em licitações brasileiras.

Em outra funcionalidade, o *TensorFlow* é uma plataforma de código aberto escrita em C++ usada para desenvolver e implementar modelos de Aprendizado de Máquina, especialmente redes neurais profundas, e é projetado para a criação de algoritmos que possam aprender com grandes conjuntos de dados, tornando-o ideal para o processamento de informações complexas, como dados de mídias sociais ou em aplicações industriais [24]. Sua integração com o *Spring Boot* pode proporcionar uma solução robusta e escalável, ao permitir que o modelo processe grandes quantidades de dados.

O JNI (*Java Native Interface*) permite a comunicação e interação entre Java e bibliotecas nativas escritas em C ou C++, o que traz consideráveis ganhos de desempenho, pois o código nativo pode executar operações de baixo nível de forma mais eficiente do que o Java puro [23]. Desse modo, quando combinado com um sistema *Spring Boot*, o uso de JNI potencializa a capacidade de processamento, permitindo que o cálculo de preços de referência em licitações seja realizado de forma ainda mais eficiente e com maior controle sobre o desempenho.

4.2 Abordagem da Pesquisa

Este trabalho adota uma abordagem quantitativa para investigar o desempenho e a precisão de diferentes algoritmos na definição de preços de referência para licitações públicas no Brasil. A pesquisa busca validar a assertividade do software desenvolvido, testando sua capacidade de fornecer valores de referência com maior precisão do que os métodos tradicionalmente usados por órgãos públicos. O foco está na análise de grandes conjuntos de dados abertos de licitações e na comparação quantitativa entre os resultados gerados pelo software e os valores homologados pelos órgãos.

4.3 Posição Epistemológica

A posição epistemológica adotada neste trabalho é positivista, pois busca mensurar e testar hipóteses sobre a eficiência de algoritmos na definição de preços de referência, com base em observações empíricas e análise estatística dos dados coletados. A pesquisa visa gerar conhecimento objetivo e generalizável a partir de experimentos rigorosos, com a aplicação de técnicas estatísticas e de Aprendizado de Máquina.

4.4 Método de Pesquisa

O método utilizado é um estudo comparativo, em que os métodos tradicionais de formação de preço de referência (menor preço, média aritmética ou mediana) são comparados com os valores efetivamente contratados, comparando-se essa diferença com a gerada do cálculo do preço de referência do software proposto. O estudo foi dividido em duas fases experimentais principais:

- Fase 1: Utilização do software com base em algoritmos tradicionais de seleção estatística para a definição de preços de referência. Esta fase utilizou algoritmos como coeficiente de variação, primeiro quartil, média harmônica, mediana e a Lei de Benford para analisar preços e identificar distorções.
- Fase 2: Integração do *TensorFlow* para treinar modelos de Aprendizado de Máquina, com a requisição enviada a um sítio eletrônico governamental que concentra dados de licitações, feita utilizando requisição HTTP (*Hypertext Transfer Protocol*) embutida no software, como descrito na Figura 5, a fim de detectar padrões de sobrepreço ou subpreço. Esta fase utilizou algoritmos supervisionados, com foco em identificar tendências de preços e prever possíveis irregularidades.


4.5 Finalidade da Pesquisa

A finalidade desta pesquisa é explicativa, pois busca explicar o comportamento dos preços de referência em licitações públicas brasileiras, utilizando um software baseado em estatísticas de modo avançado e Aprendizado de Máquina. O objetivo principal é demonstrar a superioridade da ferramenta desenvolvida em relação às abordagens atualmente utilizadas por órgãos públicos na definição de preços de referência.

4.6 Técnicas de Coleta de Dados

Os dados utilizados nos experimentos foram coletados de duas fontes principais:

- Portais de Dados Abertos: Dados de preços de licitações públicas, disponíveis em plataformas como ComprasNet, foram



```

1 curl --location 'https://contratos.sistema.gov.br/
  transparencia/transparencia/arp-item' \
2 --header 'Accept: application/json' \
3 --header 'Accept-Language: pt-PT,pt;q=0.9' \
4 --header 'Content-Type: application/x-www-form-urlencoded' \
5 --data-urlencode '0%5Bname%5D= palavra_chave' \
6 --data-urlencode '0%5Bvalue%5D= ' \
7 --data-urlencode '1%5Bname%5D= codigoUnidade' \
8 --data-urlencode '1%5Bvalue%5D= ' \
9 --data-urlencode '2%5Bname%5D= modalidadeCompra' \
10 --data-urlencode '2%5Bvalue%5D= ' \
11 --data-urlencode '3%5Bname%5D= numeroItemCompra' \

