

---

**FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE**

**O USO DE MACHINE LEARNING  
PARA DETECÇÃO DE ANOMALIAS TECTÔNICAS**

**THE USE OF MACHINE LEARNING FOR TECTONIC ANOMALY  
DETECTION**

Gabriel Rodrigues Cardoso<sup>\*</sup>  
Kauan Kaiky Grossa Takano<sup>\*\*</sup>  
Me. Adriane Cavichioli<sup>\*\*</sup>

**Resumo**

Este estudo investiga o uso do *Total Electron Content* (TEC) como possível precursor sísmico e propõe um fluxo metodológico para detectar anomalias ionosféricas associadas a terremotos por meio de técnicas de *machine learning*. São analisadas referências sobre o acoplamento litosfera-atmosfera-ionosfera e avaliadas as bases *Guardian* (NASA) e CDDIS como fontes globais de dados. O estudo organiza um procedimento de pré-processamento envolvendo séries temporais de TEC, cálculo de medidas estatísticas e definição de limiares para identificação de anomalias. Como principal contribuição, apresenta-se um fluxo conceitual de modelagem supervisionada utilizando *Support Vector Machine* (SVM) e *Random Forest* (RF). Conclui-se que a integração entre bases globais de TEC e algoritmos de aprendizado de máquina representa uma abordagem promissora para estudos de precursores sísmicos.

**Palavras-chave:** *Machine Learning*, *Total Electron Content*, Precursores Sísmicos, Inteligência Artificial, *Random Forest*.

**Abstract**

*This study investigates the use of Total Electron Content (TEC) as a potential seismic precursor and proposes a methodological workflow to detect ionospheric anomalies associated with earthquakes using machine learning techniques. The study reviews literature on lithosphere-atmosphere-ionosphere coupling and evaluates the Guardian (NASA) platform and the CDDIS repository as global data sources. A preprocessing procedure is organized, involving TEC time series, statistical measures, and threshold definition for anomaly identification. As its main contribution, the work presents a conceptual supervised learning workflow employing Support Vector Machine (SVM) and Random Forest (RF). The study concludes that integrating global TEC datasets with machine learning algorithms represents a promising approach for seismic*

---

\* Discente do curso de Tecnologia em Análise e Desenvolvimento de Sistemas, da Faculdade de Presidente Prudente. E-mail: gabriel.cardoso40@fatec.sp.gov.br.

\*\* Discente do curso de Tecnologia em Análise e Desenvolvimento de Sistemas, da Faculdade de Presidente Prudente. E-mail: kauan.takano@fatec.sp.gov.br.

\*\* Professora orientadora Me. em Computação Avançada com ênfase em Realidade Virtual, da Faculdade de Presidente Prudente. E-mail: adriane.cavichioli@fatec.sp.gov.br.

---

**FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE**

---

*precursor research.*

**Keywords:** *Machine Learning, Total Electron Content, Seismic Precursors, Artificial Intelligence, Random Forest.*

## 1. INTRODUÇÃO

O *Total Electron Content* (TEC), uma medida da quantidade total de elétrons presentes na ionosfera, desempenha papel central no monitoramento das variações ionosféricas e é amplamente aplicado em sistemas de comunicação por satélite, operações GNSS e estudos de clima espacial. Pesquisas recentes demonstram que flutuações anômalas no TEC podem ocorrer antes de grandes eventos sísmicos, sugerindo seu potencial como precursor de terremotos (LIU et al., 2004; AKHOONDZADEH et al., 2019). Esse comportamento é sustentado por modelos físico-geofísicos que indicam que tensões acumuladas na crosta terrestre promovem a liberação de partículas carregadas e alterações eletromagnéticas que se propagam para a ionosfera, resultando em perturbações detectáveis antes da ruptura sísmica, o que motiva o desenvolvimento de abordagens metodológicas capazes de explorar essas variações em bases de dados globais de TEC (PULINETS; OUZOUNOV, 2011).

A análise do TEC como indicador sísmico, entretanto, apresenta desafios importantes, pois a ionosfera é altamente sensível a fenômenos externos, como tempestades geomagnéticas, ejeções de massa coronal e variações na radiação solar (FULLER-ROWELL et al., 1994). Dessa forma, torna-se essencial distinguir anomalias ionosféricas resultantes de processos tectônicos daquelas associadas a fatores solares e espaciais. Estudos anteriores demonstram que anomalias significativas no TEC, frequentemente identificadas por desvios estatísticos em relação à mediana móvel de referência, podem ser observadas dias antes de terremotos de grande magnitude, reforçando a correlação entre a dinâmica ionosférica e a atividade sísmica (SHARMA et al., 2017; SHARMA et al., 2021). Esses desafios evidenciam a necessidade de procedimentos sistemáticos de pré-processamento e detecção de anomalias em séries temporais de TEC, que possam ser posteriormente integrados a modelos de aprendizado de máquina.

