



CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS

CAMPUS ARAXÁ

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE MINAS

MESTRADO PROFISSIONAL

Bruno Gomes dos Santos

**MODELO DE PREDIÇÃO DE CINTILAÇÃO IONOSFÉRICA APLICÁVEL À
OTIMIZAÇÃO DE OPERAÇÃO DE LAVRA SUPORTADA POR COMUNICAÇÃO
GNSS**

Araxá, MG

2026

BRUNO GOMES DOS SANTOS

**MODELO DE PREDIÇÃO DE CINTILAÇÃO IONOSFÉRICA APLICÁVEL À
OTIMIZAÇÃO DE OPERAÇÃO DE LAVRA SUPORTADA POR COMUNICAÇÃO
GNSS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Minas do Centro Federal de Educação Tecnológica de Minas Gerais – CEFET-MG, Campus Araxá, como parte dos requisitos para obtenção do título de Mestre em Engenharia de Minas.

Orientador: Prof. Dr. Domingos Savio de Resende

Coorientador: Prof. Dr. Mateus Antunes Oliveira Leite

Linha de pesquisa: Modelagem preditiva aplicada à degradação do sinal GNSS em ambientes sujeitos à variabilidade ionosférica.

Araxá, MG

2026

**ATA DA 55ª DEFESA DE DISSERTAÇÃO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE MINAS
MESTRADO PROFISSIONAL**

Aos 18 (dezoito) dias do mês de dezembro do ano de 2025 (dois mil e vinte cinco), às 20h00min (vinte horas), através da Plataforma Conferência WEB-RNP, foi instalada a Sessão Pública para a Defesa de Dissertação do Mestrando Bruno Gomes dos Santos, *sob a forma totalmente remota (Resolução CPPG 08/2020, de 09/07/2020; Resolução CEPE 09/2020, de 17/11/2020)*, sendo a banca examinadora composta pelo Prof. Dr. Domingos Savio de Resende (Presidente) – CEFET- MG, Prof. Dr. Mateus Antunes Oliveira Leite (Coorientador) – CEFET-MG, Prof. Dr. Leandro Resende Mattioli (Membro externo) – CEFET-MG e Prof. Dr. Carlos Henrique Nogueira de Resende Barbosa (Membro externo) – UFOP-MG.

Dando início aos trabalhos o Presidente, com base no Regulamento do Programa e nas Normas que regem as Sessões de Defesa de Dissertação, concedeu ao Mestrando **Bruno Gomes dos Santos**, até 40 (quarenta) minutos para a apresentação do seu trabalho intitulado “Modelo de predição de Cintilação Ionosférica aplicável à otimização de operação de lavra suportada por comunicação GNSS”, na Área de Concentração: *Engenharia de Minas* e Linha de Pesquisa *Processamento de Minério e Rejeitos*. Terminada a exposição, o Presidente da Banca examinadora passou a arguição do candidato pelos membros da banca examinadora. Dando continuidade, ainda de acordo com as normas que regem a Sessão, o Presidente solicitou aos presentes que se retirassem do recinto para que a banca examinadora procedesse a análise e decisão, anunciando, a seguir publicamente, que o Mestrando foi **aprovado com recomendações específicas de correção do texto** por unanimidade. Para constar, foi lavrada a presente ATA que, após aprovada, vai assinada pelos membros da Banca Examinadora e pelo Mestrando.

Araxá, 18 de Dezembro de 2025

Prof. Dr. Domingos Savio de Resende
Presidente (CEFET-MG)

Prof. Dr. Leandro Resende Mattioli
Membro externo (CEFET-MG)

Prof. Dr. Mateus Antunes Oliveira Leite
Coorientador (CEFET-MG)

Prof. Dr. Carlos Henrique Nogueira de Resende Barbosa
Membro externo (UFOP)

Eng. Bruno Gomes dos Santos
Discente

Santos, Bruno Gomes dos.
S237m Modelo de predição de cintilação ionosférica aplicável à otimização de operação
de lavra suportada por comunicação GNSS / Bruno Gomes dos Santos. – 2026.
111 f. : il.

Orientador: Prof. Dr. Domingos Sávio de Resende.
Coorientador: Prof. Dr. Mateus Antunes Oliveira Leite.