```

Figura 5: Detalhes técnicos da requisição enviada para retornos de dados de licitação

extraídos para formar a base de dados utilizada na fase inicial da pesquisa. Os valores incluíam cotações de diferentes fornecedores para produtos como resmas de papel, materiais de escritório e medicamentos.

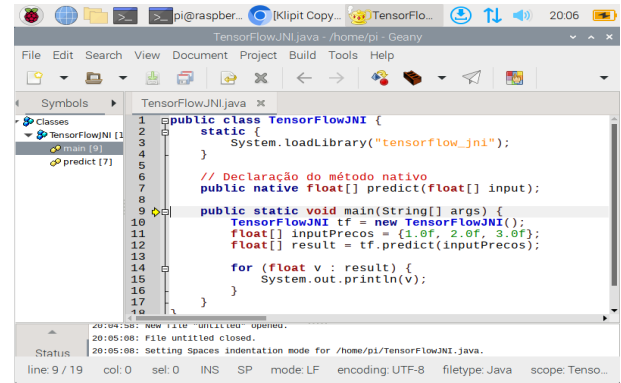
- Fontes Primárias de Cotações: Para alguns experimentos específicos, cotações fornecidas por fornecedores diretamente ligados a processos de licitação foram utilizadas para alimentar o software e permitir a comparação com os métodos tradicionais.

Foram coletados um total de 500 mil preços de diferentes categorias de produtos, que serviram como base para os experimentos nas duas versões do software, mediante requisição feita ao endereço “https://contratos.sistema.gov.br/transparencia/arp-item”, cujo retorno revela um total de mais de 523 mil itens de compra no formato JSON para posterior análise de dados.

4.7 Técnicas de Análise de Dados

Duas técnicas principais foram empregadas para a análise dos dados coletados:

- Análise Estatística: Na primeira versão do software, os dados foram tratados com algoritmos estatísticos tradicionais, como coeficiente de variação, média harmônica, primeiro quartil e a Lei de Benford. Cada um desses algoritmos foi aplicado para calcular o preço de referência para cada conjunto de dados, e os resultados foram comparados com os valores homologados fornecidos pelos portais públicos.
- Análise de Aprendizado de Máquina: Na segunda versão, os dados foram submetidos a um processo de treinamento utilizando o *TensorFlow*, que permitiu a criação de modelos preditivos para identificar padrões de preços atípicos. O modelo foi treinado utilizando o método de regressão linear e algoritmos supervisionados, com base nos preços coletados de 500 mil licitações. A detecção de sobrepreço e subpreço foi realizada com uma precisão de 70%, cuja implementação pode ser vista na Figura 6.



```

1 public class TensorFlowJNI {
2     static {
3         System.loadLibrary("tensorflow_jni");
4     }
5
6     // Declaração do método nativo
7     public native float[] predict(float[] input);
8
9     public static void main(String[] args) {
10         TensorFlowJNI tf = new TensorFlowJNI();
11         float[] inputPrecos = {1.0f, 2.0f, 3.0f};
12         float[] result = tf.predict(inputPrecos);
13
14         for (float v : result) {
15             System.out.println(v);
16         }
17     }
18 }

```

Figura 6: A integração do *Tensorflow* permitiu o treinamento de dados para detecção de subpreços e sobrepreços.

4.8 Procedimentos

A fim de alcançar resultados satisfatórios, a metodologia usada buscou alcançar melhores resultados em relação às temáticas propostas, como evidenciado nas próximas subseções.

4.8.1 Desenvolvimento do Software. O software foi desenvolvido utilizando o *framework Spring Boot*, com o objetivo de criar um endpoint REST capaz de processar dados de cotações de licitações públicas em formato JSON. O sistema foi projetado para ser modular, permitindo que o seletor de algoritmos escolha o melhor tratamento estatístico com base nas características dos dados recebidos.