Nesse cenário, técnicas de *machine learning* têm se destacado como uma abordagem promissora para a análise de dados geofísicos complexos, permitindo explorar relações não lineares em grandes volumes de informações. Estudos recentes empregam classificadores

---

**FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE**

como *Support Vector Machine* (SVM) e *Random Forest* (RF) em tarefas de classificação de anomalias ionosféricas e previsão de terremotos. Ainda assim, observa-se a carência de fluxos metodológicos bem definidos que integrem bases globais de TEC e algoritmos de aprendizado de máquina de forma reprodutível e transparente, especialmente no contexto de monitoramento de precursores sísmicos

Diante desse contexto, este artigo tem como objetivo investigar o potencial do TEC como precursor sísmico e propor um fluxo metodológico para detecção de anomalias ionosféricas associadas a terremotos, integrando bases globais de TEC a algoritmos de aprendizado de máquina, em especial SVM e RF. O estudo adota uma abordagem teórico-metodológica: a partir de uma revisão da literatura sobre acoplamento litosfera–atmosfera–ionosfera e do mapeamento das possibilidades de uso da base Guardian e do repositório CDDIS, é estruturado um procedimento de pré-processamento de séries temporais de TEC e um fluxo conceitual de modelagem supervisionada, destinado a subsidiar futuras implementações e validações quantitativas em cenários reais.

## **2. FUNDAMENTAÇÃO TEÓRICA**


A presente seção apresenta a fundamentação teórica que embasa a pesquisa sobre o uso do TEC como possível precursor sísmico, analisando sua relação com fenômenos ionosféricos e geomagnéticos, bem como discutir estudos que aplicam técnicas de *machine learning* à detecção de anomalias precursoras de terremotos, fornecendo base para a proposta metodológica apresentada nas seções seguintes.

### **2.1 TEC, Precursores Sísmicos e Influência Geomagnética/Ionosférica**

O *Total Electron Content* (TEC) representa a quantidade total de elétrons livres na ionosfera ao longo de uma coluna de 1 m<sup>2</sup>, sendo amplamente utilizado no monitoramento ionosférico e em aplicações de posicionamento GNSS e estudos do clima espacial. Evidências científicas indicam que anomalias no TEC podem anteceder eventos sísmicos de grande magnitude, destacando seu potencial como indicador precursor de terremotos (PULINETS; OUZOUNOV, 2011).

**FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE**

Figura 1 – Como funciona a leitura do TEC



Fonte: ResearchGate - Observed Discrepancies in International Reference Ionosphere Model Predictions at a Nigerian Low Latitude Station.

De acordo com o modelo de acoplamento litosfera–atmosfera–ionosfera (LAIC), tensões acumuladas na crosta terrestre antes da ruptura sísmica geram processos físico-químicos que alteram o campo elétrico atmosférico, resultando em perturbações detectáveis na ionosfera. “Essas perturbações podem se manifestar como variações anômalas de densidade eletrônica, observáveis dias antes de grandes eventos sísmicos” (PULINETS; OUZOUNOV, 2011, p. 373).

Pesquisas anteriores, como as de Sharma (2021) e Pulinets (2004), demonstram que flutuações significativas no TEC, muitas vezes observadas dias ou semanas antes de terremotos, podem refletir alterações eletromagnéticas associadas à atividade tectônica. Em análises baseadas em dados de redes GNSS, é comum observar uma depleção gradual no TEC seguida de recuperação pós-evento em terremotos com magnitude superior a 5.0 (SHARMA, 2021).

Entretanto, a ionosfera também é sensível a fenômenos naturais não tectônicos, como tempestades geomagnéticas e explosões solares, que podem induzir variações expressivas no TEC. Essas perturbações são provocadas pela interação de partículas energéticas solares com a magnetosfera terrestre (HUANG ET AL., 1985; FULLER-ROWELL et al., 1994). Durante tais eventos, o aumento da ionização pode elevar o TEC, gerando assinaturas semelhantes às anomalias sísmicas, o que exige cautela na interpretação dos dados.

Para distinguir anomalias de origem sísmica das provocadas por eventos espaciais e

---

**FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE**

geomagnéticos, é essencial o uso de indicadores como os índices Kp e Dst, amplamente aplicados no monitoramento da atividade geomagnética (FULLER-ROWELL et al., 1994). A análise combinada desses parâmetros permite reduzir falsos positivos e melhorar a confiabilidade das detecções.

Diante dessas complexidades, métodos estatísticos tradicionais podem ser insuficientes para capturar os padrões multifatoriais envolvidos. Assim, o emprego de técnicas computacionais avançadas, como *machine learning*, tornam-se fundamentais para identificar assinaturas sísmicas em meio às variações induzidas por fenômenos solares e geomagnéticos, favorecendo a criação de sistemas mais robustos e automatizados de detecção precoce (AKHOONDZADEH et al., 2019).