Dissertação (mestrado) – Centro Federal de Educação Tecnológica de Minas
Gerais, Programa de Pós-Graduação em Engenharia de Minas, Araxá, 2026.
Bibliografia.

1. Mineração – Teses. 2. Mineração a céu aberto – Teses. 3.
Satélites artificiais em sensoriamento remoto – Teses. 4. Ionosfera – Teses. I. Re-
sende, Domingos Sávio de. II. Leite, Mateus Antunes Oliveira. III. Centro Federal de
Educação Tecnológica de Minas Gerais. IV. Título.

CDU 622:528.8

AGRADECIMENTOS

Agradeço primeiramente a Deus, por me conceder saúde, força e perseverança ao longo de toda esta jornada, permitindo que eu superasse os desafios encontrados durante a realização deste trabalho.

Ao meu orientador, Prof. Dr. Domingos Sávio de Resende, e ao meu coorientador, Prof. Dr. Mateus Antunes Oliveira Leite, pela orientação, dedicação, paciência e pelos valiosos ensinamentos, fundamentais para o desenvolvimento e conclusão deste estudo.

Aos professores e aos servidores do CEFET-MG – Campus Araxá, pela contribuição na minha formação acadêmica e profissional, bem como pela estrutura e suporte oferecidos ao longo do curso.

À minha família, pelo amor, incentivo e apoio incondicional em todos os momentos, sendo base essencial para que eu alcançasse mais esta conquista.

Aos meus amigos, pela amizade, companheirismo e pelos momentos de incentivo e descontração, que tornaram essa caminhada mais leve.

Por fim, a todos que, direta ou indiretamente, contribuíram para a realização deste trabalho, o meu sincero agradecimento.

“Em algum lugar, algo incrível está esperando para ser descoberto.”

(Carl Sagan)

RESUMO

Esta dissertação investiga condições associadas à degradação do sinal GNSS em uma mina de nióbio situada no município de Araxá, Minas Gerais, por meio da integração entre dados observacionais, variáveis geofísicas e parâmetros ambientais. A pesquisa parte da relevância do posicionamento por satélites nas operações de lavra a céu aberto, especialmente em atividades que requerem confiabilidade nas observações para controle geométrico, monitoramento operacional e apoio ao planejamento de lavra. Nesse contexto, perturbações ionosféricas associadas à cintilação podem comprometer a estabilidade dos sinais GNSS, exigindo abordagens analíticas capazes de representar, de forma indireta, esse comportamento em condições reais de operação. O objetivo geral consistiu em analisar condições associadas à degradação do sinal GNSS na região de mineração de Araxá (MG), utilizando a variação da pseudodistância L1 como proxy observacional e modelos preditivos de aprendizado de máquina para representar indiretamente o fenômeno e comparar o desempenho das abordagens adotadas. Para isso, foram revisados os fundamentos teóricos sobre ionosfera, cintilação ionosférica, variáveis geofísicas e posicionamento GNSS; organizados e pré-processados os dados observacionais e explicativos; investigados padrões temporais presentes nas variáveis analisadas; e desenvolvidos modelos preditivos baseados nos algoritmos Random Forest e XGBoost. A metodologia foi estruturada em quatro etapas: revisão bibliográfica, coleta e pré-processamento de dados, modelagem preditiva e avaliação de desempenho. Foram utilizados dados obtidos por receptor GNSS de alta precisão, com taxa de amostragem de 1 Hz, incluindo observações das constelações GPS e GLONASS, além de variáveis geofísicas e ambientais relacionadas ao comportamento ionosférico. O desempenho dos modelos foi avaliado pelas métricas R^2 , MSE, MAE e RMSE. Os resultados indicaram elevado desempenho preditivo para ambos os modelos, com forte aderência entre valores estimados e observados e baixos níveis de erro. O Random Forest apresentou desempenho ligeiramente superior ao XGBoost, evidenciando o potencial da abordagem proposta para representar indiretamente condições associadas à degradação do sinal GNSS na área de estudo.

Palavras-chave: cintilação ionosférica; degradação do sinal GNSS; lavra a céu aberto; modelagem preditiva; pseudodistância L1; Random Forest; XGBoost.