- Versão 1: Esta versão utilizou exclusivamente algoritmos estatísticos. Após o recebimento dos dados, o sistema aplicava os algoritmos de seleção com base nos critérios predefinidos e retornava o preço de referência calculado.
- Versão 2: A versão mais avançada incorporou o uso de Aprendizado de Máquina por meio do *TensorFlow*, integrado ao sistema por meio de JNI (*Java Native Interface*). Isso permitiu que o sistema processasse grandes volumes de dados e utilizasse a aprendizagem de máquina para identificar anomalias de preços, como sobrepreço ou subpreço.

4.8.2 Experimentação e Testes. Os testes foram realizados em duas etapas principais:

- Etapa 1: Comparação com Preços Homologados: A primeira versão do software foi testada em 80% das licitações que foram analisadas, nas quais o desvio-médio entre o preço de referência calculado e os valores homologados foi de apenas 2,53%, enquanto os métodos tradicionais apresentaram um desvio de 15,58%.
- Etapa 2: Implementação do *TensorFlow*: Na segunda versão, o uso do Aprendizado de Máquina permitiu que o software identificasse evidências de sobrepreço ou subpreço com uma assertividade de 70% para os valores calculados pela primeira versão.

4.8.3 Avaliação dos Resultados. A eficácia do software foi avaliada com base nos seguintes critérios:

- **Precisão na Previsão de Preços:** A precisão do sistema foi medida pela proximidade dos preços de referência calculados em relação aos valores homologados.
- **Deteção de Anomalias:** Na segunda versão, a capacidade de identificar sobrepreço e subpreço foi avaliada utilizando métricas como precisão, sensibilidade e especificidade.

4.9 Validação e Limitações

A validação dos resultados foi realizada por meio da comparação dos preços de referência calculados com os preços efetivamente homologados em processos de licitação pública. O principal desafio enfrentado durante a pesquisa foi a variabilidade dos dados entre diferentes categorias de produtos e fornecedores, o que exigiu ajustes nos parâmetros dos algoritmos para aumentar a precisão do sistema.

A limitação da segunda versão do software foi observada na complexidade dos dados e na necessidade de maior treinamento dos modelos de Aprendizado de Máquina, o que reduziu a assertividade para 70%, embora tenha fornecido uma segunda camada de verificação.

5 Análise dos Resultados

Em um primeiro momento, cumpre exemplificar a metodologia relacionada ao cálculo de obtenção do desvio médio absoluto em relação ao valor efetivamente contratado nos certames, que foi notoriamente menor nos preços de referência calculados pelo software objeto deste trabalho e mais elevado nas estimativas feitas pelo próprio órgão.

Uma das muitas licitações analisadas foi a de um órgão público municipal, que realizou licitação na modalidade pregão eletrônico para aquisição de papel para impressão, em embalagens de 500 folhas. De acordo com o Edital publicado no ComprasNET (plataforma de licitações do governo brasileiro), o órgão público estimou o preço de referência em R\$ 27.25 e o item foi contratado a preço de R\$ 19.88 após a licitação, o que dá um desvio absoluto de R\$ 7.37 (27,25 - 19.88), conforme Tabela 2.

Código da Entidade (UASG)	Número da Licitação	Endereço Público de Consulta
986969	62/2023	http://www.comprasnet.gov.br/livre/pregao/termohom.asp?prgcod=1126163&co_no_uasg=986969&numprp=000622023&codigoModalidade=5&f_lstSrp=&f_Uf=&f_numPrp=&f_coduasg=&f_codMod=&f_tpPregao=&f_lstICMS=&f_dtAberturaIni=&f_dtAberturaFim=

Tabela 2: Dados da licitação de papel para impressão, que pode ser consultado publicamente por meio do endereço da consulta.

Por outro lado, a cotação de preços foi refeita no software objeto deste trabalho e, após a alimentação dos preços coletados e tratativas

internas, foi gerado o preço de referência de R\$ 19.98, pelo critério do primeiro quartil, o que representa um desvio abosoluto de R\$ 0.10 evidenciado na Figura 7.

```
Status: 200 OK Size: 1.03 KB Time: 31 ms
Response Headers Cookies Results Docs
1 [
2 {
3   "numeroItem": 1,
4   "descricao": "Papel Para Impressão",
5   "quantidadeTotal": 4500,
6   "cotacoes": [
7     {
8       "valorDeReferencia": 19.98,
9       "coeficienteVariacao": 34.17,
10      "metodo": "PRIMEIRO_QUARTIL"
11    }
12  ]
13 }
```

Figura 7: Preço de referência gerado via software para o objeto “Papel para Impressão” é bem próximo ao valor efetivamente contratado.