Nesse sentido, a literatura recente aponta para a necessidade de estruturar fluxos metodológicos que integrem, de forma sistemática, séries temporais de TEC, indicadores geomagnéticos e algoritmos de *machine learning*, lacuna que o presente trabalho busca abordar.

## **2.2 Aplicação de Machine Learning à Análise de Precusores Sísmicos**

O avanço das técnicas de aprendizado de máquina proporcionou significativos progressos em pesquisas voltadas à previsão sísmica. Diferentemente de abordagens estatísticas tradicionais, esses modelos são capazes de identificar relações não lineares e padrões complexos em séries temporais atmosféricas e ionosféricas (SHARMA, 2021).

A pesquisa de Sharma (2021) mostra que algoritmos supervisionados conseguem correlacionar anomalias no TEC com terremotos passados, oferecendo maior sensibilidade e detecção automatizada. De modo similar, Liu et al. (2004) exploraram o uso de redes neurais artificiais para detectar flutuações ionosféricas precursoras, obtendo resultados promissores em acurácia e estabilidade preditiva.

Estudos mais recentes combinam variáveis solares e geomagnéticas, como os índices Kp, Dst e F10.7, para distinguir anomalias originadas por atividade tectônica daquelas causadas por eventos espaciais (AKHOONDZADEH et al., 2019). De acordo com Dimitar et al. (2011), a integração dessas variáveis em modelos de aprendizado profundo contribui para reduzir falsos positivos e aprimorar sistemas de alerta sísmico.

Neste contexto, destacam-se dois algoritmos supervisionados amplamente aplicados na literatura: SVM e *Random Forest*, selecionados neste estudo como base para um fluxo

---

**FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE**

metodológico cuja comparação empírica em dados reais é proposta como etapa futura.

### **2.2.1 *Support Vector Machine (SVM)* na Detecção de Precusores Sísmicos**

O *Support Vector Machine (SVM)* é um método robusto de classificação que busca encontrar hiperplanos que maximizam a margem entre classes, sendo especialmente eficiente em problemas de alta dimensionalidade (Sharma, 2021). Para dados não linearmente separáveis, o SVM utiliza funções kernel, como a *Radial Basis Function (RBF)*, capazes de modelar relações não lineares entre anomalias do TEC e eventos sísmicos associados.

Segundo Sharma (2021), o SVM apresenta boa generalização e estabilidade em diferentes regiões geográficas, especialmente em ambientes com ruído e desbalanceamento de classes. Assim, o algoritmo se mostra adequado para sistemas de alerta sísmico baseados em TEC, pela sua alta capacidade de discriminação em contextos ionosféricos complexos.

### **2.2.2 *Random Forest* Aplicado à Classificação de Anomalias Sísmicas**

O *Random Forest (RF)* é um algoritmo baseado em múltiplas árvores de decisão construídas por bootstrap aggregation (bagging), técnica que promove maior precisão e reduz riscos de overfitting (AKHOONDZADEH et al., 2019). Sua arquitetura permite lidar eficientemente com dados ruidosos e com variáveis correlacionadas, como séries de TEC combinadas a índices solares e geomagnéticos.

Akhoondzadeh et al. (2019) demonstraram que o RF é eficaz na distinção entre anomalias ionosféricas relacionadas a terremotos e distúrbios espaciais, apresentando bom desempenho em cenários reais de monitoramento. Além disso, o algoritmo oferece interpretabilidade, por meio de medidas de importância de atributos, possibilitando identificar quais variáveis contribuem mais para a classificação sísmica.

Sua capacidade de generalização em grandes volumes de dados e de lidar com desbalanceamento torna o RF uma abordagem sólida para detecção de possíveis precursoros sísmicos, justificando sua escolha para comparação neste trabalho.

## **3. METODOLOGIA**

Esta seção descreve os procedimentos metodológicos adotados no estudo, contemplando o tipo de pesquisa, as bases de dados utilizadas e as etapas de análise. Apresentam-se a caracterização da base de TEC, os critérios de organização das séries

---

## FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

temporais e o fluxo geral de tratamento e preparação dos dados que fundamenta a proposta de modelagem.

### 3.1 Tipo de pesquisa e abordagem

A pesquisa desenvolvida neste trabalho é de natureza exploratória e explicativa, com abordagem quantitativa, orientada por um viés teórico-metodológico. Exploratória, por buscar mapear e sistematizar o uso do TEC como possível precursor sísmico em bases de dados globais; explicativa, por discutir os mecanismos físicos associados às anomalias ionosféricas e às perturbações geomagnéticas; e quantitativa, por se apoiar em séries temporais de TEC e em procedimentos estatísticos para caracterização de anomalias.

Do ponto de vista metodológico, o estudo combina revisão bibliográfica sobre acoplamento litosfera–atmosfera–ionosfera e sobre aplicações de *machine learning* em dados geofísicos, com a análise das possibilidades de uso da base Guardian, mantida pela NASA, e do repositório *Crustal Dynamics Data Information System* (CDDIS) como fontes de dados ionosféricos. A partir desses elementos, é proposto um fluxo conceitual de modelagem supervisionada que integra atributos derivados de séries de TEC a classificadores SVM e RF, visando à detecção de anomalias ionosféricas associadas a terremotos.

