

Nota Conforme: Sistema Integrado para Classificação Automatizada de Serviços em NFS-e com Machine Learning

Tarcísio Paraíso Farias¹, Thiago Souto Mendes¹, Rafael Sena da Conceição²

¹Programa de Pós-Graduação em Engenharia de Sistemas e Produtos (PPGESP)
Instituto Federal de Educação, Ciência e Tecnologia da Bahia (IFBA)

tarcisioparaíso@gmail.com, thiagosouto@ifba.edu.br

²Secretaria de Finanças - Prefeitura do Recife (PE)

rafaelsena@gmail.com

Abstract. This article presents *Nota Conforme*, a system developed to support the Recife-PE City Hall in the inspection processes of Electronic Service Invoices (NFS-e). Through machine learning, the system automatically classifies the services described in the NFS-e documents issued within the healthcare sector. The tool offers integration with the city hall's internal systems via API, aiming to assist auditors in identifying possible tax fraud, as well as enabling the automation of tasks such as sending emails and communicating with the NFS-e issuer, in order to alert taxpayers about potential inconsistencies.

Resumo. Este artigo apresenta o *Nota Conforme*, um sistema desenvolvido para apoiar a Prefeitura do Recife-PE nos processos de fiscalização em Notas Fiscais de Serviços Eletrônicas (NFS-e). Por meio de aprendizado de máquina, o sistema classifica automaticamente os serviços descritos nas NFS-e do setor de saúde. A ferramenta oferece integração com sistemas internos da prefeitura por meio de API, para auxiliar os auditores na identificação de possíveis fraudes fiscais. Além disso, possibilita a automatização de tarefas como o envio de e-mails e a comunicação com o próprio emissor de NFS-e, com o objetivo de notificar os contribuintes sobre eventuais inconsistências identificadas.

1. Introdução

A Nota Fiscal de Serviços Eletrônica (NFS-e) é um documento digital que registra operações de prestação de serviços [ABRASF 2008], contribuindo para a eficiência da administração tributária [Neto and Martinez 2016]. Contudo, práticas fraudulentas visam reduzir tributos [Dias and Becker 2017], configurando sonegação fiscal [BRASIL 1965] e prejudicando investimentos sociais [De Macedo and Diniz Filho 2019]. Assim, o monitoramento eficaz é essencial para mitigar esse problema [Pinheiro and Cunha 2009].

Entretanto, dada a inviabilidade da análise humana diante da complexidade e do volume das bases de dados municipais, a implementação de ferramentas de Inteligência Artificial (IA) pode potencializar a extração de informações relevantes e aprimorar significativamente os processos de fiscalização [Dos Anjos and Pinheiro 2024]. Diante disso, este estudo tem como objetivo apresentar o sistema Nota Conforme¹, desenvolvido para atender à demanda da Prefeitura do Recife-PE por uma solução automatizada

¹Vídeo de demonstração: <https://youtu.be/OLaRtmSYXY> e repositório com o código fonte: <https://github.com/tpfarias/notaconforme>

na classificação dos serviços descritos nas NFS-e do setor de saúde, o segmento foi escolhido inicialmente devido à sua relevância apontada por auditores, especialmente em relação ao volume de notas e à ocorrência de inconsistências.

Seu principal objetivo é apoiar a fiscalização, auxiliando na identificação de divergências entre os serviços declarados e as alíquotas aplicadas. Além disso, o Nota Conforme permite a integração com sistemas internos de monitoramento, viabilizando o envio de alertas e relatórios de inconsistências para os contribuintes. Dessa forma, a proposta visa contribuir para a modernização da gestão tributária municipal, ao promover maior eficiência, transparência e assertividade nas ações de fiscalização.

2. Trabalhos Relacionados

Estudos recentes investigaram o uso de técnicas computacionais na classificação de dados fiscais. [Gomes 2023] propôs um sistema de *machine learning* (ML) para classificar Órteses, Próteses e Materiais Especiais com base na descrição de produtos em NF-e, por meio de interface para entrada textual e exibição de resultados. Já [Lins Neto 2021] desenvolveu um conjunto de regras para identificar NFS-e suspeitas de fraude na Construção Civil, implementadas em sistema que processa arquivos CSV e gera saídas classificadas.