Assim, após a coleta dos desvios absolutos individuais de cada valor estimado da licitação em relação ao valor efetivamente contratado, fez-se a média desses desvios, chegando-se ao resultado de 15.58%. Para cada licitação, foi gerado o preço de referência no software objeto deste trabalho e, após o cálculo da média dos desvios, chegou-se ao resultado de 2.53%, um resultado que evidencia a corretude metodológica.

A Tabela 3 representa uma amostra de 10 entidades coletadas da metodologia empregada e já evidencia a queda dos desvios em nível de software, extraída dos registros da pesquisa original com universo de mais de 250 registros.

UASG	Licitação	Item	Desvio Absoluto (UASG)	Desvio Absoluto (Software)
929069	10/2023	56	12,75	3,51
120039	29/2022	205	27,13	1,51
160358	7/2022	10	0	1,15
120623	104/2022	69	2,48	0,75
160253	4/2023	18	12,37	2,35
154215	11/2023	54	7,95	3,31
160537	22/2023	54	7,74	1,11
160446	3/2023	105	6,44	0,55
986969	62/2023	1	7,37	0,11
194085	1/2023	24	6,10	1,80
Desvio Absoluto Médio (Estimado - Contratado)			9,03	1,62

Tabela 3: Amostra de 10 licitações analisadas evidencia a diferença entre as estimativas das próprias entidades e dos softwares, em comparação com o valor contratado.

5.1 Contribuições da Pesquisa e Inovação

Os resultados desta pesquisa evidenciam importantes contribuições para a área de Sistemas de Informação aplicados à auditoria

de preços em licitações públicas, com foco no uso de algoritmos estatísticos e Aprendizado de Máquina para a geração e cálculo de preços de referência. O desenvolvimento de um software modular, que combina diferentes técnicas de análise de dados, representa uma inovação significativa, ao permitir a automatização do processo de auditoria e fornecer uma camada adicional de verificação com o uso de Aprendizado de Máquina.

A primeira versão do software, utilizando o seletor de algoritmos com base em regras estatísticas, demonstrou um desempenho superior em relação aos métodos tradicionais adotados por órgãos públicos.

O desvio-médio de apenas 2,53% em relação aos valores homologados, comparado ao desvio de 15,58% observado nos métodos utilizados pelos órgãos públicos, confirma a eficácia da ferramenta para melhorar a precisão na definição de preços de referência. Essa inovação é relevante não apenas pela melhoria na precisão, mas também pela rapidez e automação no cálculo, oferecendo aos gestores públicos uma solução acessível e eficiente.

A segunda versão, que integra o *TensorFlow* com o uso de JNL, destaca-se por introduzir técnicas de Aprendizado de Máquina no processo de auditoria de preços. Embora a assertividade tenha sido de 70%, inferior à primeira versão, a segunda versão atua como espécie de verificação adicional, garantindo uma maior robustez no processo e identificando padrões de sobrepreço e subpreço em grandes volumes de dados.

A integração de dados de mais de 500 mil licitações e o uso de algoritmos preditivos representam um avanço no uso de dados abertos para auditorias públicas, alinhando-se às tendências de transparência e eficiência nos processos de compras governamentais.

5.2 Comparação com Trabalhos Relacionados

Ao comparar os resultados deste trabalho com outros estudos da área, observa-se que, enquanto grande parte da literatura se concentra em métodos estatísticos tradicionais, como médias ajustadas ou medianas, esta pesquisa avança ao incorporar Aprendizado de Máquina como uma ferramenta adicional para prever possíveis irregularidades de preços.

O estudo de Brasil [2] introduz métodos alternativos como a média saneada, buscando melhorar a acurácia dos preços de referência. No entanto, o uso de técnicas estatísticas sozinho não aborda suficientemente as variações e comportamentos atípicos detectados em grandes bases de dados.