### 3.2 Base de dados TEC (Guardian e CDDIS)

A base de dados considerada neste estudo está centrada no produto Guardian, desenvolvido pela NASA, que disponibiliza, em ambiente web, informações sobre a evolução do TEC em função de eventos sísmicos recentes. A ferramenta permite selecionar terremotos já catalogados a partir de parâmetros como data, horário (UTC), coordenadas epicentrais e magnitude, identificando quais satélites de navegação (por exemplo, GPS e BeiDou) cruzaram a região de interesse em janelas anteriores e posteriores ao evento. Para cada combinação evento–satélite, o Guardian gera gráficos de séries temporais de TEC, nos quais é possível visualizar variações expressivas associadas à ocorrência do terremoto.

Quando se deseja utilizar esses dados em análises quantitativas, o próprio Guardian fornece o caminho para o repositório CDDIS, que armazena arquivos de leitura de TEC organizados por data e hora, em geral com histórico de até quatro anos. Esses arquivos podem ser obtidos em formato compatível com processamento numérico (como .csv), acompanhados de documentação técnica detalhando os procedimentos de observação, correções aplicadas e

---

## FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

limitações do conjunto de dados.

No contexto deste trabalho, o Guardian e o CDDIS são tratados como fontes primárias de dados para a construção de séries temporais de TEC associadas a eventos sísmicos. O foco recai menos na exaustividade da amostragem e mais na definição de um procedimento replicável de seleção e organização das informações, que possa ser aplicado posteriormente a diferentes regiões tectonicamente ativas.

### 3.3 Procedimentos de análise

Os procedimentos metodológicos adotados podem ser organizados em três etapas principais: (i) seleção e organização dos eventos e das séries de TEC; (ii) pré-processamento e caracterização estatística das séries temporais; e (iii) definição do fluxo conceitual de modelagem supervisionada com SVM e RF.

Na primeira etapa, parte-se da seleção de eventos sísmicos catalogados no Guardian, considerando critérios como magnitude mínima, localização epicentral em regiões tectonicamente ativas e disponibilidade de observações de TEC em uma janela temporal adequada anterior ao evento. Para cada terremoto selecionado, são identificados os satélites GNSS mais relevantes e extraídas as séries temporais de TEC correspondentes, que são então organizadas em uma estrutura de dados única, contendo, para cada instante, valores de TEC, informações de geometria do enlace e metadados associados ao evento sísmico.

Na segunda etapa, procede-se ao pré-processamento das séries temporais de TEC. Esse processo envolve, de forma geral:

- A verificação de consistência dos dados (identificação de lacunas, valores espúrios e outliers instrumentais);
- A aplicação de filtros temporais adequados para atenuar ruídos de alta frequência não relacionados à dinâmica ionosférica de interesse;
- A cálculo de medidas de tendência central e dispersão (tais como mediana e desvio-padrão em janelas móveis), com o objetivo de caracterizar a variabilidade “normal” do TEC;
- A definição de limiares estatísticos para identificação de anomalias, de modo que desvios superiores ou inferiores a esses limites sejam marcados como possíveis assinaturas precursoras ou como efeitos associados a perturbações geomagnéticas e solares.

---

**FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE**

Na terceira etapa, com base nas séries pré-processadas e nas anomalias estatísticas identificadas, é proposto um fluxo conceitual de modelagem supervisionada. Nesse fluxo, cada segmento temporal é descrito por um conjunto de atributos derivados do TEC (por exemplo, amplitude das anomalias, duração, frequência de ocorrência, razão entre valores máximos e mínimos em janelas específicas) e por variáveis auxiliares, como indicadores geomagnéticos e parâmetros do evento sísmico. Esses atributos são, então, organizados em um conjunto de dados rotulado, no qual instantes ou janelas associados à ocorrência de terremotos são distinguidos daqueles em que as variações decorrem predominantemente de fenômenos espaciais ou meteorológicos não tectônicos.

O fluxo proposto contempla a utilização de algoritmos SVM e RF como classificadores principais, em virtude de sua ampla aplicação na literatura em problemas de detecção de anomalias e de sua capacidade de lidar com conjuntos de dados de alta dimensionalidade. Na perspectiva deste estudo, a ênfase recai sobre a estruturação das etapas de preparação e organização dos dados e sobre a definição das entradas do modelo, deixando a implementação prática, o ajuste de hiperparâmetros e a comparação quantitativa de desempenho como escopo para trabalhos futuros. Dessa forma, a metodologia aqui descrita fornece a base necessária para a proposta de fluxo apresentada na seção de resultados, ao mesmo tempo em que assegura transparência e reprodutibilidade dos procedimentos.