Outros trabalhos focaram em modelos preditivos para detectar fraudes fiscais [De Araujo Neto 2021, Dias and Becker 2017, Soares and Cunha 2020], sem propor sistema para aplicação prática. Diferente desses estudos, este avança com duas contribuições principais: (i) abordagem centrada na classificação multirrótulo de códigos de serviço, oferecendo maior flexibilidade e durabilidade na análise fiscal; e (ii) desenvolvimento de API de predição que facilita a integração da solução com sistemas diversos.

3. O Sistema Nota Conforme

3.1. Modelo Preditivo

O modelo preditivo foi escolhido com base na avaliação comparativa de sete algoritmos de ML, conforme apresentado na Tabela 1. A base de dados utilizada no experimento compreende aproximadamente 5,69 milhões de NFS-e referentes a serviços da área de saúde, emitidas entre 2022 e 2024 na Prefeitura do Recife-PE. As NFS-e foram rotuladas manualmente com base na descrição, resultando em 21 serviços do setor. Devido à presença de descrições genéricas que impedem a identificação de um serviço, criou-se uma 22^a classe para tais instâncias.

Tabela 1. Desempenho dos Modelos Preditivos

Modelo	Precisão	Recall	F1-Score	HL	TMT	TMP
Random Forest	0,9978	0,9960	0,9969	0,00039	01:47:36	00:01:29
Decision Tree	0,9971	0,9958	0,9965	0,00045	01:45:05	00:00:07
Linear SVM	0,9948	0,9914	0,9931	0,00093	00:10:28	00:00:03
LightGBM	0,9960	0,9901	0,9930	0,00101	00:15:06	00:00:12
Logistic Regression	0,9893	0,9758	0,9825	0,00220	00:01:09	00:00:03
Gradient Boosting	0,9917	0,9553	0,9719	0,00400	03:46:38	00:00:10
Naive Bayes Multinomial	0,9168	0,9490	0,9296	0,00921	00:00:05	00:00:04

TMT: Tempo Médio de Treinamento. **TMP:** Tempo Médio de Predição. **HL:** *Hamming Loss*.

A base original apresentava forte desequilíbrio, com classes concentrando até 25% das amostras, enquanto outras tinham menos de 0,1%. Com o balanceamento, a base passou a ter 2,1 milhões de amostras com distribuição mais uniforme, cujas proporções variam de 4,6% a 11,35%. Os experimentos foram realizados por meio técnica de validação cruzada *K-Fold*, com 5 divisões ($n_splits=5$), implementada na biblioteca *Sklearn*. Para assegurar a reproduzibilidade dos resultados, adotou-se embaralhamento prévio dos dados ($shuffle=True$) e definição explícita do estado aleatório ($random_state = 42$).

O modelo *Random Forest* foi selecionado por apresentar o melhor desempenho geral entre os algoritmos avaliados, com os maiores valores de precisão (0,9978), *recall* (0,9960) e *F1-score* (0,9969). Além disso, obteve o menor valor de *Hamming Loss* (0,00039), evidenciando baixa taxa de erro na classificação multirrotulo.

3.2. Arquitetura do Sistema

O Diagrama de Contexto fornece uma visão geral das integrações da solução [C4 Model 2025], com destaque para o *pipeline* de dados que alimenta o *Data Warehouse* da NFS-e, apoiando a atuação fiscal. O sistema também pode se integrar ao emissor de NFS-e, permitindo a detecção de inconsistências durante a emissão, e ao módulo de envio de e-mails, automatizando a comunicação de inconformidades aos contribuintes.