No trabalho sobre a Lei de Benford desenvolvido por Cunha e Bugarin [3] para auditoria de preços, os resultados obtidos indicam a importância de utilizar métodos automatizados para identificar distorções nos valores de contratos públicos. Contudo, esses métodos são aplicados de forma isolada, enquanto o sistema desenvolvido neste trabalho adota uma abordagem mais holística, integrando várias técnicas, tanto estatísticas quanto baseadas em inteligência artificial, para fornecer uma solução completa.

5.3 Limitações da Pesquisa

Apesar das contribuições significativas, este trabalho apresenta limitações. A principal limitação está na segunda versão do software, que incorpora Aprendizado de Máquina. A assertividade de 70%

no uso do *TensorFlow*, embora promissora, ainda está aquém do desejável para garantir a total confiabilidade no cálculo dos preços de referência.

Isso se deve, em parte, à complexidade dos dados utilizados, que apresentam uma alta variabilidade entre diferentes categorias de produtos e fornecedores. O treinamento do modelo exigiu um tempo considerável de processamento, o que pode ser um desafio para sua aplicação em cenários de uso real em larga escala.

Outra limitação é a dependência de grandes volumes de dados para o funcionamento da segunda versão do software. Embora os 500 mil preços coletados tenham sido suficientes para os experimentos realizados, a coleta contínua de novos dados será necessária para manter a precisão do modelo de Aprendizado de Máquina ao longo do tempo. A gestão de bases de dados dessa magnitude pode representar um desafio para órgãos públicos com infraestrutura limitada.

5.4 Trabalhos Futuros

Os próximos passos de pesquisa envolvem aprimorar o modelo de Aprendizado de Máquina para aumentar sua assertividade, explorando técnicas como aprendizado semi-supervisionado ou *transfer learning*, que podem reduzir a necessidade de grandes volumes de dados para o treinamento.

Será importante investigar a utilização de modelos mais sofisticados, como redes neurais recorrentes (RNN) ou *transformers*, que podem lidar melhor com séries temporais e dados sequenciais, potencialmente melhorando a detecção de padrões irregulares de preços ao longo do tempo.

Outro ponto a ser explorado em trabalhos futuros é a implementação de um sistema de recomendação para gestores públicos, que poderia sugerir os melhores fornecedores com base nos históricos de licitações passadas e nas tendências de mercado. Essa função poderia ser incorporada à versão do software com Aprendizado de Máquina, oferecendo uma solução mais abrangente para o setor público.

Por fim, a aplicação do software em outros contextos, como licitações internacionais ou setores específicos como infraestrutura e saúde, também será investigada. A personalização dos algoritmos para atender às necessidades de diferentes categorias de produtos e serviços pode ampliar ainda mais o impacto da ferramenta proposta.

6 Conclusão

Este trabalho apresentou o desenvolvimento de um software inovador para formação de preço de referência em licitações públicas brasileiras, utilizando técnicas estatísticas e Aprendizado de Máquina, com o objetivo de aprimorar a precisão na definição de preços de referência e fomentar auditoria de preços públicos. A implementação em *Spring Boot*, aliada ao uso de *TensorFlow* por meio do JNL, mostrou-se promissora ao combinar métodos tradicionais com abordagens modernas de inteligência artificial.

Os resultados obtidos mostram que o sistema, em sua versão inicial de seletor de algoritmos é capaz de reduzir significativamente o desvio de preços em relação aos métodos utilizados por órgãos públicos, com uma variabilidade de apenas 2,53%. A segunda versão, com Aprendizado de Máquina, embora com uma assertividade de

70%, oferece uma camada adicional de verificação, contribuindo para maior segurança no processo de auditoria.

As contribuições deste trabalho estão alinhadas com os temas de transparência e eficiência em sistemas de informação aplicados ao setor público. A utilização de dados abertos e algoritmos avançados de Aprendizado de Máquina destaca-se como uma solução inovadora para um dos maiores desafios enfrentados pelo governo brasileiro: a gestão eficiente de recursos em compras públicas.

