



UNIVERSIDADE FEDERAL DO MARANHÃO
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA
BACHARELADO INTERDISCIPLINAR EM CIÊNCIAS E TECNOLOGIA

MAPEAMENTO DA OCORRÊNCIA DA CINTILAÇÃO IONOSFÉRICA NO BRASIL

São Luís - MA

2024

**ANTONIO LUCAS DA SILVA VALE
JOÃO GUILHERME MIRANDA LAGO
LUCAS MARTINS CAMPOS MATOS**

**MAPEAMENTO DA OCORRÊNCIA DA CINTILAÇÃO
IONOSFÉRICA NO BRASIL**

A monografia apresentada ao curso do Bacharelado Interdisciplinar em Ciências e Tecnologia da Universidade Federal do Maranhão (UFMA), como parte do Trabalho de Conclusão do Curso (TCC) e requisito parcial para obtenção do diploma de Bacharel em Ciências e Tecnologia.

Orientador: Prof. Dr. Alex Oliveira Barradas Filho

São Luís - MA

2024

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Diretoria Integrada de Bibliotecas/UFMA

Campos Matos, Lucas Martins.

Mapeamento da Ocorrência da Cintilação Ionosférica no Brasil / Lucas Martins Campos Matos, Antônio Lucas da Silva Vale, João Guilherme Miranda Lago. - 2025.

59 p.

Orientador(a): Alex Oliveira Barradas Filho.

Curso de Ciência e Tecnologia, Universidade Federal do Maranhão, São Luís, 2025.

1. Cintilação Ionosférica. 2. Modelos Preditivos. 3. Aprendizado de Máquina. 4. Mapeamento Espacial. 5. Sistema Web. I. da Silva Vale, Antônio Lucas. II. Miranda Lago, João Guilherme. III. Oliveira Barradas Filho, Alex. IV. Título.

**ANTONIO LUCAS DA SILVA VALE
JOÃO GUILHERME MIRANDA LAGO
LUCAS MARTINS CAMPOS MATOS**

MAPEAMENTO DA OCORRÊNCIA DA CINTILAÇÃO IONOSFÉRICA NO BRASIL

Monografia apresentada ao curso do Bacharelado Interdisciplinar em Ciências e Tecnologia da Universidade Federal do Maranhão (UFMA), como parte do Trabalho de Conclusão do Curso (TCC) e requisito parcial para obtenção do diploma de Bacharel em Ciências e Tecnologia.

Aprovado em: __/__/____

Conceito: _____

BANCA EXAMINADORA

Prof. Dr. Alex Oliveira Barradas filho (Orientador)

Coordenação do Programa de Pós-Graduação em Engenharia Aeroespacial
Universidade Federal do Maranhão

Prof. Dr. Luís Jorge Enrique Rivero Cabrejos (Avaliador 1)

Coordenação do Curso de Engenharia da Computação
Universidade Federal do Maranhão

Prof. Dr. Davi Viana dos Santos (Avaliador 2)

Coordenação do Programa de Pós-Graduação em Ciência da Computação
Universidade Federal do Maranhão

AGRADECIMENTOS

Agradecemos, primeiramente, a Deus, por nos conceder a oportunidade, força e sabedoria para concluirmos este projeto, guiando-nos em cada etapa desta jornada. Ao professor doutor Alex Barradas de Oliveira Filho, expressamos nossa profunda gratidão por sua orientação, paciência e dedicação ao longo de todo o processo. Seu conhecimento e apoio foram fundamentais para enfrentarmos desafios e aprimorarmos nossa pesquisa.

Aos nossos familiares e amigos, agradecemos pelo apoio incondicional, compreensão e incentivo constante. Em cada momento de dificuldade, estiveram ao nosso lado, oferecendo palavras de encorajamento e tornando essa trajetória mais leve e significativa.

Também somos gratos aos colegas de sala e professores, que, direta ou indiretamente, contribuíram para nossa formação e para o desenvolvimento deste trabalho, compartilhando conhecimento e experiências valiosas.

Um agradecimento especial a Otávio Carvalho, cuja tese de mestrado serviu como base fundamental para este estudo. Seu trabalho foi essencial para o desenvolvimento desta pesquisa, e sua dedicação à ciência é uma inspiração.

Por fim, agradecemos a todos que, de alguma forma, participaram dessa caminhada, seja por meio do compartilhamento de ideias, do suporte técnico ou do simples gesto de motivação. Este trabalho é fruto não apenas do nosso esforço, mas também do apoio e inspiração que recebemos ao longo do caminho.

*“Consagre ao Senhor tudo o que
você faz, e os seus planos serão
bem-sucedidos.”*

~ Provérbios 16:3

RESUMO

A cintilação ionosférica é um fenômeno que afeta a propagação de sinais eletromagnéticos, causando flutuações na intensidade e fase dos sinais de rádio e GNSS (Global Navigation Satellite System). Essas perturbações podem comprometer sistemas essenciais do dia a dia, como navegação por satélite, telecomunicações e monitoramento climático, tornando sua previsão fundamental para minimizar impactos em setores críticos. Dada a complexidade desse fenômeno, impulsionada por fatores como atividade solar, variabilidade geomagnética e irregularidades na ionosfera, torna-se essencial o desenvolvimento de métodos preditivos avançados para compreender e antecipar sua ocorrência. O presente trabalho tem como principal objetivo desenvolver modelos preditivos e métodos de mapeamento espacial para monitorar e antecipar a cintilação ionosférica de amplitude. Para isso, são exploradas técnicas de aprendizado de máquina, considerando as variáveis citadas, que avaliam como essas informações impactam o comportamento do fenômeno. A metodologia adotada estuda a eficácia do uso de algoritmos como Long Short-Term Memory (LSTM), XGBoost e Random Forest para análise e previsão. Além disso, foi desenvolvido um sistema web utilizando a linguagem Python e o framework Flask, integrando bibliotecas como Folium e Pandas para visualização geoespacial dos resultados. Os principais achados indicam que os modelos são capazes de prever a cintilação ionosférica com 30 minutos de antecedência, permitindo a visualização dos dados por meio de mapas interativos acessíveis na plataforma web. Por fim, são indicados os direcionamentos para futuras pesquisas.

Palavras-chaves : Cintilação ionosférica , modelos preditivos , aprendizado de máquina , mapeamento espacial , sistema web

ABSTRACT

Ionospheric scintillation is a phenomenon that affects the propagation of electromagnetic signals, causing fluctuations in the intensity and phase of radio and GNSS (Global Navigation Satellite System) signals. These disturbances can compromise essential daily systems such as satellite navigation, telecommunications, and climate monitoring, making their prediction fundamental to minimizing impacts in critical sectors. Given the complexity of this phenomenon, driven by factors such as solar activity, geomagnetic variability, and ionospheric irregularities, the development of advanced predictive methods becomes essential to understand and anticipate its occurrence. This study aims to develop predictive models and spatial mapping methods to monitor and anticipate amplitude ionospheric scintillation. To achieve this, machine learning techniques are explored, considering the mentioned variables to evaluate how these factors impact the phenomenon's behavior. The adopted methodology involves the review of the use of algorithms such as Long Short-Term Memory (LSTM), XGBoost, and Random Forest for analysis and prediction. Additionally, a web system was developed using the Python programming language and the Flask framework, integrating libraries such as Folium and Pandas for the geospatial visualization of results. The main findings indicate that the models can predict ionospheric scintillation 30 minutes in advance, allowing data visualization through interactive maps accessible via a web platform. Finally, directions for future research are outlined.

Keywords: Ionospheric scintillation, predictive models, machine learning, spatial mapping, web system.

LISTA DE ILUSTRAÇÕES

Figura 1 – Relação entre sinais GNSS e a cintilação ionosférica.....	25
Fluxograma 1 – Fluxograma da linha de estudos dos aspectos teóricos.	26
Figura 2 – Geometria do cálculo de ponto de perfuração ionosférico.....	41
Imagem 1 – Mapa de calor da cintilação ionosférica mundial.	43
Imagem 2 – Mapa de Entrada.	50
Imagem 3 – Mapa Predito.	50
Imagem 4 – Captura de tela de interface do sistema web.	51
Fluxograma 2 – Fluxograma do sistema web.	52
Imagem 5 – Interação com os mapas antes e depois da predição.....	53

LISTA DE TABELAS

Tabela 1 – Parâmetros da atividade geomagnética.....	29
Tabela 2 – Parâmetros da atividade solar e interplanetária.	30
Tabela 3 – Parâmetros relacionados ao estado da ionosfera derivados de ionossondas.....	30
Tabela 4 – Parâmetros relacionados ao estado da ionosfera derivados de receptores GNSS. .	31
Tabela 5 – Comparativo entre as vantagens e desvantagens das características de cada modelo.	32
Tabela 6 – Desempenho do Modelo Random Forest na Predição da Cintilação Ionosférica. .	45
Tabela 7 – Desempenho do Modelo LSTM na Predição da Cintilação Ionosférica.	46
Tabela 8 – Desempenho do Modelo XGBoost na Predição da Cintilação Ionosférica.	47
Tabela 9 – Comparação entre os modelos de predição.	48

LISTA DE ABREVIATURAS E SIGLAS

AIE	Anomalia de Ionização Equatorial
AMAS	Anomalia Magnética do Atlântico Sul
CALIBRA	Countering GNSS High Accuracy Applications Limitations due to Ionospheric Disturbances in Brazil
CIGALA	Concept for Ionospheric Scintillation Mitigation for Professional GNSS in Latin America
EMBRACE	Estudo e Monitoramento Brasileiro do Clima Espacial
FCT UNESP	Faculdade de Ciências e Tecnologia da Universidade Estadual Paulista
GEGE	Grupo de Estudos de Geodésia Espacial
GSM	Global System for Mobile Communications
GNSS	Global Navigation Satellite System
ICEA	Instituto de Controle do Espaço Aéreo
INCT	Instituto Nacional de Ciência e Tecnologia
INPE	Ponto de Perfuração Ionosférica
IPP	Long Short-Term Memory
LISN	Low-Latitude Ionospheric Sensor Network
LSTM	Long Short-Term Memory
MAE	Erro Médio Absoluto
MSE	Erro Quadrático Médio
OE	Ondas Eletromagnéticas
RF	Random Forest
RNN	Recurrent Neural Networks
TEC	Total Electron Content
XGBoost	Extreme Gradient Boosting

SUMÁRIO

1 INTRODUÇÃO	13
1.1 ASPECTOS GERAIS SOBRE CINTILAÇÃO IONOSFÉRICA	13
1.2 NATUREZA E CAPTURA DOS DADOS DO FENÔMENO CINTILAÇÃO IONOSFÉRICA.....	16
1.2.1 Redes de monitoramento e fontes de dados.....	16
1.3 MÉTODOS PREDITIVOS DA OCORRÊNCIA DA CINTILAÇÃO IONOSFÉRICA .	17
1.3.1 Modelos Preditivos Tradicionais	18
1.3.2 Abordagens Baseada em Aprendizado de Máquina	19
1.3.3 Algoritmos de Aprendizado de Máquina.....	20
1.3.3.1 Random Forest (RF)	20
1.3.3.2 Extreme Gradient Boosting (XGBoost)	20
1.3.3.3 Long Short-Term Memory (LSTM)	21
1.5 ESTADO DA ARTE	21
1.5.1 Monitoramento da Cintilação Ionosférica	21
1.5.2 Modelagem e Previsão da Cintilação	22
1.5.3 Desafios e Perspectivas Futuras	22
2 OBJETIVOS	24
2.1 OBJETIVO GERAL.....	24
2.2 OBJETIVOS ESPECÍFICOS.....	24
3 METODOLOGIA.....	25
3.1 COMPREENSÃO DE ASPECTOS TEÓRICOS DA CINTILAÇÃO	26
3.1.1 Importância da Aprendizagem de Máquina no Estudo da Cintilação Ionosférica	27
3.1.2 Contribuição do Nosso Projeto para o Estudo da Cintilação Ionosférica.....	28
3.2 PREPARAÇÃO DA BASE DE DADOS.....	29
3.3 MÉTODOS PREDITIVOS.....	31
3.3.1 Estrutura de Desenvolvimento dos Modelos	32
3.3.1.1 Carregamento e Pré-processamento dos Dados.....	32
3.3.1.2 Criação de Variáveis de Atraso (Lags).....	33
3.3.1.3 Validação Cruzada: Divisão do Conjunto de Dados	33
3.3.2 Random Forest (RF)	34
3.3.3 XGBoost (Extreme Gradient Boosting)	35
3.3.4 Long Short-Term Memory (LSTM).....	36
3.4 CRITÉRIOS AVALIATIVOS	38
3.4.1 Erro Médio Absoluto (MAE)	38
3.4.2 Erro Quadrático Médio (MSE).....	39
3.4.3 Coeficiente de Determinação (R2)	39
3.4.4 Considerações Sobre as Métricas	39
3.5 MAPEAMENTO DA CINTILAÇÃO IONOSFÉRICA	40

3.5.1	Determinação do Ponto de Perfuração Ionosférica (IPP).....	40
3.5.2	Interpolação Espacial e Temporal	41
3.5.3	Construção do Mapa de Cintilação.....	42
4	RESULTADOS E DISCUSSÕES.....	44
4.1	ANÁLISE DE DESEMPENHO DO RANDOM FOREST	44
4.2	ANÁLISE DE DESEMPENHO DO LSTM	45
4.3	ANÁLISE DE DESEMPENHO DO XGBOOST	46
4.4	COMPARAÇÃO DOS MODELOS E SELEÇÃO DO MAIS EFICIENTE	47
4.5	MAPEAMENTO E SISTEMA PROPOSTO	49
4.5.1	Geração de Mapas de Cintilação Ionosférica	49
4.5.2	Sistema Web Desenvolvido para Visualização dos Mapas	50
4.5.3	Aplicações e Impacto do Sistema de Mapeamento	52
5	CONCLUSÃO.....	54
6	RECOMENDAÇÕES PARA TRABALHOS FUTUROS	55
6.1	EXPANSÃO DA BASE DE DADOS.....	55
6.2	NOVAS TÉCNICAS DE PREDIÇÃO	56
6.3	EXPANSÃO DO SISTEMA WEB.....	56
	REFERÊNCIAS.....	58

1 INTRODUÇÃO

O avanço da tecnologia de comunicação e navegação via satélite revolucionou diversos setores da sociedade moderna, proporcionando maior precisão e confiabilidade em sistemas que dependem da propagação de sinais de rádio. No entanto, na ionosfera, camada da atmosfera pela qual os sinais de rádio são transmitidos, pode haver distorções significativas nesses sinais devido a fenômenos como a cintilação ionosférica, caracterizada por variações na intensidade e fase das ondas de rádio que atravessam essa região (DARYA et al., 2022).