ABSTRACT

This dissertation investigates conditions associated with GNSS signal degradation in a niobium mine located in Araxá, Minas Gerais, Brazil, through the integration of observational data, geophysical variables, and environmental parameters. This study is motivated on the relevance of satellite positioning in open-pit mining operations, especially in activities that require reliable observations for geometric control, operational monitoring, and mine planning support. In this context, ionospheric disturbances associated with scintillation may compromise GNSS signal stability, requiring analytical approaches capable of indirectly representing such behavior under real operating conditions. The general objective was to analyze conditions associated with GNSS signal degradation in the mining region of Araxá (MG), using L1 pseudorange variation as an observational proxy and machine learning predictive models to indirectly represent the phenomenon and compare the performance of the adopted approaches. To this end, the theoretical foundations of the ionosphere, ionospheric scintillation, geophysical variables, and GNSS positioning were reviewed; observational and explanatory data were organized and preprocessed; temporal patterns in the analyzed variables were investigated; and predictive models based on the Random Forest and XGBoost algorithms were developed. The methodology was structured into four stages: literature review, data collection and preprocessing, predictive modeling, and performance evaluation. The dataset comprised observations collected by a high-precision GNSS receiver at a 1 Hz sampling rate, including GPS and GLONASS constellations, in addition to geophysical and environmental variables related to ionospheric behavior. Model performance was assessed using the metrics R^2 , MSE, MAE, and RMSE. The results indicated high predictive performance for both models, with strong agreement between estimated and observed values and low error levels. Random Forest showed slightly better performance than XGBoost, highlighting the potential of the proposed approach to indirectly represent conditions associated with GNSS signal degradation in the study area.

Keywords: GNSS signal degradation; ionospheric scintillation; L1 pseudorange; open-pit mining; predictive modeling; Random Forest; XGBoost.

LISTA DE FIGURAS

Figura 1 - Fotoionização.	35
Figura 2 - Divisão da ionosfera em camadas.	35
Figura 3 - Exemplo de buraco coronal, que aparece na imagem como região mais escura.	40
Figura 4 - Estrutura do campo magnético da Terra.	45
Figura 5 - Equador geomagnético no hemisfério Norte no ano de 2020.	47
Figura 6 - Influência do vento solar no campo geomagnético.	48
Figura 7 - Tempestades com início súbito e gradual.	49
Figura 8 – Consequências de uma grande explosão solar.....	50
Figura 9 – Matéria de uma área desaparecida de filamento.....	52
Figura 10 - Variação dos polos magnéticos e geomagnético no hemisfério Norte. ...	54
Figura 11 - Comportamento temporal e espacial das irregularidades ionosféricas. .	59
Figura 12 - Esquematização da cintilação nos sinais GNSS.	60
Figura 13 - Frequência de ocorrência de cintilação de acordo com a localização geográfica.....	61
Figura 14 - Oval auroral sobre a América do Norte.	62
Figura 15 - Distribuição global do índice S4 em 15 de setembro de 2000 às 21h local.....	65
Figura 16 - Imagem aérea da mina de nióbio em Araxá, MG, onde ocorre o estudo.	76
Figura 17 - Fluxograma esquemático da metodologia proposta nesta dissertação. .	77
Figura 18 - Receptor Trimble SPS855 e antena Zephyr Geodetic Modelo 2.....	78
Figura 19 - Estação base de recepção e transmissão GNSS.....	79
Figura 20 - Web interface do receptor.	80
Figura 21 - Web interface de downloads do rastreo.	81
Figura 22 - Software de conversão de arquivos Trimble GNSS.	82
Figura 23 - Metadados de observação.	83
Figura 24 - Fluxograma das etapas de transformação dos dados.....	86
Figura 25 - Manchas solares.	107
Figura 26 - Manchas solares entre 400 anos.	108
Figura 27 - Exemplo do WBMOD.	111
Figura 28 - Exemplos do GISM.	113

LISTA DE TABELAS

Tabela 1 - Características das camadas ionosféricas.....	36
Tabela 2 - Classificação de uma tempestade geomagnética.....	42
Tabela 3 - Valores dos índices K_p e condições da atividade geomagnética.	43
Tabela 4 - Desempenho dos modelos avaliados.	93

LISTA DE QUADRO

Quadro 1 - fenômenos associados ao desaparecimento súbito de filamentos.....	53
---	----