A pesquisa também avança na direção dos Grandes Desafios da Pesquisa em Sistemas de Informação no Brasil para a Década de 2016-2026, ao propor o uso de tecnologias de análise preditiva para promover a melhoria contínua dos serviços públicos. O uso de dados em larga escala e a automatização de processos de auditoria, por meio de soluções modulares, respondem diretamente aos desafios relacionados à integração de dados e ao uso de sistemas de informação para a gestão inteligente do setor público.

Este trabalho contribui para a adoção de IA aplicada à formação de preços de referência e auditoria pública, o que abre novas oportunidades para a utilização de algoritmos preditivos na detecção de fraudes e irregularidades em processos licitatórios. Ao automatizar o cálculo de preços de referência e integrar algoritmos de Aprendizado de Máquina, este estudo oferece uma solução viável e escalável para o uso em diferentes níveis de governo, potencialmente impactando outras áreas, como a saúde e a infraestrutura.

Como trabalhos futuros, pretende-se melhorar a assertividade do sistema baseado em Aprendizado de Máquina, investigando o uso de novas técnicas, como aprendizado semi-supervisionado e redes neurais mais sofisticadas. A expansão do sistema para outras áreas de aplicação, como licitações internacionais e setores específicos, também será explorada, buscando consolidar o software como uma ferramenta essencial para a auditoria e gestão de compras públicas no Brasil.

Com base nos resultados obtidos e nas perspectivas de aprimoramento, este trabalho representa uma contribuição importante para a área de sistemas de informação aplicada ao setor público, com potencial para otimizar a utilização dos recursos públicos e promover maior transparência e eficiência nos processos de compras governamentais.