A pesquisa adota uma abordagem quantitativa e explicativa, fundamentada na análise de séries temporais do TEC e de variáveis relacionadas à atividade geomagnética e solar, com o objetivo de identificar e classificar anomalias ionosféricas potencialmente associadas a eventos sísmicos. Trata-se também de um estudo bibliográfico e experimental, utilizando dados históricos provenientes de instituições científicas e aplicando técnicas supervisionadas de machine learning.

#### **4. RESULTADOS E DISCUSSÃO**

Nesta seção são apresentados e discutidos os principais resultados teórico-metodológicos do estudo. São detalhadas a caracterização das fontes de dados ionosféricos e geomagnéticos, o procedimento estatístico de detecção de anomalias em séries de TEC, o fluxo conceitual de modelagem com técnicas de *machine learning* e o protocolo proposto para avaliação futura dos modelos.

---

**FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE****4.1 Caracterização das fontes de dados ionosféricos e geomagnéticos**

Como resultado da etapa de mapeamento de dados, foram identificadas e organizadas as principais fontes globais relevantes para o monitoramento ionosférico e para o estudo de precursores sísmicos. Destacam-se, entre elas:

- A *NASA (National Aeronautics and Space Administration)*, responsável por serviços de monitoramento ionosférico baseados em constelações GNSS, produção de séries de TEC, modelos ionosféricos e indicadores de atividade solar;
- O *CODE (Center for Orbit Determination in Europe)*, que disponibiliza mapas globais de TEC gerados a partir de uma rede de estações GNSS distribuídas mundialmente;
- O *The Australian Bureau of Meteorology*, por meio do serviço *Space Weather Services (SWS)*, que oferece modelos ionosféricos e mapas globais de TEC atualizados em tempo quase real, voltados ao monitoramento das condições espaciais e ionosféricas.

Além dos dados ionosféricos, o levantamento considerou indicadores de atividade geomagnética e solar, como os índices Kp e Dst e o fluxo de radiação solar F10.7, fundamentais para distinguir variações induzidas por tempestades geomagnéticas e por ciclos solares de possíveis assinaturas associadas à atividade tectônica. A literatura clássica destaca que perturbações geomagnéticas podem provocar variações significativas na ionosfera, exigindo cuidado na separação entre anomalias naturais e sinais de interesse sísmico (FULLER-ROWELL et al., 1994).

No fluxo proposto, essas diversas fontes são concebidas como componentes de uma estrutura integrada de dados, na qual séries temporais de TEC podem ser associadas a parâmetros geomagnéticos, solares e sísmicos. Esse arranjo fornece base para análises estatísticas e, posteriormente, para a aplicação de métodos de classificação supervisionada.

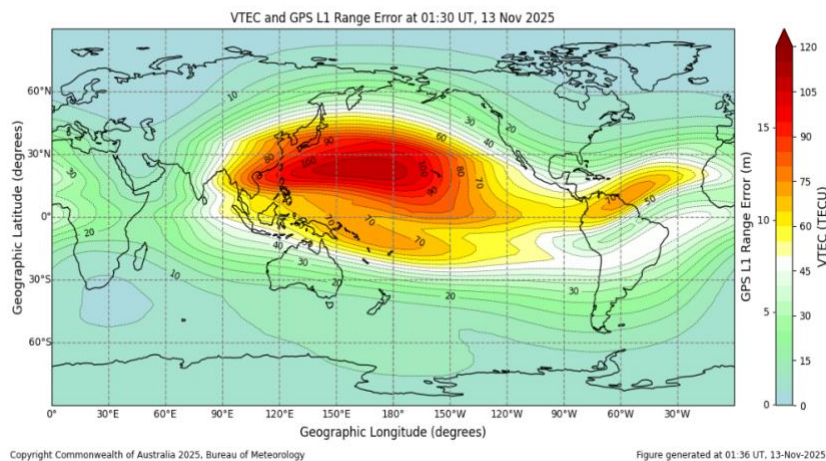
A Figura 2 ilustra um exemplo de mapa global de TEC fornecido pelo SWS, evidenciando a distribuição espacial típica do conteúdo eletrônico total e reforçando a importância de produtos globais para o monitoramento contínuo da ionosfera.

**FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE**

Figura 2 – Mapa mundial de TEC fornecido pelo The Australian Bureau of Meteorology (Atualizado em 13 de novembro de 2025).

**TEC Global Map**

Updates: Every 15 minutes



Fonte: SWS - Total Electron Content - TEC Global Map - [www.sws.bom.gov.au](http://www.sws.bom.gov.au)

#### 4.2 Procedimento estatístico para detecção de anomalias em séries de TEC

A partir da organização das fontes de dados, foi proposto um procedimento estatístico para identificação de anomalias em séries temporais de TEC, com o objetivo de distinguir variações compatíveis com o comportamento “normal” da ionosfera de desvios potencialmente associados a eventos sísmicos.