LISTA DE ABREVIATURAS E SIGLAS

AE – Auroral Electrojet

CGM – Corrected GeoMagnetic

DST – Disturbance Storm Time

DGRF/IGRF – Definite/International Geomagnetic Reference Field

GISM – Modelo Global de Cintilação Ionosférica

GNSS – Sistema Global de Navegação por Satélite

GPS – Global Satellite System

HSS – High Speed Stream

ISM – Ionospheric Scintillation Monitor

K_p – Planetarische Kennziffer

NASA – National Aeronautics and Space Administration

NOAA – National Oceanic and Atmospheric Administration

NRCan - Natural Resources Canadá

NWRA – Northwestern Research Associates

PSD – Densidade Espectral de Potência do Sinal

RAIM – Monitoramento de Integridade Autônoma do Receptor

RINEX (Receiver Independent Exchange Format)

SDF Sudden Disappearing Filaments

SSN – Sunspot Number

S4 – Cintilação de amplitude

TEC – Total Electron Content

TECU – Total Electron Content Units

WBMOD – Wide Band Model

SUMÁRIO

1. INTRODUÇÃO	25
1.2 JUSTIFICATIVA	28
1.3 OBJETIVO	30
1.3.1 Objetivo Geral	30
1.3.2 OBJETIVOS ESPECÍFICOS	30
1.4 ESTRUTURA DA DISSERTAÇÃO	31
2 REVISÃO DA LITERATURA	33
2.1 Ionosfera	33
2.1.1 Divisão de camadas da ionosfera	35
2.1.2 Influência da Atividade Solar na Ionosfera	37
2.2 Densidade de elétrons	41
2.2.1 Oscilações temporais	41
2.2.2 Índices Geomagnéticos	42
2.2.3 Influência geomagnética	45
2.3 Conteúdo Total de Elétrons	55
2.3.1 Pseudodistância GNSS e sensibilidade aos efeitos ionosféricos	57
2.4 Cintilação Ionosférica	57
2.5 Estimativas da cintilação ionosférica	63
2.5.1 Cintilação de Amplitude e Índice S4	63
2.5.2 Cintilações de Fase e índice Sigma-Phi	66
2.6 Influência da Cintilação Ionosférica no Posicionamento GNSS	68
2.6.1 Detecção e Correção de Erros nas Mensagens de Navegação	70
2.7 Métodos preditivos	71
2.7.1 Aprendizado de máquina para predição	72
2.7.2 Algoritmos de aprendizagem	73
2.8 Características gerais da área de estudo	75
3 METODOLOGIA	77
3.1 Fundamentação Teórica	77
3.2 Coleta e Pré-Processamento de Dados	77
3.3 Modelos de Aprendizado de Máquina para Cintilação GNSS	86
3.3.1 Random Forest	86
3.3.2 XGBoost (Extreme Gradient Boosting)	87

3.4	Critério e Métricas de Avaliação dos Modelos Preditivos.....	87
3.4.1	Coeficiente de determinação (R^2)	87
3.4.2	Erro Quadrático Médio (MSE).....	88
3.4.3	Erro Médio Absoluto (MAE)	88
3.4.4	Raiz do Erro Quadrático Médio (RMSE).....	88
3.5	Avaliação das Métricas de Desempenho dos Modelos Preditivos	89
4	RESULTADOS	91
4.1	Análise de Desempenho do Random Forest.....	91
4.2	Análise de Desempenho do XGBoost.....	92
4.3	Comparação dos Modelos e Seleção do Mais Eficiente	93
5	CONCLUSÕES	95
6	REFERÊNCIAS BIBLIOGRÁFICAS	97
	APÊNDICE A – CÓDIGO EM LINGUAGEM PYTHON	102
	APÊNDICE B – CICLO SOLAR	107
B.1	Manchas solares	107
	APÊNDICE C – CÓDIGO EM LINGUAGEM PYTHON	110
C.1	Modelos de Cintilação Ionosférica	110
C.1.1	WideBand (WBMOD).....	110
C.1.2	Modelo Global de Cintilação Ionosférica (GISM)	112

1. INTRODUÇÃO

No contexto das operações de lavra a céu aberto, o posicionamento por satélites desempenha papel estratégico no suporte ao controle geométrico, ao monitoramento operacional e ao planejamento de lavra. Em empreendimentos minerários que dependem de elevado rigor posicional, a confiabilidade das observações GNSS assume importância central, uma vez que os dados derivados desses sistemas subsidiam decisões técnicas relacionadas à condução das atividades produtivas, à aferição geométrica das frentes de lavra e ao acompanhamento do desenvolvimento operacional da mina.