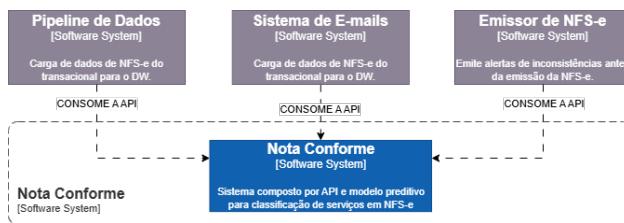


Figura 1. Diagrama de contexto do Nota Conforme

O Diagrama de Contêiner detalha a arquitetura do sistema ao evidenciar a distribuição de responsabilidades entre seus principais componentes [C4 Model 2025]. No Nota Conforme, destacam-se três contêineres: a API, desenvolvida em *Python* com *FastAPI*, que integra sistemas externos, acessa o banco de dados e aciona o modelo preditivo; o Banco de Dados, em PostgreSQL 16.2, exclusivo à API, que armazena dados dos usuários; e o Modelo Preditivo, em *Python*, baseado em *Random Forest* com *TF-IDF* (*Term Frequency-Inverse Document Frequency*), que realiza a classificação dos códigos de serviço nas NFS-e a partir dos dados recebidos da API.

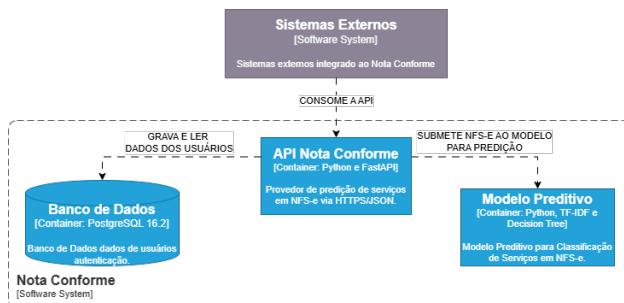


Figura 2. Diagrama de Contêiner do Nota Conforme

Já o Diagrama de Componentes detalha a estrutura interna do sistema, evidenciando os elementos e responsabilidades de cada contêiner [C4 Model 2025]. Na API do Nota Conforme, destacam-se três componentes principais: o CRUD² de Usuários, responsável pelas operações básicas de manipulação de dados; o Componente de Autenticação, que valida credenciais e emite tokens JWT; e o Componente de Predição, que processa NFS-e para identificação dos serviços via modelo preditivo. Esse diagrama é fundamental para compreender a organização e as tecnologias da aplicação.



Figura 3. Diagrama de componentes do Nota Conforme

3.3. Funcionalidades e Demonstração

A Figura 4 apresenta os dois recursos da API do Nota Conforme: **Usuarios** e **Predicoes**. O recurso **Usuarios** contempla funcionalidades de cadastro, alteração, exclusão, recuperação de dados e autenticação. Já o recurso **Predicoes**, recebe conjuntos de NFS-e para classificação dos serviços prestados com base na descrição das notas. Além disso, a figura também detalha os *endpoints* e métodos HTTP associados a cada operação.

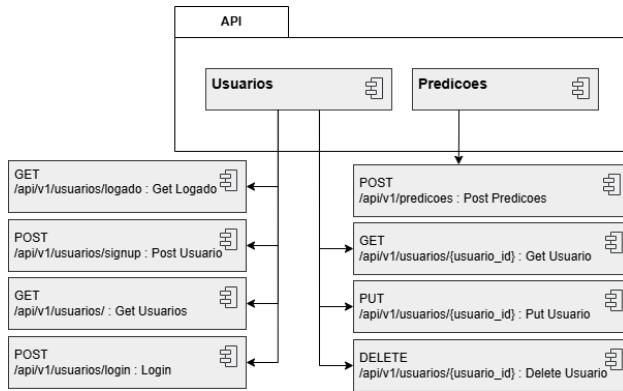
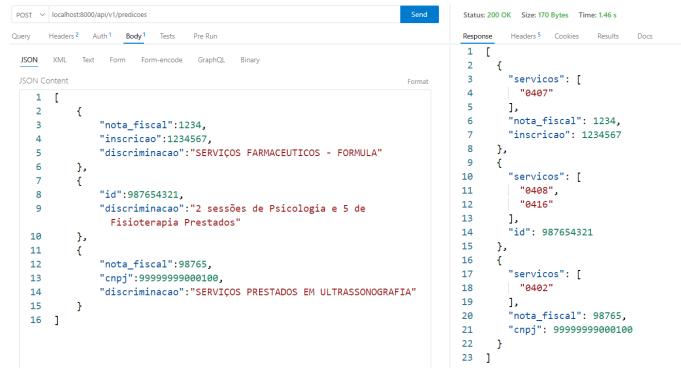