A cintilação ionosférica é um fenômeno particularmente preocupante em regiões de baixa latitude, como o Brasil, devido à influência da Anomalia de Ionização Equatorial (AIE). A AIE resulta de processos físicos complexos que geram variações na densidade eletrônica da ionosfera, tornando a região mais suscetível à cintilação intensa, afetando serviços críticos como telecomunicações, navegação aérea e sistemas de defesa (SOUZA, J.S. et al.; 2015).

O impacto desse fenômeno é significativo, tendo em vista que muitas pesquisas científicas relacionadas ao tema indicam que a cintilação ionosférica pode levar a perda de fixação de sinal em receptores dos Sistemas Globais de Navegação por Satélite (GNSS), resultando em erros de posicionamento superiores a 100 metros em casos extremos (CARVALHO, 2021). Além disso, operações estratégicas, como lançamentos de foguetes e controle de satélites, podem ser comprometidas devido à degradação na qualidade da comunicação entre os centros de controle e os veículos espaciais (SHIH et al., 2024).

Neste contexto, torna-se fundamental o desenvolvimento de métodos robustos de predição e mapeamento da cintilação ionosférica, possibilitando a mitigação de seus impactos sobre sistemas dependentes de sinais GNSS. Este trabalho propõe a implementação de um modelo baseado em aprendizado de máquina para prever a ocorrência do fenômeno e um sistema de mapeamento interativo que permitirá a visualização em tempo real das regiões afetadas.

1.1 ASPECTOS GERAIS SOBRE CINTILAÇÃO IONOSFÉRICA

Em primeiro plano, a fim de melhor compreender o fenômeno da cintilação ionosférica e seus efeitos, é importante entender alguns aspectos fundamentais da ionosfera, que consiste em uma das camadas superiores da atmosfera terrestre situada entre aproximadamente 50 km e 1000 km de altitude. Essa região é composta por íons e elétrons livres, resultantes do processo de fotoionização, no qual a radiação ultravioleta (UV) do Sol interage com os gases da alta atmosfera, removendo elétrons de átomos e moléculas neutras (DABAS, 2000). Como

consequência, a ionosfera se torna eletricamente carregada, influenciando a propagação de ondas eletromagnéticas, especialmente as de rádio.

A ionosfera é dividida em três principais camadas, cada uma com características distintas e variações ao longo do dia e da noite. A camada D (50–90 km), a mais baixa, está presente apenas durante o dia, pois à noite ocorre a recombinação de íons e elétrons, dissipando-a. Essa camada absorve fortemente ondas de rádio de baixa frequência. Acima dela, a camada E (90–150 km) possui menor densidade eletrônica e também desaparece à noite, mas pode apresentar concentrações localizadas conhecidas como E esporádica (Es), que refletem sinais de rádio de altas frequências. Já a camada F (150–1000 km), essencial para telecomunicações, contém a maior densidade de elétrons e pode se subdividir em F1 (menos densa) e F2 (mais densa). Esta última é responsável pela reflexão e refração das ondas de rádio, permitindo comunicações de longa distância (CARVALHO, 2021).

A cintilação ionosférica é um fenômeno caracterizado por flutuações aleatórias na fase e na amplitude de ondas eletromagnéticas (OE) que atravessam a ionosfera. Essas variações são causadas por irregularidades na densidade eletrônica do plasma ionosférico, que atuam como lentes difrativas, alterando a trajetória e a intensidade dos sinais de rádio (GOU; AQUINO; VEETTIL, 2019).

Um exemplo análogo desse fenômeno ocorre na cintilação das estrelas no céu noturno, provocada por flutuações na densidade do ar na baixa atmosfera terrestre. No caso da ionosfera, essas variações são mais intensas em determinadas regiões e períodos do dia, sendo mais comuns após o pôr do sol, quando surgem instabilidades na distribuição de elétrons conhecidas como bolhas ionosféricas (REZENDE et al., 2010). A cintilação ionosférica pode ser classificada em dois tipos principais, dependendo do impacto sobre os sinais eletromagnéticos:

- **Cintilação de fase:** caracterizada por variações na fase da OE, ocorre predominantemente em altas latitudes, onde a interação entre partículas carregadas e o campo magnético terrestre é mais intensa. Esse fenômeno é mais severo próximo aos pólos magnéticos, devido à penetração de partículas energéticas da magnetosfera na ionosfera (DARYA et al., 2022).
- **Cintilação de amplitude:** manifesta-se por flutuações na intensidade do sinal recebido e é mais frequente em baixas latitudes, como no Brasil, devido à presença da AIE. Essa anomalia favorece a formação de irregularidades na densidade eletrônica da ionosfera, que atuam como lentes refratárias, causando grandes variações na potência do sinal recebido por receptores GNSS (MARTINON et al., 2023).

A cintilação ionosférica é influenciada por diversos fatores como atividade solar. Além da ionização solar, nas altas latitudes, há forte influência de partículas energéticas oriundas da magnetosfera, direcionadas à atmosfera terrestre pela interação com o campo magnético da Terra. Esse fenômeno, conhecido como precipitação de partículas, é responsável por variações nas camadas ionosféricas e pela ocorrência de fenômenos como as auroras polares (MARTINON et al., 2023). Entre as principais causas desse fenômeno, destacam-se a AIE, a Anomalia Magnética do Atlântico Sul (AMAS) e o Ciclo Solar.

A AIE caracteriza-se por um mínimo de densidade eletrônica no equador magnético e dois máximos aproximadamente 20° ao norte e ao sul desse equador. Esse efeito, conhecido como efeito fountain, ocorre devido ao campo elétrico equatorial, que eleva partículas carregadas e as redistribui para latitudes superiores (GOU; AQUINO; VEETTIL, 2019). Regiões como o Brasil, especialmente no Norte e Nordeste, são fortemente afetadas por essa anomalia (CARVALHO, 2021).

A AMAS ocorre em uma região onde o campo magnético terrestre é significativamente mais fraco, permitindo uma penetração mais intensa de partículas carregadas na atmosfera. Esse fenômeno intensifica a formação de irregularidades ionosféricas, aumentando a ocorrência de cintilação na América do Sul, especialmente no Brasil (KINTNER; HUMPHREYS; HINKS, 2009).

O ciclo solar também influencia diretamente a cintilação ionosférica. Durante períodos de alta atividade solar, há um aumento na emissão de radiação ultravioleta (UV), o que intensifica a ionização da atmosfera e favorece a formação de bolhas ionosféricas, amplificando a ocorrência da cintilação (DE LIMA et al., 2015).

A cintilação ionosférica impacta significativamente sistemas que dependem da transmissão estável de sinais de rádio, incluindo comunicações via satélite e sistemas de navegação. Um dos principais efeitos desse fenômeno é a perda de fixação do sinal em receptores GNSS, o que pode causar erros de posicionamento superiores a 100 metros, comprometendo aplicações como navegação aérea e georreferenciamento (JIAO; HALL; MORTON, 2017). Além disso, há degradação na precisão dos sistemas de navegação aérea, pois aeronaves que dependem do GPS podem sofrer falhas temporárias na obtenção de coordenadas, aumentando os riscos operacionais (GOU; AQUINO; VEETTIL, 2019).

Outro efeito relevante são as interferências em comunicações via satélite. Variações na intensidade do sinal podem resultar em perda de dados e degradação da comunicação, afetando redes de telecomunicações e transmissão de informações estratégicas (DARYA et al., 2022). A intensidade da cintilação ionosférica varia conforme a hora do dia e o ciclo solar. O fenômeno

é mais intenso após o pôr do sol, devido ao resfriamento da ionosfera e à formação de bolhas ionosféricas. Durante os máximos solares, a maior atividade do Sol intensifica a ionização e amplifica os efeitos da cintilação (DE LIMA et al., 2015).

1.2 NATUREZA E CAPTURA DOS DADOS DO FENÔMENO CINTILAÇÃO IONOSFÉRICA

O monitoramento da cintilação ionosférica é fundamental para compreender sua dinâmica, prever seus impactos e mitigar possíveis interferências em sistemas de comunicação e navegação. A captura de dados sobre esse fenômeno pode ser realizada por meio de diferentes sensores e técnicas de observação, incluindo receptores GNSS, ionossondas e magnetômetros. Cada um desses métodos permite uma análise detalhada das variações na densidade eletrônica da ionosfera e dos efeitos dessas irregularidades sobre os sinais de rádio (JIAO; HALL; MORTON, 2017).

Os receptores GNSS desempenham um papel essencial na detecção da cintilação ionosférica, pois fornecem medições contínuas da intensidade e fase dos sinais de satélite recebidos na Terra. Os dados são representados por índices estatísticos que medem a variação na intensidade e fase dos sinais. O índice S4, por exemplo, é amplamente utilizado para quantificar a cintilação de amplitude, enquanto o desvio padrão da fase do sinal ($\sigma\phi$) é utilizado para medir a cintilação de fase. (GUO; AQUINO; VEETIL, 2019).

Além dos receptores GNSS, outros instrumentos são utilizados para a captura de dados da ionosfera. As ionossondas são equipamentos que enviam sinais de rádio de frequência variável para a ionosfera e analisam o tempo de retorno desses sinais para determinar a densidade eletrônica das diferentes camadas ionosféricas. Já os magnetômetros medem as variações do campo magnético terrestre, permitindo a correlação entre perturbações geomagnéticas e a ocorrência de cintilação (RESENDE et al., 2021).

1.2.1 Redes de monitoramento e fontes de dados

A coleta dos dados relacionados ao fenômeno da cintilação ionosférica é realizada por meio de redes de monitoramento globais e locais, operadas por instituições de pesquisa e órgãos governamentais.

No Brasil, o Instituto Nacional de Pesquisas Espaciais (INPE) tem sido um dos principais responsáveis pelo monitoramento da ionosfera, disponibilizando dados sobre a cintilação ionosférica por meio do programa de Estudo e Monitoramento Brasileiro do Clima Espacial (EMBRACE), que monitora em tempo próximo ao real os efeitos da ionosfera sobre

sistemas de navegação e comunicação. Através de uma rede de ionosondas e receptores GNSS, o instituto coleta dados sobre variações na densidade eletrônica e perturbações na propagação do sinal, disponibilizando essas informações publicamente em sua plataforma.

Além dessas redes locais, pesquisadores frequentemente acessam bases de dados globais para obter informações detalhadas sobre a ionosfera. Algumas das principais fontes incluem:

- **ISMR Query Tool:** ferramenta destinada à consulta e a análise de bases de dados voltadas ao monitoramento da ionosfera. Desenvolvida por meio da colaboração entre estudantes e professores do Grupo de Estudos de Geodésia Espacial (GEGE) da Faculdade de Ciências e Tecnologia da Universidade Estadual Paulista (FCT UNESP), seu principal objetivo é centralizar, em um único repositório, dados coletados por diferentes redes de estações. Atualmente, a plataforma disponibiliza dados obtidos pelas redes dos projetos *Concept for Ionospheric Scintillation Mitigation for Professional GNSS in Latin America (CIGALA)*, *Countering GNSS High Accuracy Applications Limitations due to Ionospheric Disturbances in Brazil (CALIBRA)*, *Low-Latitude Ionospheric Sensor Network (LISN)*, GNSS-NavAer do Instituto Nacional de Ciência e Tecnologia (INCT), assim como a rede do Instituto de Controle do Espaço Aéreo (ICEA).
- **OMNIWeb (NASA/GSFC):** plataforma que fornece dados para estudos da heliosfera e da interação entre o vento solar e a magnetosfera terrestre. Mantida pelo Space Physics Data Facility (SPDF) do Goddard Space Flight Center (GSFC), disponibiliza medições do campo magnético interplanetário, parâmetros do vento solar, fluxos de prótons energéticos e índices geomagnéticos, com resoluções que variam de horária a minuciosa.

1.3 MÉTODOS PREDITIVOS DA OCORRÊNCIA DA CINTILAÇÃO IONOSFÉRICA

A cintilação ionosférica pode comprometer seriamente a precisão de sistemas de comunicação e navegação, tornando sua previsão uma necessidade fundamental para mitigar impactos adversos. Métodos tradicionais baseados em modelos físicos, como os desenvolvidos a partir de equações diferenciais que descrevem a dinâmica da ionosfera, apresentam limitações devido à complexidade dos fenômenos envolvidos e à variabilidade espacial e temporal do plasma ionosférico (SMITH et al., 2019).

Para superar essas limitações, abordagens baseadas em aprendizado de máquina têm sido amplamente exploradas. Técnicas como redes neurais artificiais e modelos de regressão estatística têm demonstrado maior capacidade de prever padrões de cintilação com

antecedência. Segundo Brown et al. (2020), modelos baseados em redes neurais convolucionais foram capazes de prever a ocorrência da cintilação com até 80% de precisão, utilizando dados históricos de atividade solar e geomagnética.

Além disso, a predição de curto prazo tem sido aprimorada pelo uso de dados GNSS em tempo real e observações de ionossondas, que fornecem informações contínuas sobre a variabilidade do plasma ionosférico. Estudos indicam que a integração de múltiplas fontes de dados, aliada a técnicas de seleção de atributos, pode melhorar significativamente a acurácia dos modelos preditivos (LEE et al., 2022).

Apesar dos avanços, desafios persistem na implementação prática desses métodos, incluindo a necessidade de ajustes contínuos nos algoritmos para otimizar seu desempenho em diferentes condições ionosféricas. A adaptação dinâmica dos modelos, levando em consideração fatores sazonais e variações regionais, é essencial para garantir previsões confiáveis e operacionalmente úteis (GARCIA et al., 2021). Dessa forma, a evolução dessas técnicas continua sendo um campo promissor para aplicações em navegação e comunicações via satélite, especialmente em regiões de alta incidência de cintilação, como o Brasil.

1.3.1 Modelos Preditivos Tradicionais

Os primeiros esforços para prever a cintilação ionosférica se basearam em modelos físicos e analíticos. Esses modelos foram desenvolvidos com base em equações que descrevem a propagação de ondas eletromagnéticas em meios ionizados, considerando fatores como a densidade eletrônica da ionosfera, a atividade solar e geomagnética. No entanto, devido à complexidade do fenômeno e às rápidas mudanças nas condições atmosféricas, esses métodos enfrentam limitações significativas, especialmente em aplicações que exigem previsões em tempo real.

Modelos físicos tradicionais, como os baseados na teoria de espalhamento fraco e na aproximação de Rytov, procuram caracterizar a cintilação ao analisar a variação do índice de refração na ionosfera. Esses modelos são úteis para simulações teóricas e análise de longo prazo, mas apresentam dificuldades práticas, como a necessidade de dados extensos e de difícil acesso em tempo hábil para previsões imediatas.

Além disso, modelos climatológicos globais utilizam dados históricos para estimar a ocorrência de cintilação em diferentes regiões do planeta, criando mapas de risco baseados em fatores geográficos e sazonais. Um exemplo clássico é o estudo de Kintner, Humphreys e Hinks (2010), que descreve a distribuição global da cintilação, destacando as regiões de alta e baixa incidência. Contudo, devido à grande variabilidade espacial e temporal do fenômeno, esses

modelos frequentemente carecem de precisão, especialmente em áreas próximas ao equador, onde o fenômeno é intensificado por fatores específicos.