Entretanto, o desempenho do posicionamento GNSS de alta precisão não depende exclusivamente da qualidade dos receptores, das técnicas de rastreamento ou dos métodos de processamento adotados. Sua estabilidade também está condicionada à influência de fatores externos que afetam a propagação dos sinais transmitidos pelos satélites. Entre esses fatores, destaca-se a ionosfera, cuja variabilidade espacial e temporal pode introduzir perturbações significativas nas observações GNSS. Dentre os fenômenos ionosféricos de maior relevância para aplicações que exigem maior confiabilidade posicional, sobressai-se a cintilação ionosférica, caracterizada por rápidas flutuações de amplitude e de fase do sinal, associadas a irregularidades na densidade eletrônica do plasma ionosférico.

A ocorrência da cintilação ionosférica insere-se em um sistema físico complexo, relacionado à interação entre atividade solar, condições geomagnéticas, dinâmica da ionosfera e variáveis ambientais. Em razão dessa natureza multifatorial, seus efeitos podem variar em intensidade, duração e frequência de ocorrência, comprometendo o rastreamento dos sinais, degradando observáveis GNSS e reduzindo a estabilidade das medições. Em aplicações críticas, como as desenvolvidas no setor mineral, tais perturbações assumem relevância particular, pois eventuais perdas de qualidade nas observações podem afetar a consistência técnica dos dados utilizados no acompanhamento e no controle das operações de lavra.

Na mina de nióbio situada no município de Araxá, em Minas Gerais, o uso de posicionamento GNSS de alta precisão integra diretamente as rotinas operacionais e os procedimentos de controle geométrico. Nesse cenário, torna-se necessário compreender, de maneira sistemática, as condições associadas à degradação do sinal GNSS, especialmente em períodos nos quais o comportamento ionosférico pode

comprometer a qualidade das observações. Mais do que descrever genericamente a ocorrência da cintilação ionosférica, impõe-se a necessidade de investigá-la em articulação com os dados efetivamente observados em campo e com variáveis capazes de representar o estado do ambiente geofísico em que o fenômeno se manifesta.

É nesse contexto que se insere a presente dissertação. A pesquisa parte do entendimento de que a degradação do sinal GNSS, em ambiente minerário, pode ser analisada por meio da integração entre dados observacionais provenientes de receptor GNSS de alta precisão e variáveis geofísicas e ambientais associadas ao comportamento ionosférico. Nessa perspectiva, a variação da pseudodistância L1 é adotada como proxy observacional da degradação do sinal, permitindo representar indiretamente os efeitos associados às perturbações ionosféricas nos períodos analisados. Essa escolha metodológica aproxima a investigação do comportamento real dos dados coletados em campo e confere maior aderência entre a análise proposta e as condições concretas de operação da área de estudo.

A dissertação também se fundamenta na premissa de que a complexidade desse problema exige abordagens analíticas capazes de lidar com relações não lineares e com a interação simultânea entre múltiplas variáveis explicativas. Por essa razão, são empregados modelos de aprendizado de máquina baseados nos algoritmos Random Forest e XGBoost, selecionados por sua reconhecida capacidade de representar padrões complexos, integrar atributos heterogêneos e produzir estimativas consistentes em tarefas de regressão. No presente estudo, tais algoritmos são utilizados para modelar a variação da pseudodistância L1 a partir da integração entre dados observacionais, variáveis geofísicas e parâmetros ambientais, permitindo comparar o desempenho das abordagens adotadas.

Sob esse enfoque, a pesquisa não pretende afirmar a mensuração direta da cintilação ionosférica por meio dos índices clássicos S4 e Sigma-Phi, mas investigar, de forma indireta, condições associadas à degradação do sinal GNSS em uma área real de mineração. Com isso, busca-se construir uma interpretação analítica do problema, articulando fundamentação física, observação empírica e modelagem preditiva em uma mesma estrutura investigativa.