Figura 4. Recursos da API Nota Conforme

Todos os *endpoints* são protegidos e necessitam de autenticação para acesso aos recursos. Através do *endpoint* **login** é realizada a autenticação com usuário e senha por meio do método POST para obtenção do *token* JWT. O *token* será útil para acessar os demais *endpoints*, como o **predicoes**, que além do *token*, deverá enviar os dados das NFS-e que serão classificadas na requisição. Dessa forma, a API responderá com as previsões realizadas pelo modelo.

²CRUD - Acrônimo para as quatro operações básicas de manipulação de dados: *Create* (Criar), *Read* (Ler), *Update* (Atualizar) e *Delete* (Excluir).

Para realizar predições de serviços em NFS-e usando o Nota Conforme, é necessário incluir ao menos o campo **discriminacao** na requisição. Os demais campos são opcionais e podem ser usados conforme a necessidade de cada organização. Conforme apresentado na Figura 5, a resposta da API incluirá o campo **servicos**, com os códigos de serviços identificados na descrição da nota, além dos demais campos enviados, exceto **discriminacao**, que é omitido para reduzir o volume de dados. Isso garante uma solução flexível e compatível com diferentes sistemas.



```

POST /localhost:8000/api/v1/predicts
{
  "nota_fiscal": "1234",
  "inscricao": "1234567",
  "discriminacao": "SERVIÇOS FARMACEUTICOS - FÓRMULA"
}

[{"nota_fiscal": "1234", "inscricao": "1234567", "discriminacao": "SERVIÇOS FARMACEUTICOS - FÓRMULA", "servicos": ["0407"]}, {"nota_fiscal": "987654321", "inscricao": "987654321", "discriminacao": "2 sessões de Psicologia e 5 de Fisioterapia Prestados", "servicos": ["0408", "0416"]}, {"nota_fiscal": "98765", "inscricao": "98765", "discriminacao": "SERVIÇOS PRESTADOS EM ULTRASSONOGRAFIA", "servicos": ["0402"]}]
  
```

Figura 5. Exemplo de requisição e resposta do Nota Conforme

O sistema Nota Conforme foi avaliado em colaboração com auditores da Prefeitura do Recife-PE, por meio da análise de 500 NFS-e selecionadas aleatoriamente. Dois auditores participaram do processo de avaliação. Eles foram responsáveis tanto pela seleção das notas fiscais quanto pela análise manual de desempenho, realizada com base na comparação entre as predições do modelo e a classificação atribuída por eles. A solução apresentou desempenho satisfatório, alcançando um *F1-Score* de 0,945.

Adicionalmente, o processamento da amostra foi concluído em apenas 3,45 segundos, demonstrando boa eficiência computacional. Esse desempenho foi obtido em um computador com processador Intel Core i7-1260P (12 núcleos, 16 threads), 16 GB de RAM e GPU integrada Intel Iris Xe. Embora os resultados sejam promissores para aplicações em tempo real com baixa latência, em cenários com grandes volumes de dados ou ambientes de produção, análises complementares de uso de CPU, memória e paralelização são recomendadas para avaliar sua viabilidade em larga escala.

4. Considerações Finais

O sistema Nota Conforme demonstrou ser uma solução eficaz no apoio aos auditores fiscais, ao facilitar a detecção de inconformidades por meio da classificação automática dos serviços descritos nas NFS-e. A abordagem baseada na identificação dos serviços revelou-se robusta e duradoura, uma vez que não depende de regras fiscais específicas ou temporais, diferentemente de métodos anteriores focados apenas na detecção de fraudes.