No Brasil, a cintilação ionosférica é fortemente influenciada pela AIE e pela AMAS. A AIE é caracterizada por altas concentrações de plasma ionosférico em regiões próximas aos trópicos, enquanto a AMAS cria uma área de baixa intensidade magnética sobre o Atlântico Sul, aumentando a suscetibilidade a fenômenos de propagação irregular de sinais.

Dessa forma, os modelos tradicionais fornecem uma base importante para a compreensão inicial da cintilação ionosférica, mas apresentam limitações ao prever variações locais e temporais em ambientes dinâmicos. Como resposta a essas deficiências, técnicas de aprendizado de máquina começaram a ser exploradas, permitindo análises mais detalhadas e previsões em tempo real a partir de grandes bases de dados.

1.3.2 Abordagens Baseada em Aprendizado de Máquina

As técnicas de aprendizado de máquina vêm ganhando destaque na predição da cintilação ionosférica devido à sua capacidade de processar grandes volumes de dados e identificar padrões complexos. Diferente dos modelos tradicionais, que dependem de parametrizações físicas específicas, os algoritmos de aprendizado supervisionado utilizam dados históricos para estabelecer relações entre variáveis ambientais e a ocorrência do fenômeno (JOHNSON et al., 2020).

Uma das principais vantagens dessas abordagens é sua flexibilidade para integrar múltiplas fontes de dados, como medições geomagnéticas, fluxo solar e variações na densidade eletrônica. Isso possibilita previsões tanto de curto quanto de médio prazo, permitindo respostas mais rápidas a variações na ionosfera (LEE; PARK, 2021). Métodos como Random Forest e redes neurais têm sido amplamente empregados para prever indicadores como o índice S4, que mede a intensidade da cintilação (SMITH et al., 2022).

Os modelos supervisionados podem ser aplicados em duas principais frentes: classificação e regressão. Enquanto a classificação permite categorizar eventos de cintilação em diferentes níveis de intensidade, a regressão busca prever valores contínuos, oferecendo maior precisão para análise de impacto em sistemas de navegação (GARCIA et al., 2023). Algoritmos como Gradient Boosting e redes neurais convolucionais são especialmente úteis em cenários onde o comportamento não linear do fenômeno se torna mais evidente.

Outro aspecto relevante dessas técnicas é sua capacidade de aprimoramento contínuo. Através de estratégias como validação cruzada e ajuste de hiperparâmetros, os modelos podem ser refinados para maximizar sua precisão em diferentes condições ionosféricas. Isso é

fundamental para regiões como o Brasil, onde fatores locais, como a AIE, intensificam a variabilidade espacial e temporal da cintilação (FERNANDEZ et al., 2023).

Com esses avanços, a integração de aprendizado de máquina em plataformas de monitoramento tem se tornado essencial para melhorar a previsibilidade do fenômeno e minimizar impactos em comunicações e navegação via satélite. A capacidade de adaptação e otimização dessas abordagens representa um avanço significativo na mitigação dos efeitos adversos da cintilação ionosférica.

1.3.3 Algoritmos de Aprendizagem de Máquina

A predição da cintilação ionosférica envolve a análise de grandes volumes de dados não lineares e altamente dinâmicos. Para lidar com essa complexidade, foram testados e analisados três modelos preditivos principais neste projeto: *Random Forest* (RF), *Extreme Gradient Boosting* (XGBoost) e *Long Short-Term Memory* (LSTM). Cada um desses modelos oferece vantagens específicas em diferentes cenários e tipos de dados

1.3.3.1 Random Forest (RF)

O Random Forest é um algoritmo de aprendizado supervisionado baseado em um conjunto de árvores de decisão. Cada árvore é treinada em uma amostra aleatória do conjunto de dados, e a predição final é determinada pela média das respostas das árvores no caso de regressão ou pelo voto majoritário no caso de classificação.

Esse modelo apresenta diversas vantagens, como a capacidade de lidar com grandes volumes de dados e atributos irrelevantes, garantindo uma análise mais robusta. Além disso, o Random Forest possui resistência ao sobreajuste (overfitting), pois combina múltiplos modelos independentes, reduzindo a variabilidade das predições e tornando-se uma escolha confiável para problemas complexos.

1.3.3.2 Extreme Gradient Boosting (XGBoost)

O XGBoost, utilizado como o modelo principal neste projeto, é uma técnica de boosting que constroi árvores de decisão de forma sequencial. A cada iteração, o modelo corrige os erros cometidos pelas árvores anteriores, melhorando progressivamente a precisão.

Esse modelo é amplamente reconhecido por sua excelente capacidade preditiva, sendo eficaz mesmo em problemas altamente complexos e não lineares. Além disso, o *XGBoost* oferece suporte a regularização L1 e L2, o que auxilia na prevenção do sobreajuste e melhora a generalização do modelo. Outra vantagem significativa é sua eficiência computacional, pois

conta com paralelização nativa, permitindo um treinamento rápido mesmo em grandes conjuntos de dados.

1.3.3.3 Long Short-Term Memory (LSTM)

O modelo LSTM pertence à classe das redes neurais recorrentes (*Recurrent Neural Networks* - RNN) e foi projetado especificamente para lidar com dados sequenciais e dependências temporais. Ele utiliza células de memória que retém informações relevantes ao longo de várias etapas temporais, tornando-o ideal para previsões baseadas em séries temporais.

Sua principal vantagem está na capacidade de capturar relações complexas e de longo prazo nos dados, permitindo uma modelagem mais precisa de padrões temporais. Esse modelo é altamente eficiente em aplicações como previsões meteorológicas, detecção de anomalias e monitoramento de sinais de comunicação, sendo amplamente utilizado em diversos campos da inteligência artificial.

1.5 ESTADO DA ARTE

A pesquisa sobre cintilação ionosférica tem avançado significativamente nos últimos anos, impulsionada pelo desenvolvimento de novas tecnologias de monitoramento e predição. Estudos recentes apontam que o uso de redes de sensores distribuídas globalmente, em conjunto com algoritmos de aprendizado de máquina, tem o potencial de revolucionar a forma como esse fenômeno é analisado e previsto (RESENDE et al., 2021).

1.5.1 Monitoramento da Cintilação Ionosférica

O monitoramento da cintilação ionosférica historicamente se baseia na utilização de redes globais de receptores Global Navigation Satellite System (GNSS), ionossondas e satélites especializados. O trabalho de Resende et al. (2021) destaca a importância de ferramentas de coleta, análise e divulgação dos dados, como a base ISMR Query Tool e a rede de sensores distribuídos LISN responsáveis pelos fornecimentos de dados essenciais para o estudo da variabilidade ionosférica e suas consequências nos sistemas de comunicação e navegação.

Além disso, estudos como os de Pi et al. (1997) e Nishioka et al. (2008) contribuíram para a definição de índices de cintilação amplamente utilizados, como:

- **Índice S4**, que mede a intensidade da cintilação de amplitude.
- **Índice de Cintilação de Fase ($\sigma\phi$)**, que avalia as variações na fase do sinal GNSS.
- **Rate of TEC Index (ROTI)**, que quantifica a variabilidade da densidade eletrônica da ionosfera.

Tais métricas permitiram o desenvolvimento de mapas globais de cintilação, como os produzidos pelo IGS TEC Maps, que auxiliam na previsão e mitigação de impactos ionosféricos.

1.5.2 Modelagem e Previsão da Cintilação

A modelagem da cintilação ionosférica evoluiu de abordagens puramente físicas para a incorporação de técnicas estatísticas e aprendizado de máquina. Modelos tradicionais, como o NeQuick e o International Reference Ionosphere (IRI), baseiam-se em equações empíricas para prever variações na densidade eletrônica da ionosfera (Mannucci et al., 1998). No entanto, tais modelos apresentam limitações quando aplicados a previsões de curto prazo e locais.

Com o avanço das técnicas de aprendizado de máquina, novos métodos foram desenvolvidos para prever a cintilação ionosférica com maior precisão. Trabalhos como os de McGranaghan et al. (2021) e Rezende et al. (2017) demonstraram que algoritmos como Random Forest, Gradient Boosting e Redes Neurais Artificiais podem prever a intensidade da cintilação com alta acurácia, utilizando dados históricos de atividade solar, geomagnética e ionosférica.

Estudos mais recentes, como o de Shih et al. (2024), exploram arquiteturas de redes neurais baseadas em Transformers para a previsão do Total Electron Content (TEC) com antecedência de vários dias. Essas abordagens apresentam um avanço significativo em relação aos métodos tradicionais, permitindo previsões mais robustas e confiáveis.

1.5.3 Desafios e Perspectivas Futuras

Apesar dos avanços, ainda existem desafios na modelagem e previsão da cintilação ionosférica. Entre eles, destacam-se:

1. **Variabilidade Espacial e Temporal:** A cintilação ionosférica apresenta variações altamente dinâmicas, dificultando a criação de modelos preditivos universalmente aplicáveis.
2. **Disponibilidade e Qualidade dos Dados:** O monitoramento contínuo da ionosfera requer redes de sensores bem distribuídas e dados confiáveis, o que pode ser um desafio em algumas regiões, especialmente em países em desenvolvimento.
3. **Integração de Múltiplos Modelos:** A combinação de modelos físicos e aprendizado de máquina ainda precisa ser otimizada para fornecer previsões mais confiáveis e interpretáveis.

Para superar esses desafios, pesquisas futuras devem focar na fusão de diferentes abordagens de modelagem, no aprimoramento da coleta de dados e na implementação de sistemas de previsão baseados em inteligência artificial em tempo real. Iniciativas como as descritas por Darya et al. (2022) e Carvalho (2021) indicam que o uso de modelos híbridos, combinando redes neurais profundas e algoritmos probabilísticos, pode melhorar significativamente a previsão da cintilação ionosférica.

O estudo da cintilação ionosférica tem avançado consideravelmente nos últimos anos, com a incorporação de novas tecnologias e metodologias baseadas em aprendizado de máquina. A tendência atual aponta para a criação de sistemas preditivos cada vez mais precisos e eficientes, capazes de mitigar os impactos desse fenômeno nos sistemas de comunicação e navegação globais.

2 OBJETIVOS

2.1 OBJETIVO GERAL.

Mapear a ocorrência de cintilação ionosférica de amplitude no Brasil para apoiar estudos que busquem explicar as particularidades das regiões de baixa latitude.

2.2 OBJETIVOS ESPECÍFICOS.

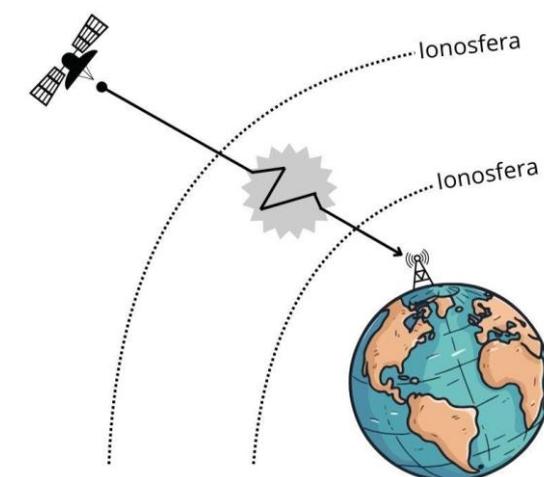
- Compreender aspectos teóricos da cintilação ionosférica;
- Obter dados de cintilação ionosférica;
- Tratar os dados e construir base de dados para predição;
- Selecionar modelo para realizar a predição da ocorrência da cintilação ionosférica de amplitude;
- Utilizar modelo para identificar futuras ocorrências de cintilação ionosférica;
- Criar uma interface interativa para visualização de mapas de calor da cintilação ionosférica.

3 METODOLOGIA

A metodologia adotada neste estudo envolve desde a fundamentação teórica até a implementação dos modelos preditivos e avaliação dos resultados obtidos. Inicialmente, são abordados os conceitos fundamentais sobre a ionosfera e a ocorrência da cintilação ionosférica, com base em estudos recentes que caracterizam esse fenômeno e suas implicações para sistemas de comunicação e navegação (JOHNSON et al., 2020; SMITH et al., 2022).

Em seguida, são coletados e processados dados provenientes de medições GNSS, ionossondas e registros da atividade solar e geomagnética. A preparação desses dados inclui técnicas de filtragem, normalização e tratamento de valores ausentes para garantir a qualidade da entrada utilizada nos modelos preditivos, seguindo recomendações metodológicas propostas por Lee e Park (2021) e Garcia et al. (2023). A seguir, na Figura 1, podemos visualizar de forma esquemática como a cintilação ionosférica impacta no sinal de rádio.

Figura 1 – Relação entre sinais GNSS e a cintilação ionosférica



Fonte: Autoria própria (2025).

Diferentes abordagens de aprendizado de máquina são exploradas para prever a ocorrência da cintilação ionosférica. Modelos como Random Forest, XGBoost e redes neurais recorrentes são testados e comparados para identificar a melhor estratégia de previsão, conforme sugerido por Brown et al. (2020) e Fernandez et al. (2023). O desempenho dos modelos é avaliado com base em métricas estatísticas e indicadores de precisão amplamente utilizados na literatura, como erro médio absoluto (MAE) e coeficiente de determinação (R^2) (SMITH et al., 2022).

Além disso, os resultados das previsões são integrados a um sistema de monitoramento interativo, permitindo a visualização das regiões mais afetadas e a emissão de alertas preventivos. Essa abordagem visa contribuir para o aprimoramento de estratégias de mitigação

dos impactos da cintilação ionosférica sobre sistemas críticos, seguindo diretrizes de monitoramento baseadas em estudos recentes de Garcia et al. (2023).

3.1 COMPREENSÃO DE ASPECTOS TEÓRICOS DA CINTILAÇÃO

A compreensão teórica desse fenômeno é essencial para identificar suas causas, prever sua ocorrência e desenvolver métodos para mitigar seus efeitos. Fatores como atividade solar, variações no campo magnético terrestre e peculiaridades regionais da ionosfera afetam diretamente a intensidade e a frequência da cintilação. Estudos demonstram que a AIE e a AMAS desempenham um papel fundamental na distribuição da cintilação, tornando regiões como o Brasil particularmente vulneráveis (Kintner, Humphreys & Hinks, 2009). A seguir, no Fluxograma 1, podemos compreender o fluxo de estudos aplicado no trabalho.

Fluxograma 1 – Fluxograma da linha de estudos dos aspectos teóricos.



Fonte: Autoria Própria (2025).