Dessa forma, o trabalho se organiza de modo a estabelecer uma sequência lógica entre o problema estudado, a base teórica mobilizada, os procedimentos metodológicos adotados e os resultados alcançados. O Capítulo 2 apresenta a revisão

da literatura, contemplando os fundamentos relacionados à ionosfera, à cintilação ionosférica, aos índices e variáveis geofísicas relevantes, aos observáveis GNSS e aos métodos preditivos empregados. O Capítulo 3 descreve a metodologia, incluindo a caracterização da área de estudo, a coleta e o pré-processamento dos dados, a definição das variáveis utilizadas e a configuração dos modelos Random Forest e XGBoost. O Capítulo 4 apresenta e discute os resultados obtidos, com ênfase no desempenho preditivo dos modelos. Por fim, o Capítulo 5 reúne as conclusões da pesquisa, destacando suas contribuições, limitações e possibilidades de aprofundamento em trabalhos futuros.

1.2 JUSTIFICATIVA

A crescente utilização de sistemas GNSS nas operações de lavra a céu aberto reforça a necessidade de compreender, com maior rigor, os fatores que podem comprometer a estabilidade e a confiabilidade dos sinais utilizados em atividades de controle geométrico, monitoramento operacional e suporte ao planejamento de lavra. Em empreendimentos como a mina de nióbio localizada em Araxá (MG), a qualidade das observações GNSS assume papel relevante, uma vez que eventuais degradações do sinal podem afetar a consistência dos dados empregados nas rotinas técnicas de acompanhamento da operação.

Entre os fatores externos capazes de interferir no desempenho desses sistemas, a cintilação ionosférica se destaca por estar associada a irregularidades na densidade eletrônica da ionosfera, as quais podem provocar flutuações rápidas na propagação dos sinais de navegação. Embora esse fenômeno seja amplamente reconhecido na literatura, ainda são limitados os estudos aplicados ao contexto da mineração brasileira que articulem, de forma integrada, dados observacionais GNSS, variáveis geofísicas e parâmetros ambientais em condições reais de operação.

Nesse contexto, a presente dissertação justifica-se pela necessidade de avançar da descrição geral do problema para uma abordagem analítica baseada em dados, capaz de investigar condições associadas à degradação do sinal GNSS na área de estudo. Em vez de restringir a análise a indicadores conceituais do fenômeno, o trabalho adota uma perspectiva observacional, utilizando a variação da pseudodistância L1 como proxy da degradação do sinal e integrando-a a variáveis explicativas representativas do ambiente ionosférico e geomagnético. Tal escolha confere maior aderência entre a modelagem desenvolvida e o comportamento real das observações coletadas em campo.

A relevância da pesquisa também se expressa no emprego de técnicas de aprendizado de máquina, especificamente os algoritmos Random Forest e XGBoost, cuja aplicação possibilita explorar relações não lineares e interações complexas entre os dados rastreados e os parâmetros geofísicos e ambientais selecionados. Os resultados obtidos evidenciam elevado desempenho preditivo para ambas as abordagens, com ligeira superioridade do Random Forest, indicando que a integração entre variáveis observacionais e geofísicas constitui base consistente para representar indiretamente a degradação do sinal GNSS nos períodos analisados.

Sob a perspectiva técnico-científica, o estudo contribui para o entendimento das condições associadas à degradação do sinal GNSS em ambiente minerário e oferece subsídios metodológicos para futuras aplicações voltadas ao monitoramento e à interpretação desse comportamento em operações que dependem de maior rigor posicional. Assim, a dissertação se justifica tanto por sua contribuição acadêmica quanto por seu potencial de aplicação em análises futuras de suporte à tomada de decisão em campo.

1.3 OBJETIVO

Considerando a relevância do posicionamento GNSS em operações de lavra a céu aberto e a influência de fatores ionosféricos sobre a estabilidade dos sinais de navegação, esta dissertação tem como propósito investigar, em condições reais de operação, variáveis associadas à degradação do sinal GNSS na mina de nióbio localizada em Araxá, Minas Gerais. Para tanto, a pesquisa articula dados observacionais obtidos em campo com variáveis geofísicas e ambientais, adotando abordagem preditiva baseada em aprendizado de máquina. Nesse contexto, os objetivos da investigação são apresentados a seguir.