A segunda etapa do fluxo consiste na aplicação de métodos estatísticos de análise de séries temporais, utilizando janelas móveis para caracterizar a variabilidade local do TEC e realçar desvios significativos. Inspirado em abordagens utilizadas em estudos de precursores ionosféricos (SHARMA, 2021), o procedimento propõe o cálculo de medidas de tendência central e dispersão em janelas de 15 dias, a partir das quais são definidos limites superior e inferior de variação aceitável.

Esses limites são formalizados na Equação 1, que estabelece os valores de referência para a identificação de anomalias. Em linhas gerais, valores de TEC que ultrapassam o limite superior ou se situam abaixo do limite inferior são marcados como anomalias estatísticas, enquanto aqueles que permanecem dentro da faixa delimitada pela equação são interpretados como compatíveis com a variabilidade regular da ionosfera. A utilização de medidas robustas de dispersão e de janelas móveis busca reduzir a influência de outliers instrumentais e de flutuações transitórias não associadas à dinâmica ionosférica relevante.

---

**FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE**

*Limite Superior:*

$$\text{Mediana}_{\{15d\}} + 1,34 \times \sigma$$

*Limite Inferior:*

$$\text{Mediana}_{\{15d\}} - 1,34 \times \sigma$$

Onde  $\sigma$  representa o desvio-padrão da janela móvel de 15 dias. Valores de TEC que ultrapassaram esses limites foram considerados anomalias estatísticas.

Na sequência, cada anomalia identificada é analisada em conjunto com os índices Kp e Dst e com o fluxo F10.7, de modo a avaliar sua possível vinculação a fenômenos geomagnéticos ou solares. Anomalias que ocorrem simultaneamente a períodos de intensa atividade geomagnética tendem a ser interpretadas como efeitos de clima espacial, enquanto aquelas que surgem em contexto geomagnético mais estável, em janelas temporais próximas a grandes eventos sísmicos, são consideradas candidatas a assinaturas precursoras. Esse tipo de abordagem, que combina estatística robusta e análise conjunta de parâmetros ionosféricos e geomagnéticos, é amplamente utilizado em estudos sobre acoplamento litosfera-atmosfera-ionosfera (PULINETS; OUZOUNOV, 2011).

### **4.3 Fluxo conceitual de modelagem com *machine learning***

Com base nas anomalias estatísticas identificadas e na integração conceitual das bases de dados ionosféricas, geomagnéticas e sísmicas, foi elaborado um fluxo conceitual de modelagem supervisionada para a classificação automática de anomalias em séries de TEC. Esse fluxo organiza as etapas necessárias desde a preparação dos dados até a classificação final das janelas temporais, servindo como guia para futuras implementações.

No esquema proposto, segmentos temporais associados a eventos sísmicos e a períodos de controle são descritos por um conjunto de atributos derivados do TEC, tais como amplitude das anomalias, duração, frequência de ocorrência, gradientes temporais, razão entre valores máximos e mínimos em janelas específicas, entre outros. Esses atributos podem ser complementados por variáveis auxiliares, como índices Kp e Dst, fluxo F10.7 e parâmetros do evento sísmico (magnitude, profundidade, distância epicentral).

Tomando como referência estudos que empregam *machine learning* na análise de dados ionosféricos e geofísicos (SHARMA, 2021; AKHOONDZADEH et al., 2019), o fluxo adota como classificadores principais os algoritmos SVM e RF. O SVM, especialmente com

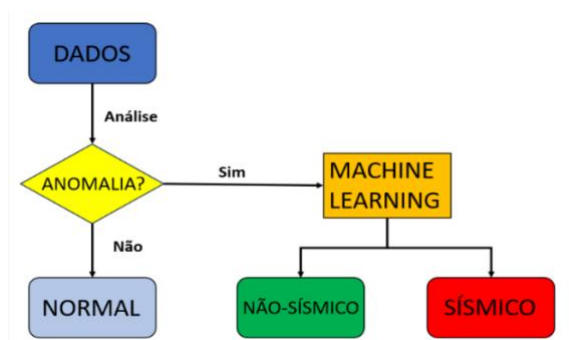
**FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE**

kernel radial (RBF), destaca-se pela capacidade de discriminar padrões complexos em dados de alta dimensionalidade (SHARMA, 2021), enquanto o Random Forest se mostra eficaz em contextos com múltiplos atributos correlacionados e permite estimar a importância relativa das variáveis na classificação (AKHOONDZADEH et al., 2019).

No contexto deste trabalho, a ênfase recai sobre a estruturação conceitual do fluxo, e não sobre a execução completa do treinamento e da comparação empírica entre os modelos. Assim, são descritas as etapas de preparação dos dados, a formação de um conjunto de exemplos rotulados (segmentos com anomalias associadas ou não a terremotos) e a indicação do uso de SVM e RF como algoritmos candidatos para a tarefa de classificação.