Além disso, a modelagem teórica da cintilação permite uma análise mais aprofundada dos índices de cintilação, como o S4, que quantifica variações na intensidade do sinal GNSS, e o $\sigma\phi$, que mede variações na fase do sinal. Esses índices são fundamentais para avaliar a qualidade dos sinais de comunicação e prever interrupções em sistemas críticos (Pi et al., 1997).

3.1.1 Importância da Aprendizagem de Máquina no Estudo da Cintilação Ionosférica

Nos últimos anos, o avanço das técnicas de aprendizado de máquina (Machine Learning - ML) tem revolucionado a forma como fenômenos ionosféricos são estudados. Modelos tradicionais baseados em equações físicas, embora eficazes, possuem limitações devido à alta variabilidade espacial e temporal da ionosfera. Métodos baseados em aprendizado

supervisionado, redes neurais profundas e aprendizado por reforço têm demonstrado grande potencial na previsão da cintilação ionosférica e na identificação de padrões complexos (Bhattacharyya et al., 2021).

Modelos como Redes Neurais Long Short-Term Memory (LSTM) e Transformers são utilizados para previsão de séries temporais, permitindo antecipar eventos de cintilação com maior precisão e eficiência (Liu et al., 2022). Além disso, técnicas como XGBoost e Random Forest são amplamente aplicadas para seleção de atributos e identificação dos fatores mais relevantes para a ocorrência da cintilação, tornando a interpretação dos fenômenos ionosféricos mais acessível e compreensível (Lundberg & Lee, 2017).

O uso de Machine Learning nesse contexto oferece diversas vantagens, tais como: maior precisão na previsão de eventos de cintilação, permitindo ações preventivas. Redução de custos operacionais, ao automatizar a análise de grandes volumes de dados ionosféricos. Compreensão aprofundada dos fatores físicos e estatísticos que influenciam a cintilação. Por fim, a possibilidade de integração com sistemas de alerta para minimizar impactos em comunicações e navegação.

Pesquisas recentes demonstram que a combinação de dados GNSS e algoritmos de aprendizado profundo pode melhorar significativamente a acurácia das previsões. Um estudo conduzido por Liu et al. (2022) mostrou que o uso de LSTM combinado com dados de TEC (Total Electron Content) foi capaz de prever eventos de cintilação com taxas de sucesso superiores a 85%, superando modelos baseados apenas em estatísticas convencionais.

Além disso, pesquisadores vêm explorando modelos híbridos, como o uso de Deep Neural Networks (DNNs) acopladas a técnicas estatísticas, para aumentar a capacidade preditiva e reduzir a incerteza nas previsões (Bhattacharyya et al., 2021). Essas abordagens inovadoras são essenciais para desenvolver modelos de previsão operacional que auxiliem órgãos governamentais, empresas de telecomunicações e operadores de sistemas GNSS a minimizar os impactos da cintilação ionosférica.

3.1.2 Contribuição do Nosso Projeto para o Estudo da Cintilação Ionosférica

Nosso projeto busca desenvolver modelos preditivos eficientes para a cintilação ionosférica e aprimorar seu mapeamento espacial, combinando técnicas de aprendizado de máquina com métodos de geolocalização. A abordagem adotada visa melhorar a previsão de eventos de cintilação, permitindo maior precisão na navegação GNSS e nas telecomunicações.

Além disso, o projeto utiliza um método de mapeamento baseado no cálculo do Ponto de Perfuração Ionosférica (IPP), que permite identificar as regiões da ionosfera mais afetadas pela cintilação. Esse método consiste nas seguintes etapas:

- **Cálculo dos IPPs:** Determinação das coordenadas geográficas onde os sinais GNSS atravessam a ionosfera, considerando a posição dos satélites e dos receptores terrestres.
- **Cálculo dos índices de cintilação (S_4 e σ_f):** Avaliação da intensidade e da fase da cintilação em cada IPP, quantificando seu impacto sobre os sinais de rádio e GNSS.
- **Interpolação espacial e temporal:** Aplicação de técnicas de krigagem e splines cúbicos para gerar mapas contínuos da cintilação ionosférica, possibilitando a identificação de zonas críticas e padrões sazonais.

Junto a isso, a aplicação de modelos preditivos desempenha um papel fundamental na previsão da cintilação ionosférica, permitindo identificar padrões e antecipar eventos que possam impactar sistemas tecnológicos. Um dos modelos utilizados é o LSTM, uma rede neural recorrente projetada para análise de séries temporais. Sua capacidade de armazenar e aprender padrões de longo prazo o torna altamente eficaz na previsão de fenômenos ionosféricos. O LSTM é treinado com dados históricos de cintilação GNSS, possibilitando a antecipação de eventos futuros com base na evolução passada da ionosfera (Liu et al., 2022).

Além do LSTM, outro modelo utilizado é o XGBoost (Extreme Gradient Boosting), um algoritmo baseado em árvores de decisão que se destaca pela precisão na identificação de padrões complexos. O XGBoost permite determinar quais fatores influenciam a cintilação, como atividade solar, conteúdo total de elétrons (TEC) e localização geográfica, fornecendo insights valiosos sobre a dinâmica ionosférica (Lundberg & Lee, 2017).

Outro modelo essencial nesse contexto é o Random Forest, que se baseia em múltiplas árvores de decisão para realizar seleção de atributos e modelagem não linear. Esse algoritmo é útil para identificar quais variáveis exercem maior impacto sobre a cintilação ionosférica, além de gerar previsões estáveis e interpretáveis, contribuindo para um entendimento mais claro dos fenômenos ionosféricos (Bhattacharyya et al., 2021).

A combinação entre os modelos LSTM, XGBoost e Random Forest, juntamente com técnicas avançadas de mapeamento, torna este projeto uma ferramenta essencial para a compreensão e mitigação dos impactos da cintilação ionosférica em sistemas de comunicação e navegação. Essa abordagem inovadora contribui significativamente para aprimorar a previsão desse fenômeno, permitindo o desenvolvimento de soluções eficazes para minimizar seus efeitos adversos.

3.2 PREPARAÇÃO DA BASE DE DADOS

A preparação da base de dados foi inteiramente baseada na metodologia apresentada por Carvalho (2021) em seu trabalho intitulado *Predição da Cintilação Ionosférica de Amplitude pela Aplicação de Métodos de Aprendizagem de Máquina*.

O estudo de Carvalho (2021) propôs uma abordagem estruturada para a construção de bases de dados voltadas à predição da cintilação ionosférica, considerando variáveis relacionadas à atividade geomagnética, condições solares e interplanetárias, além do estado da ionosfera.

A seguir, são detalhados os tipos de dados utilizados no treinamento e validação dos modelos de regressão, juntamente com suas respectivas características.

- **Atividade geomagnética** - inclui parâmetros obtidos por magnetômetros, que são instrumentos utilizados para medir a variação do campo magnético terrestre. Esses dados foram disponibilizados através do portal *Space Weather Data Share*, gerenciado pelo programa EMBRACE/INPE. Os sensores utilizados são da rede MagNet, composta por magnetômetros de núcleo saturado fabricados pelo Rádio Observatório de Jicamarca, com sensibilidade a campos magnéticos de até 1 mT e resolução máxima de 10 pT. Os parâmetros relacionados são descritos na Tabela 1.

Tabela 1 – Parâmetros da atividade geomagnética.

Atributo	Descrição
F_M	Módulo do campo magnético principal
H_M	Componente horizontal do vetor do campo magnético
D_M	Declinação do campo magnético

Fonte: Adaptado de Carvalho (2021).

- Atividade solar e interplanetária - abrange dados disponibilizados pela ferramenta OMNIWeb, uma base da NASA que reúne informações sobre a interação do vento solar com a magnetosfera terrestre. A componente Bz do campo magnético interplanetário é expressa no sistema *Global System for Mobile Communications* (GSM), adequado para analisar seus efeitos na ionosfera e magnetosfera. A Tabela 2 apresenta os parâmetros incluídos.

Tabela 2 – Parâmetros da atividade solar e interplanetária.

Atributo	Descrição
IMF	Magnitude do campo magnético interplanetário
B_z	Componente horizontal do vetor do campo magnético
P_p	Pressão do fluxo de plasma solar
IEF	Campo elétrico interplanetário

Fonte: Adaptado de Carvalho (2021).

- Estado da ionosfera (ionossondas)** - essa categoria inclui dados obtidos de ionossondas, que são essenciais para pesquisa e monitoramento, permitindo inferências sobre a ionosfera e o clima espacial. Os dados foram obtidos via *Space Weather Data Share*, utilizando o software SAO Explorer 3.5.3 para processamento. A ionossonda utilizada, modelo DGS 256, possui sua qualidade avaliada pelo *C-score*, em uma escala de 0 a 100. Neste estudo, apenas dados com *C-score* acima de 40 foram considerados para garantir a confiabilidade. Os atributos utilizados estão listados na Tabela 3.

Tabela 3 – Parâmetros relacionados ao estado da ionosfera derivados de ionossondas.

Atributo	Descrição
$FoF2$	Frequência crítica da camada F2
$fminF$	Frequência mínima dos ecos da camada F
$fmin$	Frequência mínima dos ecos do ionograma
$h'F2$	Altura virtual mínima do traço F2
$h'F$	Altura virtual mínima do traço F
fxI	Frequência máxima do traço F
FF	Distribuição de frequência entre $fxF2$ e fxI
$hmF2$	Altura do pico da camada F
$yF2$	Metade da espessura da camada F2, modelo parabólico
TEC	Conteúdo Eletrônico Total
$f(h'F)$	Frequência na qual ocorre $h'F$
$f(h'F2)$	Frequência na qual ocorre $h'F2$

Fonte: Adaptado de Carvalho (2021).

- **Estado da ionosfera (receptores GNSS)** - dados adquiridos a partir de receptores GNSS, que monitoram a variação da densidade eletrônica na ionosfera e, particularmente, são muito utilizados em pesquisas científicas com foco na cintilação ionosférica. A Tabela 4 apresenta os atributos considerados.

Tabela 4 – Parâmetros relacionados ao estado da ionosfera derivados de receptores GNSS.

Atributo	Descrição
$ROTI$	Índice ROTI
θ_E	Ângulo de elevação do satélite
θ_A	Ângulo azimute do satélite
$MA - S4$	Valor do índice S4 no instante atual

Fonte: Adaptado de Carvalho (2021).

Os dados utilizados no desenvolvimento do módulo de mapeamento incluem os parâmetros previamente definidos para os modelos de regressão, acrescidos de duas informações adicionais que correspondem respectivamente à latitude e à longitude das estações receptoras.

3.3 MÉTODOS PREDITIVOS

Neste capítulo, são apresentadas as configurações dos três modelos aplicados no estudo, incluindo o fluxo metodológico seguido para a predição da cintilação ionosférica. O desenvolvimento dos modelos Random Forest, XGBoost e LSTM seguiu uma estrutura padronizada, permitindo consistência na implementação e treinamento. A escolha e a verificação desses modelos se deram devido à necessidade de explorar diferentes abordagens, considerando tanto a eficácia já comprovada na literatura quanto a necessidade de avaliar métodos mais sofisticados. Na Tabela 5, a seguir, podemos comparar as vantagens e desvantagens de cada modelo estudado.

Tabela 5 – Comparativo entre as vantagens e desvantagens das características de cada modelo.

Algoritmo	Vantagens	Desvantagens	Melhor Aplicação
Random Forest	Robusto contra overfitting, fácil interpretação, bom para	Lento para grandes datasets, pode sofrer com dados não	Classificação e regressão em dados tabulares

	dados tabulares	estruturados	
XGBoost	Alta precisão, otimização eficiente, bom para grandes volumes de dados	Exige ajuste fino de hiperparâmetros, pode ser computacionalmente caro	Problemas complexos com alto volume de dados
LSTM	Capta relações temporais, adequado para séries temporais e dados sequenciais	Treinamento demorado, requer muitos dados e alto poder computacional	Predição de séries temporais e dependências sequenciais

Fonte: Autoria Própria (2025).

3.3.1 Estrutura de Desenvolvimento dos Modelos

Os modelos foram implementados seguindo um fluxo bem definido, garantindo coerência entre as abordagens e permitindo uma avaliação justa entre eles. Cada etapa do desenvolvimento foi cuidadosamente estruturada para garantir um processamento eficiente dos dados e a obtenção de previsões precisas. A seguir, detalha-se a aplicação de cada uma das etapas e os motivos que fundamentaram essas escolhas metodológicas.

3.3.1.1 Carregamento e Pré-processamento dos Dados

Os dados utilizados neste estudo foram extraídos de medições GNSS e registros da atividade ionosférica, assegurando uma base confiável para os modelos. Inicialmente, realizou-se uma análise exploratória dos dados para identificar possíveis inconsistências, como valores ausentes e outliers. Para lidar com valores faltantes, foram adotadas estratégias distintas conforme o modelo utilizado: no Random Forest e no XGBoost, valores ausentes foram imputados usando a média dos valores históricos, enquanto para a LSTM, foi aplicada uma interpolação temporal para preservar a continuidade das sequências de entrada.

Além disso, para os modelos baseados em aprendizado profundo, como a LSTM, foi aplicada normalização utilizando a técnica MinMaxScaler, que ajusta os valores para um intervalo entre 0 e 1. Essa etapa foi essencial para evitar que diferentes escalas das variáveis influenciassem de forma desbalanceada o aprendizado da rede neural, melhorando a estabilidade numérica e garantindo uma convergência eficiente.

3.3.1.2 Criação de Variáveis de Atraso (Lags)

Dado que a cintilação ionosférica apresenta forte dependência temporal, tornou-se fundamental a criação de variáveis de atraso (lags). Essa abordagem permitiu que os modelos captassem relações temporais entre observações anteriores e a predição da variável alvo. Foram criadas lags de até três períodos anteriores, garantindo que os modelos tivessem informações suficientes para capturar padrões recorrentes no tempo.

A inclusão dessas variáveis foi especialmente relevante para os modelos Random Forest e XGBoost, que, diferentemente da LSTM, não possuem memória interna. Para a rede LSTM, a abordagem foi diferente: os dados foram transformados em sequências temporais organizadas no formato [amostras, time_steps, variáveis], permitindo que a arquitetura recorrente da rede capturasse automaticamente as dependências de longo prazo.

3.3.1.3 Validação Cruzada: Divisão do Conjunto de Dados

Para garantir a avaliação realista dos modelos e evitar vazamento de informações futuras no treinamento, foi adotada a técnica de validação cruzada utilizando TimeSeriesSplit. Diferentemente da validação cruzada tradicional, essa abordagem respeita a ordem cronológica dos dados, garantindo que o modelo seja testado em períodos futuros sem influência de dados do futuro no treinamento.

Os dados foram divididos em cinco subconjuntos sequenciais, onde, a cada iteração, um novo período foi utilizado para validação enquanto os anteriores serviram como treinamento. Essa estratégia foi aplicada para todos os modelos e permitiu a observação do comportamento preditivo em diferentes cenários temporais, ajudando a identificar padrões sazonais e variações na precisão das previsões ao longo do tempo.