Referências

- [1] Edna Hercules Augusto, Raquel Puti, Alexandre Silva Santos, and Ana Rita Tiradentes Terra Argoud. 2021. Mapeamento de Processo e Análise de Riscos de Fraude na Dispensa de Licitação em Razão da COVID-19. *Caderno de Administração* 29, 2 (2021), 116–140.
- [2] Franklin Brasil. 2019. *Preço de Referência em Compras Públicas: Ênfase em Medicamentos* (3 ed.). Publicontas, Cuiabá, Brasil.
- [3] Maurício Soares Bugarin and Flávia Ceccato Rodrigues da Cunha. 2017. Lei de Benford aplicada à auditoria da reforma do Aeroporto Internacional de Minas Gerais. *Revista do Serviço Público* 68, 4 (2017), 915–940.
- [4] Carlos Henrique Harper Cox. 2021. Orçamento Estimativo nas Licitações e Contratações Diretas Realizadas pela Administração Pública. *Revista de Administração Pública* 57, 2 (2021), 234–254.
- [5] Flávia Ceccato Rodrigues da Cunha and Maurício Soares Bugarin. 2014. Lei de Benford e Auditoria de Obras Públicas: uma análise de sobrepreço na reforma do Maracanã. *Revista do TCU* 131 (2014), 46–53.
- [6] Anderson Mateus da Silva Costa and Anuska Macedo Santos de França Paiva Maia. 2022. Análise dos Parâmetros de Pesquisas e de Cálculos de Precificações Adotados pela Administração Pública. *Auditoria e Controladoria no Setor Público* (2022).
- [7] Cristiano Jorge Pobel de Castro. 2022. A Formação de Preços em Compras Públicas de TIC: Uma Abordagem Baseada na Teoria Econômica de Leilões. *Revista de Compras Governamentais* 47, 2 (2022), 234–254.
- [8] Janaina Barboza de Castro e Maria Isabel de Paula Ribeiro. 2024. Análise da orçamentação dos custos com o Canteiro de Obras e a Administração local das licitações de obras públicas do Estado do Rio de Janeiro. *Boletim do Gerenciamento* 43, 43 (2024).
- [9] Jorge Luiz de Castro e Silva, Maria Wilda Fernandes, and Rosa Livia Freitas de Almeida. 2015. *Estatística e Probabilidade* (3 ed.). EdUECE, Fortaleza, Brasil.
- [10] Viviane Leite Dias de Mattos, Andréa Cristina Konrath, and Ana Maria Volkmer de Azambuja. 2017. *Introdução à Estatística - Aplicações em Ciências Exatas* (1 ed.). LTC, Rio de Janeiro.
- [11] Instituto Federal de Sergipe. 2020. *Manual de Pesquisa de Preços Adaptado à IN 73/2020*. Sergipe, Brasil.
- [12] Michel Madureira Loures de Souza. 2019. Eficácia e Economicidade das Licitações Realizadas pela Procuradoria-Geral do Trabalho Após a Mudança da Metodologia de Pesquisa de Preços. *Boletim Científico ESMPU* 18, 54 (2019), 407–445.
- [13] José dos Santos Carvalho Filho. 2018. *Manual de Direito Administrativo* (32 ed.). Atlas, São Paulo, Brasil.
- [14] Eduardo Faria. 2024. Engenharia de Software e Estatística no Apoio à Educação a Distância. *Anais CIET-Horizonte* 7, 1 (maio 2024).
- [15] Marcos Benítez Guayuan, Julio César Mello-Román, Rafael Fermin Palau Heikel, Marcelo López Cremona, Marco Aurelio Aquino, Ilse Grau Yegros, and Carmen Martinez Wenninger. 2023. Deployment and Automatic Registration of REST APIs using Jenkins, Spring Boot and WSO2 API Manager. In *2023 18th Iberian Conference on Information Systems and Technologies (CISTI)*. 20–23.
- [16] Edemilton Alcides Galindo Junior, Romeu Dias Rocha, and Ronierison de Souza Maciel. 2021. Desenvolvimento de API REST com Spring Boot. *Revista Científica do UniRios* 1 (2021), 499–525.
- [17] Manjula Kalita, Lipi B. Mahanta, Anup Kumar Das, and Mananjay Nath. 2024. A new deep learning model with interface for fine needle aspiration cytology image-based breast cancer detection. *Indonesian Journal of Electrical Engineering and Computer Science* 34, 3 (2024), 1739–1752.
- [18] Sungho Lee. 2019. JNI program analysis with automatically extracted C semantic summary. In *Proceedings of the 28th ACM SIGSOFT International Symposium on Software Testing and Analysis*. 448–451.
- [19] Hui Lu, Chengjie Jin, Xiaohan Helu, Chunsheng Zhu, Nadra Guizani, and Zhihong Tian. 2021. AutoD: Intelligent Blockchain Application Unpacking Based on JNI Layer Deception Call. *IEEE Network* 35, 2 (2021), 215–221.
- [20] Maria Sylvia Zanella Di Pietro. 2018. *Direito Administrativo* (31 ed.). Forense, Rio de Janeiro, Brasil.
- [21] Paulo César Roxo Ramos, Roberto de Goes Ellery Junior, and Antônio Nascimento Junior. 2021. Lei de Benford e Inteligência Artificial: Uma Integração no Trabalho de Auditoria em uma Perspectiva Regional. *DRPES* 2, 1 (2021), 1–22.
- [22] Andre Luiz Monteiro Rocha, Matheus Scatolino de Rezende, and Tiago Chaves Oliveira. 2022. Alice: Desafios, resultados e perspectivas da ferramenta de auditoria contínua de compras públicas governamentais com uso de inteligência artificial. *Revista da CGU* 14, 26 (2022), 296–308.
- [23] Arwa Mohammed Taqi, Fadwa al Azzo, Ahmed Awad, and Mariofanna Milanova. 2019. Skin Lesion Detection by Android Camera based on SSD-MobileNet and TensorFlow Object Detection API. *Journal of Advanced Research* 3, 1 (2019), 6–12.
- [24] Ahmet Ercan Topcu, Yehia Ibrahim Alzoubi, Ersin Elbasi, and Emre Camalan. 2023. Social Media Zero-Day Attack Detection Using TensorFlow. *Electronics* 12, 3554 (2023).
- [25] Farhan Ullah, Hamad Naeem, Muhammad Rashid Naeem, Sohail Jabbar, Shehazad Khalid, Fadi Al-Turjman, and Abdelrahman Abuarqoub. 2022. Detection of Clone Scammers in Android Markets using IoT-Based Edge Computing. *Transactions on Emerging Telecommunications Technologies* 33 (2022), e3791.
- [26] José Miguel Ponce Zambrano and Ignacio Wilhem Llor Colamarco. 2020. Diferencias entre presupuestos referenciales y ejecutados en licitación de obra pública. *Revista San Gregorio* 43 (2020), 1–20.

Received 20 February 2007; revised 12 March 2009; accepted 5 June 2009