A Figura 3 sintetiza o fluxo lógico proposto para a classificação das anomalias, desde a entrada das séries de TEC e dos indicadores geomagnéticos até a etapa de decisão com os classificadores SVM e Random Forest.

Figura 3 – Fluxo lógico de classificação das anomalias utilizando algoritmos de machine learning (SVM e Random Forest).



Fonte: Elaborado pelo autor

#### 4.4 Protocolo de avaliação proposto e implicações

Como desdobramento do fluxo de modelagem, o estudo delinea um protocolo de avaliação para futuras implementações práticas dos classificadores SVM e RF. Esse protocolo recomenda que os modelos sejam testados com base em dados históricos de terremotos, empregando janelas temporais que antecedem e sucedem eventos sísmicos em diferentes regiões, de forma a examinar a capacidade de distinguir anomalias precursoras de variações dominadas por fenômenos geomagnéticos e solares.

Propõe-se que o conjunto de dados seja particionado em subconjuntos de treino, validação e teste, respeitando a estrutura temporal das séries e evitando vazamento de

---

**FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE**

informação entre períodos. A avaliação quantitativa deve contemplar métricas clássicas de classificação, como acurácia, precisão, revocação, *F1-Score* e medidas derivadas da matriz de confusão, de modo a quantificar tanto a capacidade de detecção de verdadeiros positivos quanto o controle de falsos alarmes. Em linha com recomendações presentes na literatura de previsão de eventos extremos em geociências, sugere-se a utilização de intervalos de confiança, por exemplo a 95%, para as métricas de desempenho, aumentando a robustez estatística das conclusões (MOLCHANOV et al., 2004).

Embora a implementação completa desse protocolo ainda não tenha sido realizada no escopo deste trabalho, sua descrição sistemática constitui um resultado conceitual relevante, pois oferece um roteiro claro para futuras avaliações quantitativas. Em conjunto com a caracterização das bases de dados, o método estatístico de detecção de anomalias e o fluxo de modelagem supervisionada com SVM e RF, o protocolo proposto reforça o potencial da combinação entre TEC e técnicas de *machine learning* como abordagem promissora para o estudo de precursores sísmicos e para o desenvolvimento de sistemas de monitoramento em regiões de risco tectônico elevado.

## 5. CONCLUSÃO

Este artigo investigou o potencial do *Total Electron Content* (TEC) como possível precursor sísmico e propôs um fluxo metodológico para detecção de anomalias ionosféricas associadas a terremotos, integrando bases globais de dados a técnicas de *machine learning*. A partir de uma abordagem teórico-metodológica, foram sistematizados conceitos sobre o acoplamento litosfera–atmosfera–ionosfera, discutidos os principais desafios para a utilização do TEC em estudos de precursores sísmicos e analisadas as possibilidades de uso de produtos e serviços mantidos por instituições como NASA, CODE e *Bureau of Meteorology*.

Como contribuição inicial, o trabalho realizou uma caracterização estruturada das fontes de dados ionosféricos e geomagnéticos, destacando o papel do produto Guardian e do repositório CDDIS como bases centrais para a obtenção de séries temporais de TEC associadas a eventos sísmicos. Essa caracterização evidencia a existência de um ecossistema consolidado de dados, capaz de sustentar abordagens quantitativas mais robustas para o monitoramento de anomalias ionosféricas em escala global.

Em seguida, foi proposto um procedimento estatístico de detecção de anomalias em séries de TEC, fundamentado em janelas móveis, medidas de tendência central e dispersão e

---

## FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE

limiares robustos para identificação de desvios significativos. Esse procedimento organiza, de forma transparente, etapas essenciais para diferenciar variações compatíveis com o comportamento “normal” da ionosfera de potenciais assinaturas precursoras, considerando a influência de tempestades geomagnéticas e da atividade solar.

A partir dessas bases, o estudo apresentou como principal resultado um fluxo conceitual de modelagem supervisionada que integra atributos derivados do TEC, indicadores geomagnéticos e parâmetros sísmicos a algoritmos *Support Vector Machine* (SVM) e *Random Forest* (RF). O fluxo descreve as etapas necessárias desde a seleção dos eventos e a construção das séries temporais até a formação de conjuntos de dados rotulados e a aplicação de classificadores para distinguir anomalias associadas a terremotos de variações não tectônicas. Complementarmente, foi delineado um protocolo de avaliação para futuras implementações, contemplando estratégias de particionamento temporal dos dados e métricas adequadas à validação de modelos de classificação em séries históricas de terremotos.

É importante ressaltar que a contribuição deste trabalho é predominantemente conceitual e metodológica. A implementação prática dos modelos SVM e RF, o ajuste de hiperparâmetros, a comparação quantitativa de desempenho e a aplicação em séries extensas de TEC não foram realizados no escopo deste artigo, sendo propostos como desdobramentos futuros. Nessa perspectiva, o fluxo metodológico e o protocolo de avaliação aqui descritos constituem um roteiro para pesquisas subsequentes interessadas em quantificar o desempenho de sistemas de alerta baseados em anomalias ionosféricas.