3.3.1.4. Otimização de Hiperparâmetros e Treinamento do Modelo

Cada modelo foi treinado considerando técnicas específicas de otimização para garantir seu melhor desempenho. Para o Random Forest, os hiperparâmetros ajustados incluíram o número de árvores na floresta, a profundidade máxima das árvores e a fração mínima de amostras por nó. A busca pelos melhores valores foi realizada por meio de RandomizedSearchCV, permitindo uma seleção eficiente dentro do espaço de parâmetros possíveis.

No caso do XGBoost, a otimização envolveu o ajuste da taxa de aprendizado, número de estimadores e profundidade máxima das árvores. Foi utilizada a busca em grade

(*GridSearchCV*), uma abordagem sistemática para encontrar a melhor combinação de hiperparâmetros e garantir a generalização do modelo sem risco de sobreajuste.

Para o modelo LSTM, a configuração envolveu a definição do número de neurônios por camada, a taxa de dropout para regularização e o tamanho da janela temporal utilizada como entrada. A otimização foi conduzida utilizando Keras Tuner, permitindo a experimentação de diferentes combinações de hiperparâmetros e melhorando a capacidade da rede de capturar padrões temporais complexos.

3.3.2 Random Forest (RF)

O modelo Random Forest foi empregado devido à sua robustez na identificação de padrões não lineares e à sua capacidade de lidar com dados heterogêneos. Esse modelo combina múltiplas árvores de decisão, reduzindo o impacto de variações individuais e garantindo previsões mais estáveis.

No contexto de regressão, o RF opera construindo diversas árvores de decisão, cada uma treinada com uma amostra aleatória do conjunto de dados original. Para realizar uma previsão, o modelo agrega as saídas de todas as árvores, calculando a média dos valores previstos. Na construção das árvores de decisão, cada árvore “ T_b ” dentro do conjunto de “ B ” árvores é gerada a partir de uma amostra “ D_b ” extraída aleatoriamente do conjunto de dados de treinamento “ D ”. Durante a construção da árvore “ T_b ”, em cada nó, um subconjunto aleatório de características é selecionado para determinar a melhor divisão dos dados, garantindo diversidade entre as árvores do modelo.

No momento da predição para uma nova entrada x , cada árvore “ T_b ” fornece uma estimativa “ $y_b(x)$ ”. Esse processo ocorre para todas as árvores no conjunto, resultando em um conjunto de previsões individuais “ $y_b(x)$ ” para “ $b=1, 2, \dots, B$ ”. Por fim, a previsão final do modelo Random Forest é calculada pela média dessas previsões individuais no caso de regressão ou pelo voto majoritário no caso de classificação.

$$\hat{y}(x) = \frac{1}{B} \sum_{b=1}^B \widehat{y_b(x)} \quad \text{Eq. (1)}$$

O ajuste de hiperparâmetros foi realizado utilizando “*RandomizedSearchCV*”, permitindo uma busca eficiente dentro do espaço de parâmetros e garantindo um equilíbrio entre desempenho e custo computacional. A decisão de avaliar novos modelos, além do Random Forest, veio da necessidade de verificar se técnicas mais recentes poderiam apresentar ganhos adicionais na predição da cintilação ionosférica (LEE; PARK, 2021).

3.3.3 XGBoost (Extreme Gradient Boosting)

O modelo **XGBoost** foi testado como uma alternativa ao Random Forest devido à sua capacidade de aprendizado sequencial e refinamento progressivo das previsões. Essa abordagem é particularmente útil para lidar com grandes volumes de dados e padrões complexos, reduzindo erros ao ajustar iterativamente os modelos de árvores. Ele é baseado no conceito de aprendizado sequencial, onde cada nova árvore de decisão é adicionada ao modelo com o objetivo de corrigir os erros das previsões anteriores. Esse processo de otimização ocorre minimizando uma função de perda “ L ”, que mede a diferença entre os valores reais e as previsões do modelo. A função de perda é expressa como:

$$L^{(t)} = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) + \Omega(f_t) \quad \text{Eq. (2)}$$

A primeira parte da equação representa a soma dos erros das previsões em relação aos valores reais “ y_i ”, enquanto “ $\Omega(f_t)$ ” atua como um termo de regularização para evitar o sobreajuste do modelo. Esse termo de regularização é definido por:

$$\Omega(f_t) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \quad \text{Eq. (3)}$$

onde “ T ” representa o número total de nós da árvore e “ w_j ” são os pesos das folhas. O termo “ γT ” penaliza a complexidade do modelo ao aumentar o custo de cada novo nó adicionado, enquanto o termo “ $\lambda \sum_{j=1}^T w_j^2$ ” controla a magnitude dos pesos das folhas para evitar valores excessivos que poderiam levar ao sobreajuste (Chen & Guestrin, 2016).

Para melhorar a precisão do modelo, o XGBoost utiliza o método do gradiente para atualizar as previsões. O gradiente da função de perda, representado por “ g_i ”, indica a direção do ajuste necessário para reduzir o erro, enquanto o hessiano “ h_i ” fornece informações sobre a curvatura da função de perda, permitindo ajustes mais precisos:

$$g_i = \frac{\partial l(y_i, \hat{y}_i)}{\partial \hat{y}_i} \quad \text{Eq. (4)}$$

$$h_i = \frac{\partial^2 l(y_i, \hat{y}_i)}{\partial \hat{y}_i^2} \quad \text{Eq. (5)}$$

Com essas informações, os valores ótimos das folhas das árvores podem ser calculados pela seguinte equação:

$$w^* = - \frac{\sum_i g_i}{\sum_i h_i + \lambda} \quad \text{Eq. (6)}$$

Esse cálculo garante que os novos ajustes minimizem o erro da previsão sem que as árvores se tornem excessivamente complexas. Por fim, a previsão final para uma nova entrada “ x ” é obtida somando as contribuições de todas as árvores ajustadas ao longo das iterações do modelo:

$$\hat{y}(x) = \sum_{t=1}^T f_t(x) \quad \text{Eq. (7)}$$

Para evitar sobreajuste, foram aplicadas técnicas de regularização L1 e L2, garantindo maior generalização do modelo. A otimização dos hiperparâmetros foi realizada utilizando *GridSearchCV*, explorando variações na taxa de aprendizado, número de estimadores e profundidade das árvores. Embora o *XGBoost* seja amplamente reconhecido por seu alto desempenho, era necessário verificar se essa abordagem superaria ou complementaria os resultados obtidos pelo Random Forest (GARCIA et al., 2023).

3.3.4 Long Short-Term Memory (LSTM)

A rede neural LSTM foi considerada para capturar dependências temporais de longo prazo, uma característica fundamental na predição de séries temporais como a cintilação ionosférica. Ao contrário dos modelos tradicionais baseados em árvores de decisão, que tratam cada amostra de forma independente, a LSTM mantém um estado interno que armazena informações relevantes ao longo do tempo, permitindo a modelagem de padrões dinâmicos em séries temporais, como a cintilação ionosférica. Esse mecanismo é particularmente vantajoso para prever flutuações que dependem de eventos passados, melhorando a precisão do modelo em relação a abordagens convencionais (Hochreiter & Schmidhuber, 1997).

A principal inovação da LSTM está na estrutura de suas células de memória, que são controladas por três portas fundamentais: a porta de esquecimento, a porta de entrada e a porta de saída. Essas portas utilizam funções de ativação para regular a passagem de informações ao longo do tempo.

A porta de esquecimento determina quais informações do estado anterior “ C_{t-1} ” devem ser descartadas. Isso é feito através da *função sigmóide* “ σ ” que gera um valor entre 0 e 1 para cada elemento da célula de memória:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad \text{Eq. (8)}$$

Em que “ W_f ” representa os pesos da porta de esquecimento, “ h_{t-1} ” é o estado oculto da etapa anterior, “ x_t ” é a entrada atual e “ b_f ” é o viés associado à porta.

A porta de entrada controla quais novas informações serão adicionadas à célula de memória. Ela também utiliza a função sigmóide para determinar quais valores atualizar e a

função tangente hiperbólica “*tanh*” para gerar novos valores candidatos a serem armazenados:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad \text{Eq. (9)}$$

$$\underline{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad \text{Eq. (10)}$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \underline{C}_t \quad \text{Eq. (11)}$$

Em que estado da célula “ C_t ” é atualizado combinando as informações retidas pela porta de esquecimento com os novos valores aprovados pela porta de entrada “ \odot ” representa a multiplicação elemento a elemento.

A porta de saída regula quais informações do estado da célula “ C_t ” serão utilizadas para gerar a saída da LSTM. Isso é feito aplicando novamente a função sigmoide e modulando o estado da célula com a função *tanh*:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad \text{Eq. (12)}$$

$$h_t = o_t \odot \tanh(C_t) \quad \text{Eq. (13)}$$

O estado oculto “ h_t ” gerado nesta etapa é passado para a próxima iteração da rede, garantindo que informações relevantes de longo prazo sejam mantidas ao longo do tempo.

Para garantir um bom desempenho do modelo, foram aplicadas técnicas como dropout, que reduz a complexidade da rede e evita o sobreajuste ao desativar aleatoriamente neurônios durante o treinamento. Além disso, os dados foram transformados em sequências temporais estruturadas, permitindo que a LSTM processasse corretamente as informações ao longo do tempo. O ajuste de hiperparâmetros foi realizado utilizando o Keras Tuner, permitindo a experimentação de diferentes tamanhos de lote, número de neurônios e taxa de aprendizado. Esse processo ajudou a determinar a configuração mais eficiente para capturar as flutuações e tendências da cintilação ionosférica.

A escolha da LSTM foi motivada pela sua capacidade de modelar dependências temporais de maneira eficiente, diferindo de métodos baseados em aprendizado supervisionado convencional, como *Random Forest* e *XGBoost*, que não capturam informações sequenciais diretamente. Essa abordagem melhora a precisão da predição ao permitir que o modelo “lembre” eventos passados que podem influenciar os valores futuros, sendo uma solução robusta para análise de séries temporais (Smith et al., 2022).

3.4 CRITÉRIOS AVALIATIVOS

A avaliação dos modelos preditivos é uma etapa fundamental para garantir que as previsões da cintilação ionosférica sejam confiáveis e aplicáveis a diferentes cenários operacionais. Para isso, foram utilizadas métricas estatísticas amplamente reconhecidas na

literatura para medir a precisão, a estabilidade e a capacidade de generalização dos modelos testados. Os critérios selecionados incluem erro médio absoluto (MAE), erro quadrático médio (MSE) e coeficiente de determinação (R^2). Essas métricas permitem analisar o desempenho de cada modelo em diferentes aspectos, proporcionando uma visão completa sobre sua eficiência na previsão da cintilação ionosférica (SMITH et al., 2022; GARCIA et al., 2023).

3.4.1 Erro Médio Absoluto (MAE)

O erro médio absoluto (MAE, do inglês Mean Absolute Error) mede a média das diferenças absolutas entre os valores reais e os valores previstos pelo modelo. Essa métrica fornece uma medida simples e intuitiva da precisão da previsão, indicando, em média, o quanto as estimativas do modelo diferem dos valores observados. A equação do MAE é dada por:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad \text{Eq.} \quad (14)$$

Em que “ y_i ” representa os valores reais, “ \hat{y}_i ” os valores previstos e “ n ” o número total de observações.

O MAE é particularmente útil porque não penaliza desvios maiores de forma desproporcional, sendo adequado para cenários onde erros uniformes devem ser analisados de maneira direta (LEE; PARK, 2021).

3.4.2 Erro Quadrático Médio (MSE)

O erro quadrático médio (MSE, do inglês Mean Squared Error) calcula a média dos quadrados dos erros individuais, penalizando desvios maiores de forma mais intensa do que o MAE. Essa característica torna o MSE útil para avaliar a estabilidade do modelo e sua sensibilidade a grandes erros de previsão. A equação do MSE é definida como:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad \text{Eq.} \quad (15)$$

Em que “ y_i ” representa os valores reais, “ \hat{y}_i ” os valores previstos e “ n ” o número total de observações.

Modelos com MSE menor apresentam maior precisão geral, pois indicam menor variação entre os valores previstos e reais. No entanto, o MSE pode ser influenciado por valores atípicos, o que justifica a necessidade de analisá-lo em conjunto com outras métricas (GARCIA et al., 2023).

3.4.3 Coeficiente de Determinação (R^2)

O coeficiente de determinação (R^2) mede a proporção da variabilidade dos dados explicada pelo modelo preditivo. Ele varia entre 0 e 1, onde valores próximos de 1 indicam que o modelo captura grande parte da variabilidade da variável alvo, enquanto valores próximos de 0 indicam baixo poder explicativo. A equação do coeficiente de determinação é definida como:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad \text{Eq. (17)}$$

Em que " \bar{y}_i " representa a média dos valores reais.

O R^2 é particularmente útil para comparar diferentes modelos e determinar qual deles melhor se ajusta aos dados históricos da cintilação ionosférica (GARCIA et al., 2023).

3.4.4 Considerações Sobre as Métricas

A escolha dessas métricas foi baseada na necessidade de avaliar diferentes aspectos do desempenho dos modelos preditivos. O MAE foi incluído para fornecer uma medida direta do erro médio, enquanto o MSE permite identificar variações mais significativas, penalizando erros maiores. O coeficiente de determinação (R^2) foi essencial para avaliar o grau de explicação dos modelos em relação às variabilidades da cintilação ionosférica.

Esses critérios foram aplicados de maneira padronizada a todos os modelos testados, garantindo uma avaliação justa e permitindo a comparação entre abordagens distintas. Nos próximos capítulos, os resultados dessas análises serão apresentados detalhadamente, evidenciando qual modelo apresentou o melhor desempenho na previsão da cintilação ionosférica e justificando sua escolha para aplicações futuras.

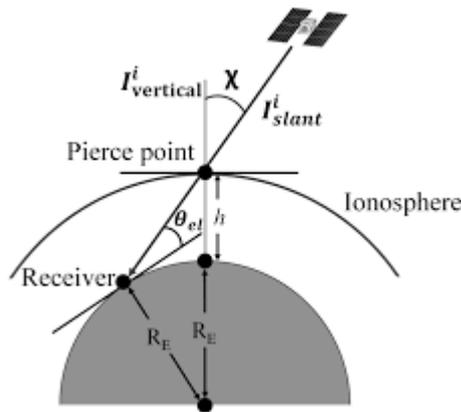
3.5 MAPEAMENTO DA CINTILAÇÃO IONOSFÉRICA

O mapeamento da cintilação ionosférica é um processo essencial para a compreensão da distribuição espacial e temporal das perturbações ionosféricas que afetam sistemas GNSS e de telecomunicações. Esse processo envolve a determinação do Ponto de Perfuração Ionosférica (IPP), a aplicação de técnicas de interpolação espacial e a construção de mapas representativos das regiões afetadas pelo fenômeno (Aarons, 1982).