1.3.1 Objetivo Geral

O objetivo geral desta pesquisa é analisar condições associadas à degradação do sinal GNSS na região de mineração de Araxá (MG), com base em dados observacionais, variáveis geofísicas e ambientais, utilizando a variação da pseudodistância L1 como proxy observacional e modelos preditivos de aprendizado de máquina para representar indiretamente o fenômeno e comparar o desempenho das abordagens adotadas.

1.3.2 OBJETIVOS ESPECÍFICOS

Para o desenvolvimento desta dissertação, estabelecem-se os seguintes objetivos específicos:

- (a) Revisar os fundamentos teóricos relacionados à ionosfera, à cintilação ionosférica, aos índices e variáveis geofísicas associados ao fenômeno e ao posicionamento GNSS;
- (b) Organizar, tratar e analisar dados observacionais GNSS, em conjunto com variáveis geofísicas e ambientais, para compor a base de dados utilizada na modelagem da degradação do sinal;
- (c) Investigar padrões temporais presentes nas observações e nas variáveis explicativas, associados às variações da pseudodistância L1 na área de estudo;
- (d) Desenvolver e avaliar modelos preditivos baseados nos algoritmos Random Forest e XGBoost para estimar a variação da pseudodistância L1, comparando seu desempenho por meio de métricas estatísticas adequadas.

1.4 ESTRUTURA DA DISSERTAÇÃO

Esta dissertação é estruturada em 5 capítulos que compõem a organização geral do trabalho. São eles:

- (i) Capítulo 1: apresenta a introdução da pesquisa, contemplando a contextualização do tema, a delimitação do problema investigado, a justificativa da relevância do estudo, os objetivos gerais e específicos e a organização da dissertação. Nesse capítulo, discute-se a importância do posicionamento GNSS em operações de lavra a céu aberto e a necessidade de investigar condições associadas à degradação do sinal em ambiente minerário, com ênfase na área de estudo localizada em Araxá, Minas Gerais;
- (ii) Capítulo 2: reúne a revisão da literatura, oferecendo o suporte conceitual necessário ao desenvolvimento da pesquisa. São abordados os fundamentos relacionados à ionosfera, à influência da atividade solar e geomagnética, à densidade de elétrons, ao conteúdo total de elétrons (TEC), à cintilação ionosférica, aos índices clássicos de amplitude e fase, aos efeitos sobre o posicionamento GNSS e aos métodos preditivos baseados em aprendizado de máquina. Esse capítulo também estabelece a ligação entre a base física do fenômeno e as variáveis observacionais, geofísicas e ambientais posteriormente utilizadas na modelagem;
- (iii) Capítulo 3: descreve os procedimentos metodológicos adotados na pesquisa. Nele são apresentadas a caracterização da área de estudo, as fontes de dados utilizadas, as etapas de coleta, organização e pré-processamento das informações, a definição das variáveis explicativas e da variável de interesse, bem como a configuração dos modelos preditivos aplicados. Nesse contexto, detalha-se a utilização da variação da pseudodistância L1 como proxy observacional da degradação do sinal GNSS, assim como a aplicação dos algoritmos Random Forest e XGBoost para a representação indireta do fenômeno investigado;
- (iv) Capítulo 4: apresenta os resultados obtidos a partir da modelagem desenvolvida, com ênfase na análise do desempenho preditivo dos algoritmos empregados. São discutidas as métricas estatísticas utilizadas na avaliação dos modelos, bem como a comparação entre as abordagens

adotadas. A análise busca evidenciar em que medida a integração entre dados observacionais, variáveis geofísicas e parâmetros ambientais se mostrou consistente para representar condições associadas à degradação do sinal GNSS na área de estudo.

- (v) Capítulo 5 reúne as conclusões da pesquisa, sintetizando os principais achados, suas contribuições acadêmicas e metodológicas, as limitações do estudo e as possibilidades de aprofundamento em trabalhos futuros. Nesse capítulo final, retoma-se a relação entre os objetivos propostos, a metodologia aplicada e os resultados obtidos, consolidando a contribuição da dissertação para a compreensão indireta da degradação do sinal GNSS em ambiente minerário.