A escolha do modelo preditivo foi fundamentada em testes comparativos entre diferentes algoritmos de aprendizado de máquina, considerando tanto a sua assertividade quanto a eficiência computacional. Além disso, o sistema se mostrou promissor ao oferecer integração com diversas ferramentas internas por meio de uma API, ampliando sua aplicabilidade prática.

Como direções para trabalhos futuros, propõe-se ampliar o escopo para incluir serviços de outros setores. Também está prevista o desenvolvimento de uma plataforma para gerir as inconsistências encontradas, bem como incorporar novos atributos da NFS-e que possibilitem o cálculo dos valores evadidos e recuperados, reforçando o suporte à fiscalização. Por fim, planeja-se avaliar abordagens baseadas em *embeddings* para melhor capturar relações semânticas complexas e aprimorar o desempenho do modelo.

Agradecimentos. Este estudo contou com o apoio da Prefeitura do Recife-PE, via Secretaria de Finanças, que forneceu dados e equipe técnica para o projeto.

Referências

- ABRASF (2008). NFS-e: Modelo Conceitual. Versão 1. <https://abrasf.org.br/biblioteca/arquivos-publicos/nfs-e/versao-1-00>. Acesso em: 10 out. 2024.
- BRASIL (1965). Lei nº 4.729, de 14 de julho de 1965. define o crime de sonegação fiscal e dá outras providências. https://www.planalto.gov.br/ccivil_03/leis/1950-1969/14729.htm. Acesso em: 20 jul. 2024.
- C4 Model (2025). C4 model for visualising software architecture. <https://c4model.com/>. Acesso em: 12 abr. 2025.
- De Araujo Neto, A. M. (2021). O uso de processamento de linguagem natural para classificação de produtos no contexto de notas fiscais eletrônicas. Trabalho de Conclusão de Curso de Graduação - Universidade Estadual da Paraíba, Campina Grande.
- De Macedo, C. and Diniz Filho, J. W. d. F. (2019). Sonegação Fiscal: Uma análise dos seus Efeitos na Economia Brasileira. *Revista de Auditoria Governança e Contabilidade*, 7(31). Acesso em: 16 out. 2024.
- Dias, M. and Becker, K. (2017). Identificação de Candidatos à Fiscalização por Evasão do Tributo ISS. *Anais do 5º Symposium on Knowledge Discovery, Mining and Learning*.
- Dos Anjos, P. G. and Pinheiro, M. T. S. (2024). A implementação da inteligência artificial (ia) na fiscalização tributária: inovações disruptivas para eficiência na arrecadação do iptu. *Revista Tributária e de Finanças Públicas*, 159. Acesso em: 30 nov. 2024.
- Gomes, W. F. (2023). Análise exploratória e experimental de aplicações de inteligência artificial para classificação de descrições incongruentes em compras na área de saúde pública. Dissertação, Universidade Federal de Sergipe, São Cristóvão.
- Lins Neto, J. C. (2021). Audita-nfse: sistema auxiliar de auditoria em notas fiscais de serviços eletrônicas. Dissertação, Universidade Federal de Pernambuco, Recife.
- Neto, H. D. A. and Martinez, A. L. (2016). Nota Fiscal de Serviços Eletrônica: Uma análise dos impactos na arrecadação em municípios brasileiros. *Revista de Contabilidade e Organizações*, 10(26):49–62.
- Pinheiro, G. J. and Cunha, L. R. S. (2009). A importância da auditoria na detecção de fraudes. *Contabilidade Vista amp; Revista*, 14(1):31–48.
- Soares, G. and Cunha, R. (2020). Predição de Irregularidade Fiscal dos Contribuintes do Tributo ISS. In *Anais do XXXV Simpósio Brasileiro de Bancos de Dados*, pages 223–228, Porto Alegre, RS, Brasil. SBC.