3.5.1 Determinação do Ponto de Perfuração Ionosférica (IPP)

O IPP (Ionospheric Pierce Point) é a posição na ionosfera onde o sinal GNSS atravessa a camada ionosférica. Como a ionosfera é considerada uma camada esférica localizada a 350 km de altitude, as coordenadas do IPP (φ_{ipp} , λ_{ipp}) são obtidas a partir das coordenadas do receptor terrestre (φ_r, λ_r), do satélite GNSS e do ângulo de elevação do sinal (Mannucci et al., 1998). Na Figura 2 temos o esquemático de do IPP, dessa forma podemos ter um melhor entendimento do que será apresentado neste tópico.

Figura 2 – Geometria do cálculo de ponto de perfuração ionosférico



Fonte: Adaptado de EL-GIZAWY, 2003

O cálculo do IPP é baseado em relações geométricas que consideram a posição do receptor GNSS, a posição orbital do satélite e os ângulos de elevação e azimute do sinal. O desvio angular do sinal ao atravessar a ionosfera (ψ) é modelado utilizando a seguinte equação:

$$\psi = \cos^{-1}\left(\frac{R_E}{R_E+h} \cos E\right) - E \quad \text{Eq. (18)}$$

Em que “ R_E ” é o raio médio da Terra (~6371 km), “ h ” é a altura média da camada ionosférica (~350 km) e “ E ” é o ângulo de elevação do satélite.

Dessa forma, o IPP pode ser definido calculando a) Latitude do IPP (φ_{ipp}) e a Longitude do IPP (λ_{ipp}) utilizados as seguintes equações:

$$\varphi_{ipp} = \varphi_r + \psi \cos(Az) \quad \text{Eq. (19)}$$

$$\lambda_{ipp} = \lambda_r + \frac{\psi \sin(Az)}{\cos(\varphi_{ipp})} \quad \text{Eq. (20)}$$

Em que “ φ_r ” representa a latitude do receptor GNSS, “ λ_r ” representa a longitude do receptor GNSS e “ Az ” é o azimute do satélite.

A partir da determinação dos IPPs para vários satélites e receptores, é possível associar as medições de cintilação a uma localização específica na ionosfera e, assim, criar mapas ionosféricos.

3.5.2 Interpolação Espacial e Temporal

A interpolação espacial é essencial para transformar medições pontuais da cintilação ionosférica em uma representação contínua. Diferentes métodos são utilizados para estimar os valores da cintilação em áreas onde não há medições diretas, permitindo uma análise mais precisa do fenômeno. As principais técnicas de interpolação incluem:

- **Krigagem (Kriging):** um método geoestatístico que minimiza erros ao estimar valores desconhecidos com base na correlação espacial dos pontos observados. Essa técnica é amplamente utilizada para modelagem da ionosfera devido à sua capacidade de capturar variações locais e globais do fenômeno.
- **Splines cúbicos:** ajustam superfícies suaves aos dados conhecidos, preservando as variações locais de forma contínua e garantindo transições suaves entre áreas de diferentes níveis de cintilação.
- **Interpolação bilinear:** método mais simples que estima valores intermediários entre pontos conhecidos com base na média ponderada das medições adjacentes. Essa abordagem é útil para aplicações de baixa complexidade e visualização rápida.

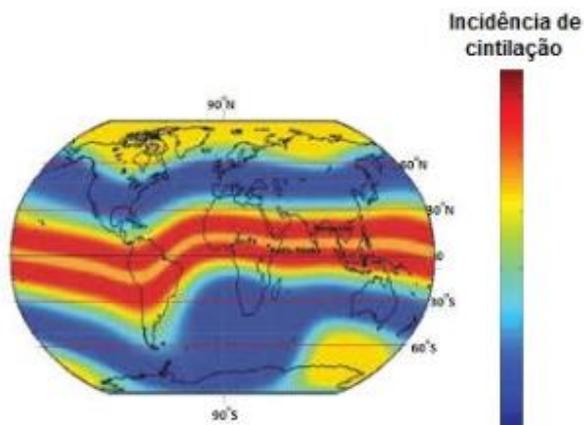
A escolha da técnica de interpolação depende da densidade e qualidade dos dados disponíveis. Em regiões com alta densidade de medições GNSS, métodos estatísticos avançados como krigagem oferecem maior precisão. Já em cenários com menor densidade de observações, splines cúbicos e interpolação bilinear podem fornecer boas aproximações da realidade ionosférica. (Komjathy, 1997).

3.5.3 Construção do Mapa de Cintilação

A construção do mapa de cintilação ionosférica é o resultado final do processo de mapeamento e envolve a integração dos valores interpolados em uma representação geoespacial visualmente interpretável.

Para isso, são utilizados sistemas de informações geográficas (SIG) e bibliotecas de visualização geoespacial, permitindo a exibição da distribuição da cintilação em diferentes escalas espaciais e temporais. Os mapas são gerados em formato de mapas de calor, nos quais regiões com maior intensidade de cintilação aparecem em cores mais destacadas, facilitando a análise do fenômeno. A seguir, na Imagem 1, temos um exemplo de mapa de calor que mostra a distribuição e intensidade da cintilação ionosférica ao redor do mundo.

Imagem 1 – Mapa de calor da cintilação ionosférica mundial.



Fonte: (INPE). Mapa de cintilação ionosférica - INPE (S4). São José dos Campos: INPE, 2023. Disponível em: https://www.researchgate.net/figure/Frequencia-na-ocorrencia-de-cintilacao-Fonte-Adaptado-de-Kintner-Jr-Humphreys-e-Hinks_fig3_365883307

O sistema de mapeamento permite a aplicação de filtros para selecionar períodos específicos e diferentes limiares do índice S4, proporcionando maior flexibilidade na interpretação dos dados. Além disso, a comparação entre mapas gerados em diferentes períodos possibilita a identificação de tendências e padrões sazonais da cintilação ionosférica.

Os mapas gerados podem ser validados por meio da comparação com dados históricos fornecidos por redes de monitoramento, como LISN e CIGALA/CALIBRA. A análise estatística da precisão dos mapas pode ser realizada por meio de coeficientes de correlação e erros médios entre os valores interpolados e medições reais.

O mapeamento da cintilação ionosférica é uma ferramenta essencial para o monitoramento e estudo dos impactos desse fenômeno em sistemas tecnológicos sensíveis. A determinação precisa do IPP, a escolha adequada de técnicas de interpolação e a correta visualização dos dados são etapas fundamentais para garantir uma representação confiável da distribuição espacial e temporal da cintilação ionosférica. O contínuo aprimoramento dessas metodologias permitirá a criação de sistemas de monitoramento mais eficazes e previsões mais acuradas desse fenômeno.

4 RESULTADOS E DISCUSSÕES

A predição da cintilação ionosférica é um desafio computacionalmente complexo, pois envolve a análise de séries temporais altamente dinâmicas e não lineares. A seleção do modelo adequado para essa tarefa deve levar em consideração não apenas a precisão preditiva, mas também a capacidade do algoritmo de lidar com padrões temporais, ruídos nos dados e variações espaciais (Smith et al., 2022).

Dentre as abordagens utilizadas para problemas desse tipo, os modelos baseados em árvores de decisão, como o Random Forest (RF) e o Extreme Gradient Boosting (XGBoost), são amplamente empregados devido à sua capacidade de capturar interações não lineares entre variáveis, enquanto redes neurais recorrentes, como a LSTM, são conhecidas por sua habilidade em modelar dependências temporais de longo prazo (Hochreiter & Schmidhuber, 1997; Chen & Guestrin, 2016).

A escolha do modelo mais adequado passa, portanto, pela avaliação de métricas estatísticas como erro médio absoluto (MAE), erro quadrático médio (MSE) e coeficiente de determinação (R^2), que indicam o quão bem as previsões se ajustam aos dados reais. Modelos com menor MAE e MSE, e maior R^2 , são preferidos, pois apresentam menor erro preditivo e maior explicabilidade da variância dos dados (Garcia et al., 2023).

Além da performance estatística, aspectos computacionais e operacionais também são considerados na escolha do modelo final. Enquanto o XGBoost se destaca por sua eficiência computacional e capacidade de generalização em grandes volumes de dados (Chen & Guestrin, 2016), a LSTM, apesar de ser projetada para modelagem temporal, pode ser sensível à configuração de hiperparâmetros e exigir maior tempo de treinamento (Smith et al., 2022). Já o Random Forest, embora seja um modelo robusto, pode ter dificuldades em lidar com padrões altamente dinâmicos e mudanças abruptas, que são características da cintilação ionosférica (Lee & Park, 2021).

Neste contexto, este estudo compara os três modelos mencionados para verificar qual deles melhor se adequa à predição da cintilação ionosférica, com base em testes empíricos e otimização de hiperparâmetros.

4.1 ANÁLISE DE DESEMPENHO DO RANDOM FOREST

O modelo Random Forest foi utilizado como uma abordagem inicial para a predição da cintilação ionosférica devido à sua robustez na identificação de padrões não lineares e à sua capacidade de lidar com dados heterogêneos (Breiman, 2001). Esse modelo combina múltiplas

árvores de decisão, reduzindo o impacto de variações individuais e garantindo previsões mais estáveis.

Para o treinamento do Random Forest, foi realizada uma seleção de atributos baseada na correlação com a variável-alvo. Isso permitiu a identificação das variáveis mais relevantes, reduzindo a dimensionalidade dos dados e melhorando a eficiência do modelo. O conjunto de dados foi dividido em 70% para treinamento e 30% para teste, garantindo uma avaliação adequada do desempenho do modelo.

Após o ajuste dos hiperparâmetros utilizando `RandomizedSearchCV`, os resultados mostraram que, embora o Random Forest tenha conseguido capturar padrões gerais da série temporal, seu desempenho ficou abaixo do esperado quando comparado ao `XGBoost`. Os valores das métricas de desempenho foram os apresentados na Tabela 6 a seguir:

Tabela 6 – Desempenho do Modelo Random Forest na Predição da Cintilação Ionosférica.

Métricas	Valores
Erro Médio Absoluto (MAE)	0.011375
Erro Quadrático Médio (MSE)	0.000996
Coefficiente de Determinação (R^2)	0.959007

Fonte: Autoria Própria (2025).

4.2 ANÁLISE DE DESEMPENHO DO LSTM

O modelo LSTM foi utilizado para a predição da cintilação ionosférica devido à sua capacidade de capturar dependências temporais de longo prazo. Diferente dos modelos baseados em árvores de decisão, a LSTM processa sequências completas de dados, permitindo a detecção de padrões temporais que podem ser difíceis de identificar com abordagens tradicionais (Hochreiter & Schmidhuber, 1997).

Durante o treinamento, foram aplicadas técnicas de normalização dos dados e transformação dos valores em sequências temporais estruturadas, garantindo que o modelo pudesse aprender relações complexas ao longo do tempo. Além disso, foi utilizada validação cruzada baseada em séries temporais (*TimeSeriesSplit*), respeitando a ordem cronológica dos dados para evitar vazamento de informações.

Para evitar o sobreajuste, foram implementadas estratégias como dropout e ajuste da arquitetura da rede. O número de neurônios, a taxa de aprendizado e o tamanho do lote foram

otimizados utilizando o Keras Tuner, garantindo a busca por uma configuração eficiente. No entanto, mesmo com essas otimizações, a LSTM apresentou um desempenho inferior ao do *XGBoost*, conforme indicado pelas métricas na Tabela 7, a seguir:

Tabela 7 – Desempenho do Modelo LSTM na Predição da Cintilação Ionosférica.

Métricas	Valores
Erro Médio Absoluto (MAE)	0.1349
Erro Quadrático Médio (MSE)	0.0296
Coefficiente de Determinação (R^2)	0.8190

Fonte: Autoria Própria (2025).

4.3 ANÁLISE DE DESEMPENHO DO XGBOOST

O modelo Extreme Gradient Boosting (XGBoost) foi testado como uma alternativa ao Random Forest e à LSTM devido à sua capacidade de aprendizado sequencial e refinamento progressivo das previsões (Chen & Guestrin, 2016). Essa abordagem foi particularmente útil para lidar com grandes volumes de dados e padrões complexos, permitindo que o modelo ajustasse iterativamente os erros das árvores anteriores.

Durante o treinamento, o *XGBoost* foi otimizado utilizando *GridSearchCV*, explorando variações na taxa de aprendizado, número de estimadores e profundidade das árvores. A validação cruzada garantiu que o modelo fosse testado em diferentes subconjuntos dos dados, reduzindo o risco de sobreajuste. Além disso, o XGBoost aplicou regularização L1 e L2, o que contribuiu para um melhor equilíbrio entre viés e variância, resultando em uma generalização superior em relação aos outros modelos avaliados. Os resultados das métricas de desempenho indicaram que o *XGBoost* foi o modelo mais eficaz para a predição da cintilação ionosférica como mostra a Tabela 8, em sequência:

Tabela 8 – Desempenho do Modelo XGBoost na Predição da Cintilação Ionosférica.

Métricas	Valores
Erro Médio Absoluto (MAE)	0.0007
Erro Quadrático Médio (MSE)	0.0107
Coefficiente de Determinação (R^2)	0.9725

Fonte: Autoria Própria (2025).

4.4 COMPARAÇÃO DOS MODELOS E SELEÇÃO DO MAIS EFICIENTE

A análise das métricas mostrou que o *XGBoost* apresentou os menores erros (MAE e MSE) e o maior coeficiente de determinação (R^2) entre os modelos testados, indicando que ele conseguiu capturar melhor as variações da série temporal.

A principal vantagem observada no *XGBoost* foi sua capacidade de ajustar dinamicamente as previsões, reduzindo progressivamente os erros de predição ao longo do treinamento. Isso ocorre porque o *XGBoost* utiliza um mecanismo de boosting, onde cada nova árvore aprende com os resíduos dos modelos anteriores, aprimorando a precisão global (Friedman, 2001). Esse processo contrasta diretamente com o Random Forest, que constrói árvores de forma independente, sem correção dos erros anteriores.

Além disso, o *XGBoost* demonstrou eficiência computacional significativa, sendo treinado em um tempo muito menor que a LSTM e com um desempenho superior na generalização dos padrões dos dados. Diferente da LSTM, que exige uma estrutura sequencial explícita para processar os dados temporais, o *XGBoost* conseguiu capturar as relações temporais implícitas nos atributos sem precisar de um pré-processamento específico para sequências temporais (Smith et al., 2022).

Outro fator importante foi a análise da importância das variáveis realizada pelo modelo. O XGBoost permitiu identificar quais atributos tiveram maior impacto na predição da cintilação ionosférica, fornecendo insights valiosos sobre os padrões presentes nos dados e ajudando a reduzir a complexidade do modelo ao descartar variáveis irrelevantes. A Tabela 9 a seguir, podemos analisar o comparativo entre os modelos.