Como trabalhos futuros, recomenda-se: (i) a implementação e teste do fluxo proposto em conjuntos de dados reais provenientes do Guardian e do CDDIS, englobando diferentes regiões tectonicamente ativas; (ii) a comparação sistemática entre diferentes algoritmos de *machine learning* e estratégias de seleção de atributos; e (iii) a incorporação de incertezas associadas às medições e aos modelos ionosféricos, de modo a aprimorar a confiabilidade das inferências. Espera-se que as contribuições teórico-metodológicas apresentadas possam apoiar o desenvolvimento de sistemas de monitoramento mais integrados, colaborando, em médio e longo prazo, para estratégias de mitigação de riscos em áreas de elevada suscetibilidade a terremotos.

## REFERÊNCIAS

---

**FACULDADE DE TECNOLOGIA DE PRESIDENTE PRUDENTE**

AKHOONDZADEH, M.; DE SANTIS, A.; MARCHETTI, D.; PISCINI, A.; JIN, S. **Anomalous seismo-LAI variations potentially associated with the 2017 Mw 7.3 Sarpol-e Zahab (Iran) Earthquake from Swarm satellites**, *Advances in Space Research*, 2019, v. 64, p. 143–158. Disponível em: <https://doi.org/10.1016/j.asr.2019.03.020> Acesso em: 12 nov. 2025.

ASALY, S.; GOTTLEIB, L.-A.; INBAR, N.; REUVENI, Y. **Using Support Vector Machine (SVM) with GPS ionospheric TEC estimations to potentially predict earthquake events**. *Journal of Geophysical Research: Space Physics*, 2022, v. 14, n. 12, 2822. Disponível em: [https://www.mdpi.com/2072-4292/14/12/2822?utm\\_source=researchgate.net&medium=article](https://www.mdpi.com/2072-4292/14/12/2822?utm_source=researchgate.net&medium=article) Acesso em: 12 nov. 2025.

AKYOL, A. A.; ARIKAN, O.; ARIKAN, F. **A machine learning-based detection of earthquake precursors using ionospheric data**. *Radio Science*, 2020, 55, e2019RS006931. Disponível em: <https://doi.org/10.1029/2019RS006931>. Acesso em: 13 nov. 2025.

BUDIMAN, K. **Analysis of earthquake forecasting using Random Forest**. *Journal of Seismic & Civil Engineering*, 2021, vol. 2, no. 2, pp. 153-162. Disponível em: <https://doi.org/10.52465/joscex.v2i2.51>. Acesso em 13 nov. 2025.

FULLER-ROWELL, T. J.; CODRESCU, M. V.; MOFFETT, R. J.; QUEGAN, S. **Response of the thermosphere and ionosphere to geomagnetic storms**. *Journal of Geophysical Research: Space Physics*, 1994, v. 99, n. A3, p. 3893–3914. Disponível em: <https://doi.org/10.1029/93JA02015> Acesso em: 12 nov. 2025.

LIU, J. Y.; CHUO, Y. J.; SHAN, S. J.; TSAI, Y. B.; CHEN, Y. I.; PULINETS, S. A.; YU, S. B. **Pre-earthquake ionospheric anomalies registered by continuous GPS TEC measurements**. *Geophysical Research Letters*, 2004, v. 31. Disponível em: <https://doi.org/10.1029/2003GL018896>. Acesso em: 12 nov. 2025.

PULINETS, S.; OUZOUNOV, D. **Lithosphere–atmosphere–ionosphere coupling (LAIC) model – a unified concept for earthquake precursors validation**. *Journal of Asian Earth Sciences*, 2011, v. 41, n. 4-5, p. 371–382. Disponível em: <https://doi.org/10.1016/j.jseaes.2010.03.005>. Acesso em: 12 nov. 2025.

SHARMA, G.; CHAMPATIRAY, P. K.; MOHANTY, S.; GAUTAM, P. K. **Ionospheric TEC modelling for earthquakes precursors from GNSS data**. *Quaternary International*, 2017, v. 462, p. 65–74. Disponível em: <https://doi.org/10.1016/j.quaint.2017.05.007>. Acesso em: 13 nov. 2025.

SHARMA, G.; SOUBAM, M.; WALIA, D.; NISHANT, N.; SARMA, K. K.; RAJU, P. L. N. **Development of a monitoring system for ionospheric TEC variability before the earthquakes**. *Applied Computing and Geosciences*, 2021, v. 9, 100052. Disponível em: <https://doi.org/10.1016/j.quaint.2016.10.038>. Acesso em: 13 nov. 2025.

## **Agradecimentos**

### **Por Gabriel Cardoso**

Agradeço a Deus pela orientação, à minha namorada Giovana pelo apoio constante, à minha família por acreditar no meu potencial e aos colegas de sala, cujo companheirismo foi essencial para superar desafios e concluir esta jornada.