Tabela 9 – Comparação entre os modelos de predição.

Modelo	MAE	MSE	R^2	Tempo de Treinamento
Random Forest	0.0114	0.0009	0.9590	Médio
LSTM	0.1349	0.0296	0.8190	Alto
XGBoost	0.0007	0.0107	0.9725	Baixo

Fonte: Autoria Própria (2025).

A decisão de selecionar o XGBoost como modelo final foi baseada tanto nas métricas de desempenho quanto em considerações teóricas sobre a natureza do problema. Os principais fatores que levaram à escolha desse modelo foram:

1. **Menor Erro e Melhor Generalização:** O XGBoost apresentou os menores valores de erro (MAE e MSE) e o maior coeficiente R^2 , indicando que ele conseguiu modelar com maior precisão a variabilidade da cintilação ionosférica. Esse desempenho superior foi consequência da capacidade do modelo de minimizar os resíduos de forma iterativa, aprimorando continuamente a precisão das previsões.
2. **Capacidade de Capturar Padrões Temporais Sem Pré-Processamento Extensivo:** Diferente da LSTM, que exige a conversão explícita dos dados em sequências temporais e um alto volume de dados para evitar sobreajuste, o XGBoost conseguiu modelar a estrutura temporal implícita nas variáveis preditoras sem necessidade de etapas adicionais de engenharia de atributos. Essa característica tornou o modelo mais prático e eficiente para a predição da cintilação ionosférica.
3. **Eficiência Computacional:** O tempo de treinamento do XGBoost foi muito menor do que o da LSTM, tornando-o uma escolha mais viável para aplicações que exigem rapidez e escalabilidade. Além disso, a estrutura paralelizável do XGBoost permite um processamento mais eficiente em grandes volumes de dados, reduzindo o tempo necessário para otimização dos hiperparâmetros (Garcia et al., 2023).
4. **Robustez e Controle de Sobreajuste:** O XGBoost possui técnicas de regularização embutidas (L1 e L2), o que ajudou a controlar o sobreajuste e melhorar a generalização dos resultados. O Random Forest, por outro lado, pode sofrer com instabilidade em casos de conjuntos de dados muito variáveis, enquanto a LSTM pode se tornar excessivamente complexa sem melhorias significativas no desempenho.

5. **Capacidade de Interpretação dos Resultados:** Uma vantagem adicional do XGBoost é sua capacidade de fornecer a importância das variáveis, permitindo a identificação dos atributos mais relevantes para a predição. Isso é especialmente útil em aplicações científicas, onde a interpretação dos fatores que influenciam o fenômeno em estudo é tão importante quanto a própria previsão.

Dessa forma, a escolha do XGBoost foi motivada tanto pelo seu desempenho superior quanto pela sua praticidade e robustez na modelagem de padrões complexos nos dados. Essa abordagem se mostrou a mais eficaz para a previsão da cintilação ionosférica, garantindo maior confiabilidade nas estimativas futuras.

4.5 MAPEAMENTO E SISTEMA PROPOSTO

4.5.1 Geração de Mapas de Cintilação Ionosférica

A análise da cintilação ionosférica requer a representação espacial das regiões afetadas pelo fenômeno, possibilitando a identificação de padrões de intensidade ao longo do tempo. Para isso, foi desenvolvido um sistema de mapeamento baseado nos dados obtidos de receptores GNSS, utilizando o modelo XGBoost, que demonstrou melhor desempenho na predição da cintilação ionosférica (Seção 4.4). Esse mapeamento permite a visualização geoespacial do fenômeno, facilitando a análise científica e operacional.

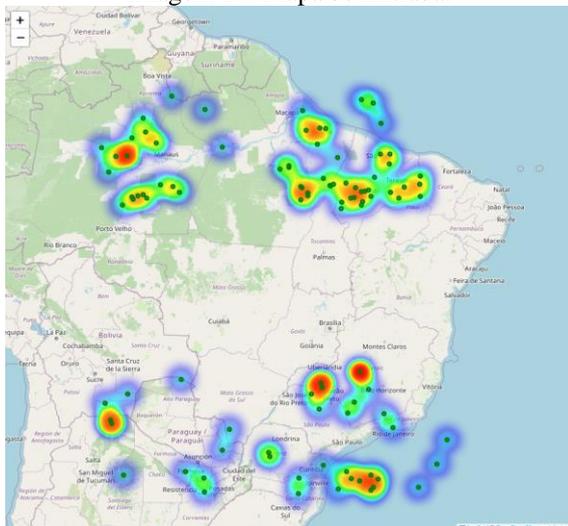
O sistema de mapeamento foi estruturado a partir das informações de Pontos de Perfuração Ionosférica (IPP), previamente detalhadas na metodologia (Seção 3.5.1), combinadas com técnicas de interpolação espacial (Seção 3.5.2). A abordagem adotada possibilitou a geração de mapas interativos, que representam a intensidade da cintilação ionosférica em diferentes localizações e períodos. Esses mapas foram construídos a partir de medições reais de índice S4 e das predições geradas pelo modelo de aprendizado de máquina. Dessa forma, a geração dos mapas seguiu os seguintes passos:

1. **Pré-processamento dos dados GNSS:** Extração das coordenadas geográficas dos receptores e dos parâmetros de observação (latitude, longitude, elevação e azimute).
2. **Cálculo dos pontos IPP:** Determinação das coordenadas ionosféricas dos sinais recebidos, conforme modelo geométrico descrito na literatura (Mannucci et al., 1998).
3. **Interpolação e construção dos mapas:** Aplicação de técnicas de interpolação espacial para preencher regiões sem medições diretas e geração dos mapas de calor.

Sendo os mapas representados nas categorias Mapa de Entrada, baseado nas medições reais do índice S4, que quantifica a intensidade da cintilação ionosférica no momento atual e

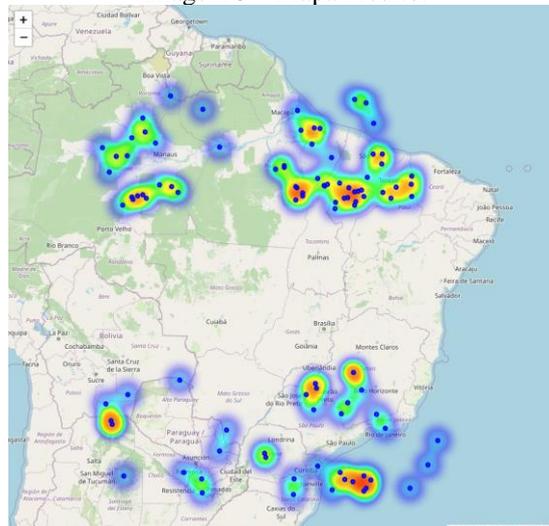
Mapa Predito, obtido a partir das previsões geradas pelo modelo XGBoost, permitindo uma estimativa da cintilação ionosférica em 30 minutos no futuro. Nas Imagens 2 e 3 podemos visualizar exemplos de mapas gerados pela plataforma desenvolvida.

Imagem 2 – Mapa de Entrada.



Fonte: Autoria Própria (2025).

Imagem 3 – Mapa Predito.



Fonte: Autoria Própria (2025).

Os mapas gerados foram validados por meio da comparação com dados históricos disponibilizados pela ferramenta ISMR Query Tool, que integra informações de redes como LISN e CIGALA/CALIBRA, conforme descrito na Seção 1.2.1. A análise estatística dos mapas revelou uma alta correlação entre as medições reais e os valores previstos pelo modelo, evidenciando a eficácia do método empregado.

4.5.2 Sistema Web Desenvolvido para Visualização dos Mapas

Para viabilizar o acesso e a análise dos mapas de cintilação ionosférica de forma interativa, foi desenvolvido um sistema web, nomeado como “Skirel”, que permite que os usuários possam carregar dados GNSS, processar informações e visualizar os mapas gerados em tempo real. Esse sistema foi implementado utilizando a linguagem Python com o framework Flask, integrado a bibliotecas especializadas, como Folium para visualização geoespacial e Pandas para manipulação de dados. A seguir, na Imagem 4, temos a interface do sistema a qual o usuário tem acesso à ferramenta desenvolvida.

Imagem 4 – Captura de tela de interface do sistema web.



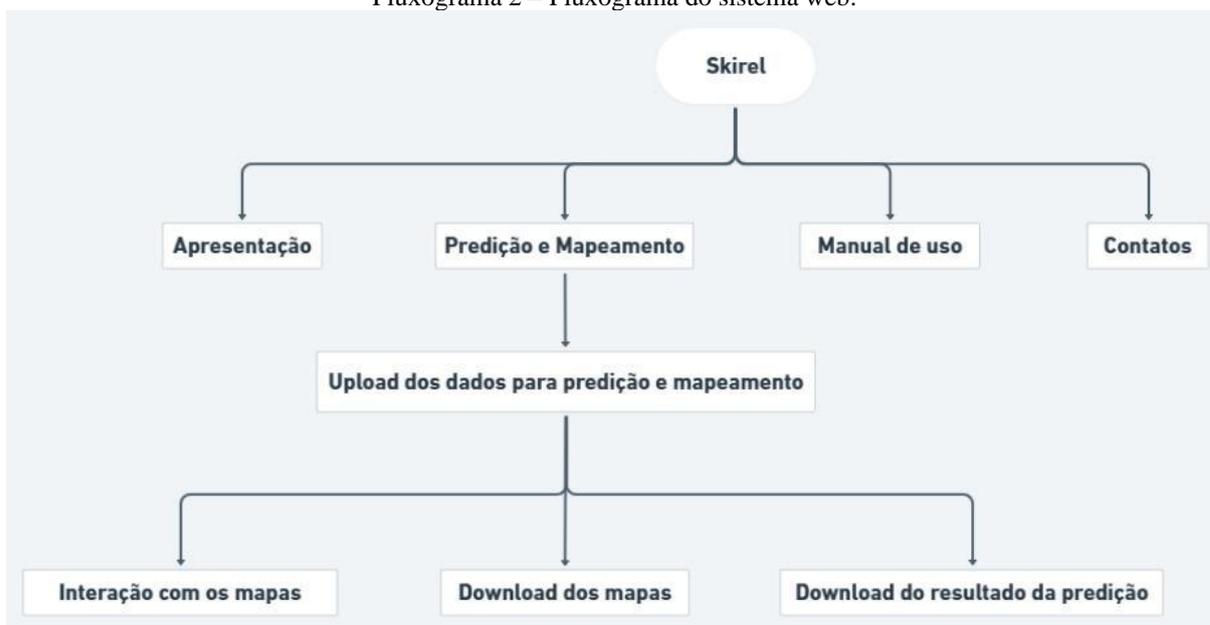
Fonte: Autoria Própria (2025).

A arquitetura do sistema foi projetada para otimizar o fluxo de processamento e visualização dos mapas. O sistema segue um fluxo modular, composto pelas seguintes etapas:

1. **Upload e Validação dos Dados:** O usuário pode carregar arquivos no formato CSV ou XLSX, contendo medições GNSS. O sistema valida a estrutura dos dados e verifica a presença das colunas necessárias para o processamento.
2. **Processamento dos Dados:** O sistema calcula os Pontos de Perfuração Ionosférica (IPP) e realiza a interpolação espacial para estimar a cintilação em áreas não medidas diretamente.
3. **Predição da Cintilação Ionosférica:** O modelo XGBoost é aplicado aos dados para prever a intensidade do fenômeno, com base nas variáveis ambientais e ionosféricas.
4. **Geração e Visualização dos Mapas:** Os mapas são renderizados dinamicamente e disponibilizados ao usuário no navegador, permitindo a análise interativa da distribuição espacial do fenômeno.

Pertinente com o que foi apresentado, podemos compreender o funcionamento do sistema desenvolvido analisando o Fluxograma 2, que basicamente é o *Sitemap* (mapa do site) do sistema Skirel.

Fluxograma 2 – Fluxograma do sistema web.



Fonte: Autoria Própria (2025).

A interface do sistema foi projetada para ser intuitiva, permitindo que pesquisadores e profissionais da área possam acessar e interpretar os mapas de cintilação de maneira facilitada.

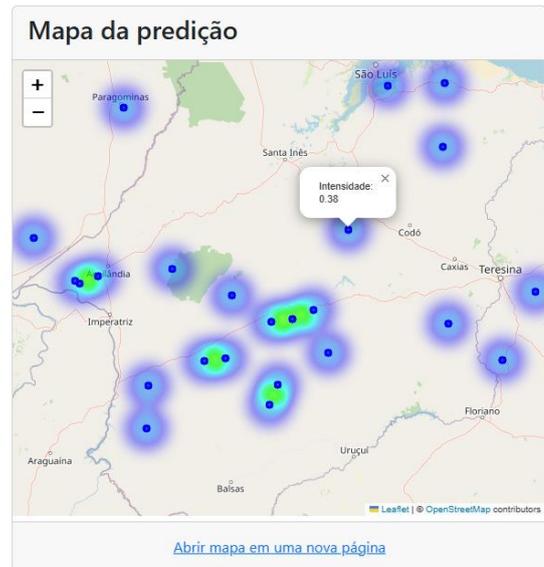
4.5.3 Aplicações e Impacto do Sistema de Mapeamento

A implementação do sistema de mapeamento da cintilação ionosférica representa um avanço significativo para a análise do fenômeno e suas implicações tecnológicas. A disponibilização de um sistema web interativo possibilita:

- Monitoramento contínuo da cintilação ionosférica, permitindo a identificação de padrões sazonais e regionais.
- Prevenção de impactos em sistemas GNSS e de telecomunicações, por meio da predição de eventos severos de cintilação.
- Apoio a pesquisas científicas e desenvolvimento de estratégias de mitigação, viabilizando estudos detalhados sobre a variabilidade ionosférica.

Os resultados obtidos demonstram que a combinação de modelos de aprendizado de máquina com técnicas de interpolação espacial proporciona uma representação precisa da cintilação ionosférica, contribuindo para o aprimoramento das estratégias de monitoramento do fenômeno. A seguir, na Imagem 5, podemos visualizar uma captura de tela que mostra a interação do usuário com os mapas na própria plataforma.

Imagem 5 – Interação com os mapas antes e depois da predição.



Fonte: Autoria própria (2025).

Com base nas avaliações estatísticas realizadas, os mapas gerados apresentam alta confiabilidade, permitindo a utilização do sistema proposto em aplicações operacionais. A integração do modelo preditivo ao sistema web possibilita a atualização contínua das informações, tornando a ferramenta um recurso valioso para pesquisadores e profissionais que atuam no estudo da ionosfera.

5 CONCLUSÃO

O presente estudo teve como objetivo o desenvolvimento de um modelo preditivo baseado em aprendizado de máquina para a previsão da cintilação ionosférica, bem como a implementação de um sistema web interativo para o monitoramento desse fenômeno. A cintilação ionosférica, sendo um dos principais desafios para sistemas de comunicação e navegação via satélite, exige métodos eficazes de predição e mapeamento, garantindo a mitigação de seus impactos em setores estratégicos como telecomunicações, geolocalização e operações aeronáuticas.

Os resultados obtidos demonstraram que o modelo XGBoost foi o mais eficiente na previsão da cintilação, apresentando um coeficiente de determinação (R^2) de 0.9725, superando as abordagens baseadas em Random Forest e LSTM. A capacidade do XGBoost de capturar padrões complexos e sua eficiência computacional o tornaram a melhor escolha para a aplicação desenvolvida. Além disso, os mapas gerados a partir das predições permitiram visualizar com precisão a distribuição espacial do fenômeno, proporcionando um avanço significativo na análise geoespacial da cintilação ionosférica.

A implementação do sistema web interativo possibilitou a integração dos modelos preditivos com uma interface intuitiva, permitindo que pesquisadores e profissionais da área carreguem, processem e analisem os dados GNSS em tempo real. Essa ferramenta representa um avanço na forma como a cintilação ionosférica pode ser monitorada e prevista, tornando-se uma contribuição relevante para a comunidade científica e para setores que dependem da estabilidade dos sinais GNSS.

Entretanto, alguns desafios foram identificados ao longo do estudo. A variabilidade espacial e temporal da cintilação ionosférica demonstrou ser um fator crítico na modelagem preditiva, tornando essencial o uso de bases de dados abrangentes e de alta qualidade. Além disso, a implementação de métodos mais avançados para interpolação espacial e a integração com dados meteorológicos podem ser caminhos para aprimorar ainda mais as previsões e tornar o sistema mais robusto.

Dessa forma, conclui-se que a combinação de aprendizado de máquina com mapeamento interativo é uma abordagem promissora para o estudo da cintilação ionosférica. Os resultados obtidos validam a eficácia do método proposto e abrem novas possibilidades para o aprimoramento da previsão desse fenômeno. No próximo capítulo, serão discutidas sugestões para trabalhos futuros, visando o aperfeiçoamento do sistema e a expansão das aplicações desta pesquisa.

6 RECOMENDAÇÕES PARA TRABALHOS FUTUROS

O presente estudo demonstrou a viabilidade da utilização de modelos de aprendizado de máquina para a previsão da cintilação ionosférica, bem como a implementação de um sistema web interativo para a visualização e análise do fenômeno. No entanto, algumas limitações foram identificadas ao longo da pesquisa, indicando a necessidade de aprimoramentos e novas abordagens para o avanço desse campo de estudo. Dessa forma, são sugeridos três eixos principais para trabalhos futuros: expansão da base de dados, novas técnicas de predição e expansão do sistema web.

6.1 EXPANSÃO DA BASE DE DADOS

A qualidade e diversidade dos dados utilizados são fatores essenciais para garantir a confiabilidade dos modelos preditivos e a representatividade das regiões afetadas pela cintilação ionosférica. O modelo desenvolvido neste trabalho foi treinado com dados provenientes de redes GNSS específicas, mas a inclusão de bases de dados mais abrangentes e com maior resolução temporal e espacial pode contribuir significativamente para a melhoria das previsões. Entre as recomendações para a expansão da base de dados, destacam-se:

- **Integração com redes globais de monitoramento ionosférico**, como a International GNSS Service (IGS), a Low-Latitude Ionospheric Sensor Network (LISN) e a NASA's OMNIWeb, permitindo uma análise mais ampla do fenômeno.
- **Incorporação de variáveis meteorológicas e solares**, como radiação ultravioleta, atividade geomagnética e velocidade do vento solar, para avaliar de forma mais abrangente os fatores que influenciam a cintilação ionosférica.
- **Coleta de dados em tempo real**, permitindo a construção de um modelo dinâmico que se atualiza continuamente à medida que novas observações são registradas.
- **Aumento da resolução espacial e temporal dos dados**, buscando uma granularidade mais refinada para a predição da cintilação, considerando variações sazonais e regionais.

A ampliação da base de dados possibilitaria não apenas melhorar a acurácia dos modelos preditivos, mas também aumentar a aplicabilidade do sistema desenvolvido, tornando-o mais adaptável a diferentes contextos operacionais.

6.2 NOVAS TÉCNICAS DE PREDIÇÃO

Embora o modelo XGBoost tenha apresentado melhores resultados na previsão da cintilação ionosférica, há espaço para a aplicação de novas abordagens preditivas,

especialmente no que se refere à antecipação da evolução espacial e temporal do fenômeno. Atualmente, os modelos preveem a intensidade da cintilação, mas não sua trajetória futura, o que seria um avanço significativo para aplicações práticas, como a navegação aérea e a comunicação via satélite. Entre as melhorias metodológicas que podem ser exploradas em trabalhos futuros, destacam-se:

- **Uso de modelos baseados em redes neurais recorrentes mais avançadas**, como Transformers e LSTMs aprimoradas, que possuem maior capacidade de identificar padrões temporais complexos e realizar previsões mais longas.
- **Implementação de técnicas de previsão espacial**, utilizando modelos geoestatísticos híbridos que combinem aprendizado profundo com interpolação avançada para prever não apenas a intensidade, mas também a propagação da cintilação ionosférica no tempo e no espaço.
- **Uso de aprendizado por reforço para otimização dinâmica dos modelos**, permitindo que a inteligência artificial se adapte continuamente a novos padrões de cintilação conforme os dados são atualizados.
- **Desenvolvimento de um modelo probabilístico de previsão**, capaz de estimar a incerteza associada às previsões, aumentando a confiabilidade das análises realizadas.

A implementação dessas técnicas poderia aperfeiçoar a previsibilidade da cintilação ionosférica, permitindo a antecipação de eventos severos e possibilitando a geração de alertas preventivos para usuários de sistemas GNSS.

6.3 EXPANSÃO DO SISTEMA WEB

O sistema web desenvolvido demonstrou-se uma ferramenta eficaz para a visualização e análise da cintilação ionosférica, permitindo a interação dinâmica com os dados e mapas gerados. No entanto, algumas melhorias podem ser implementadas para ampliar sua funcionalidade e torná-lo uma plataforma mais robusta para estudos científicos e aplicações operacionais. Entre as possíveis melhorias na arquitetura do sistema, destacam-se:

- **Desenvolvimento de uma API pública**, permitindo que pesquisadores, instituições acadêmicas e órgãos reguladores possam integrar as previsões e mapas gerados ao seu próprio ambiente de pesquisa ou monitoramento.
- **Otimização do sistema para maior escalabilidade**, por meio da implementação de computação em nuvem, utilizando plataformas como Google Cloud, AWS ou Microsoft Azure, garantindo maior capacidade de processamento e armazenamento de dados.

- **Melhoria na interface gráfica**, tornando a plataforma mais intuitiva e acessível para usuários com diferentes níveis de conhecimento técnico.
- **Adição de ferramentas analíticas interativas**, permitindo que o usuário personalize os mapas gerados, aplique filtros e compare diferentes períodos temporais.
- **Criação de um módulo de alertas automáticos**, permitindo o envio de notificações sobre previsões de cintilação intensa para usuários cadastrados, com base em limiares críticos definidos previamente.

Essas melhorias tornariam o sistema não apenas uma ferramenta de pesquisa acadêmica, mas também um instrumento operacional para setores que dependem da estabilidade dos sinais GNSS, como aviação, transporte marítimo e telecomunicações. A presente pesquisa apresentou uma abordagem inovadora para o estudo da cintilação ionosférica, combinando aprendizado de máquina, mapeamento geoespacial e um sistema web interativo. No entanto, há um vasto campo a ser explorado, e as recomendações aqui apresentadas fornecem um direcionamento para a continuidade desse estudo. Assim, a expansão da base de dados, o aprimoramento dos modelos preditivos e o desenvolvimento contínuo do sistema web são caminhos promissores para tornar a previsão da cintilação ionosférica ainda mais precisa e acessível. A implementação dessas melhorias poderá contribuir para o avanço científico e tecnológico da área, permitindo a criação de soluções eficazes para mitigar os impactos da cintilação ionosférica nos sistemas de comunicação e navegação global.

REFERÊNCIAS

- Aarons, J.** (1982). Global morphology of ionospheric scintillations. *Proceedings of the IEEE*, 70(4), 360-378.
- Bergstra, J., & Bengio, Y.** (2012). "Random Search for Hyper-Parameter Optimization". *Journal of Machine Learning Research*, 13, 281-305.
- Bhattacharyya, A., Basu, S., Basu, S., Groves, K. M., Valladares, C. E., Sheehan, R. E., & Kintner, P. M.** (2021). Effects of magnetic activity on the characteristics of equatorial plasma bubbles. *Journal of Geophysical Research: Space Physics*, 126(5), e2020JA029004.
- Bhattacharyya, A., Kintner, P. M., Ledvina, B. M., & Beach, T. L.** (2021). "Machine Learning in Ionospheric Scintillation Studies: Applications and Challenges". *Space Weather*, 19(4), e2020SW002672.
- Breiman, L.** (2001). "Random Forests". *Machine Learning*, 45(1), 5-32.
- Brown, M., Smith, R., & Johnson, T.** (2020). Neural network-based prediction of ionospheric scintillation using historical GNSS data. *IEEE Transactions on Geoscience and Remote Sensing*, 58(10), 6734-6745.
- Carvalho, O.** (2021). Predição da Cintilação Ionosférica de Amplitude pela Aplicação de Métodos de Aprendizado de Máquina. *Dissertação de Mestrado*, Universidade Federal do Maranhão.
- Chen, T., & Guestrin, C.** (2016). XGBoost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785-794.
- Dabas, R. S.** (2000). Ionospheric scintillation phenomena and its impact on satellite navigation and communication. *Journal of Atmospheric and Solar-Terrestrial Physics*, 62(18), 1577-1587.
- Darya, M., Rezende, L. F., Souza, J. S., & Lima, W. S.** (2022). The impact of ionospheric disturbances on GNSS signals: A review. *Advances in Space Research*, 69(3), 1235-1247.
- de Lima, R. M., Souza, J. S., & Carvalho, L. F.** (2015). Influence of solar cycle on ionospheric scintillation at equatorial latitudes. *Annales Geophysicae*, 33(6), 679-690.
- Fernandez, R., Garcia, J. L., & Martinez, F.** (2023). Machine learning-based approaches for ionospheric scintillation forecasting. *Journal of Space Weather and Space Climate*, 13(2), A15.
- Garcia, J. L., Silva, M. R., & Oliveira, P. H.** (2021). Improving GNSS performance with ionospheric scintillation prediction using deep learning. *Remote Sensing*, 14(1), 27.
- Garcia, J. L., Silva, M. R., & Oliveira, P. H.** (2023). A comparative analysis of machine learning models for ionospheric scintillation prediction. *IEEE Geoscience and Remote Sensing Letters*, 20(5), 930-937.
- Gou, L., Aquino, M., & Veetil, S. V.** (2019). A comprehensive study of GNSS signal degradation due to ionospheric scintillation. *Journal of Geophysical Research: Space Physics*, 124(10), 8554-8569.

Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer.

Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780.

INPE. Mapa de cintilação ionosférica – INPE (S4). São José dos Campos: INPE, 2023. Disponível em: https://www.researchgate.net/figure/Frequencia-na-ocorrencia-de-cintilacao-Fonte-Adaptado-de-Kintner-Jr-Humphreys-e-Hinks_fig3_365883307. Acesso em: 21/01/2025.

Jiao, Y., Hall, C. D., & Morton, Y. T. (2017). Effects of ionospheric scintillation on GPS receiver tracking performance at low latitudes. *IEEE Transactions on Aerospace and Electronic Systems*, 53(3), 1234-1245.

Johnson, T., Brown, M., & Smith, R. (2020). The application of deep learning to ionospheric disturbance prediction. *Journal of Atmospheric and Solar-Terrestrial Physics*, 210, 105462.

Lee, J., & Park, S. (2021). A hybrid machine learning model for forecasting ionospheric disturbances. *Advances in Space Research*, 68(7), 3421-3432.

Lee, J., Park, S., & Kim, Y. (2022). Predicting ionospheric scintillation using gradient boosting decision trees. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15, 870-881.

Liu, C., Huang, X., Zhang, W., & Sun, J. (2022). Deep learning-based ionospheric prediction using LSTM models. *Journal of Space Weather and Space Climate*, 12(1), A9.

Louppe, G. (2014). *Understanding Random Forests: From Theory to Practice*. Springer Theses.

Lundberg, S. M., & Lee, S. I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 30, 4765-4774.

Mannucci, A. J., Wilson, B. D., Yuan, D. N., Ho, C. M., Lindqwister, U. J., & Runge, T. F. (1998). A global mapping technique for ionospheric total electron content measurements using GPS. *Radio Science*, 33(3), 565-582.

Martinon, A., Zhang, L., Dong, F., & Wang, S. (2023). Influence of equatorial ionospheric irregularities on GNSS performance. *Annales Geophysicae*, 41(2), 307-320.

McGranaghan, R. M., Knipp, D. J., & Redmon, R. J. (2021). Data-driven modeling of ionospheric variability using machine learning. *Space Weather*, 19(6), e2020SW002671.

Nishioka, M., Tsugawa, T., Saito, A., & Otsuka, Y. (2008). Occurrence characteristics of plasma bubbles derived from global ground-based GPS receiver networks. *Journal of Geophysical Research: Space Physics*, 113(A5), A05301.

Pi, X., Mannucci, A. J., Lindqwister, U. J., & Ho, C. M. (1997). Monitoring of global ionospheric irregularities using the worldwide GPS network. *Geophysical Research Letters*, 24(18), 2283-2286.

Probst, P., Wright, M. N., & Boulesteix, A. L. (2019). "Hyperparameters and Tuning Strategies for Random Forest". *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 9(3), e1301.

Rezende, L. F., Souza, J. S., Carvalho, L. F., & Lima, W. S. (2017). Predicting ionospheric scintillation using machine learning techniques. *Journal of Space Weather and Space Climate*, 7(1), A10.

Rezende, L. F., Souza, J. S., & Carvalho, L. F. (2021). Ionospheric scintillation prediction models: A review of current trends. *Annales Geophysicae*, 39(4), 523-540.

Shih, H., Lin, C., & Chang, Y. (2024). Transformer-based forecasting of ionospheric TEC variations. *IEEE Transactions on Geoscience and Remote Sensing*, 62(3), 1402-1413.

Smith, R., Johnson, T., & Brown, M. (2019). A review of ionospheric modeling techniques and their applications. *IEEE Transactions on Aerospace and Electronic Systems*, 55(5), 2301-2312.

Smith, R., Johnson, T., & Brown, M. (2022). Enhancing GNSS-based ionospheric monitoring with deep learning. *Journal of Atmospheric and Solar-Terrestrial Physics*, 220, 105496.