2 REVISÃO DA LITERATURA

O presente capítulo reúne os fundamentos teóricos necessários à compreensão da influência da ionosfera sobre a propagação dos sinais GNSS e, em particular, dos mecanismos físicos associados à cintilação ionosférica. Considerando que o fenômeno investigado nesta dissertação resulta da interação entre processos solares, geomagnéticos, ionosféricos e observacionais, a revisão da literatura foi estruturada de modo a contemplar, de forma integrada, os principais elementos que sustentam a análise proposta. Nesse sentido, são abordados os conceitos relacionados à ionosfera, à variabilidade da densidade de elétrons, aos índices geomagnéticos, ao conteúdo total de elétrons, às pseudodistâncias GNSS, aos índices clássicos de cintilação e aos efeitos do fenômeno sobre o posicionamento por satélites, além dos fundamentos dos métodos preditivos utilizados posteriormente na modelagem. A organização deste capítulo busca não apenas apresentar os conceitos clássicos da literatura, mas também estabelecer a ponte entre a fundamentação física do problema e a abordagem metodológica adotada no Capítulo 3. Assim, os tópicos aqui discutidos oferecem suporte à interpretação das variáveis geofísicas e observacionais empregadas na modelagem, bem como à compreensão do uso de algoritmos de aprendizado de máquina para representar, de forma indireta, a degradação do sinal GNSS em condições ionosféricas perturbadas.

2.1 Ionosfera

A ionosfera é uma região da atmosfera terrestre caracterizada pela presença de partículas ionizadas, especialmente íons positivos e elétrons livres, capazes de influenciar significativamente a propagação de ondas eletromagnéticas (CORDEIRO, 2005). Sua formação decorre, principalmente, da interação entre a radiação solar de alta energia e os constituintes neutros da atmosfera superior, por meio do processo de fotoionização (CARVALHO, 2021). Em consequência, a ionosfera passa a atuar como um meio dispersivo, no qual a propagação dos sinais de rádio depende da frequência da onda e da distribuição espacial e temporal da densidade eletrônica (BORA, 2017; CARVALHO, 2021). Do ponto de vista aplicado, essa característica torna a ionosfera particularmente relevante para os sistemas de navegação por satélite. Os sinais GNSS, ao atravessarem essa região, podem sofrer atrasos, flutuações de fase e amplitude e até perda de rastreamento, dependendo do estado ionosférico. Assim, a compreensão da estrutura e da dinâmica da ionosfera constitui


requisito fundamental para o diagnóstico e a interpretação das perturbações que afetam o posicionamento em aplicações de alta precisão.

No contexto desta dissertação, a ionosfera não é tratada apenas como pano de fundo físico do problema, mas como elemento central para a compreensão das variáveis explicativas utilizadas na modelagem preditiva. Sua variabilidade influencia diretamente o comportamento de parâmetros como TEC, índices geomagnéticos e observáveis GNSS, tornando indispensável sua discussão em uma revisão da literatura voltada à análise da degradação do sinal em ambiente minerário.

A estrutura da ionosfera é composta por várias camadas, cuja composição e taxas de ionização variam conforme a atmosfera neutra (BORA, 2017; CARVALHO, 2021). Estendendo-se de aproximadamente 50 a 1000 km acima da superfície terrestre, a ionosfera serve como um meio de propagação de sinais, permitindo a comunicação global por meio das ondas de rádio (VANI, 2014). Nesta região, a densidade de íons e elétrons é suficientemente alta para afetar as ondas de rádio (NUNES, 1982). A ionização ocorre devido à absorção da radiação solar e dos raios X na faixa do ultravioleta extremo (EUV) pelos átomos neutros da atmosfera. Este processo envolve a transferência de energia dos fótons para os elétrons dos átomos neutros, que se separam e se tornam livres. Consequentemente, os átomos neutros transformam-se em íons positivos ao perderem seus elétrons negativos (McNAMARA, 1991; DAL POZ, 2010). Os elétrons livres são capazes de refletir as ondas de rádio, facilitando a comunicação através da ionosfera (McNAMARA, 1991; DAL POZ, 2010).

Na ionosfera, também ocorrem processos inversos à fotoionização, como a recombinação e a ligação. A recombinação consiste na união de elétrons livres negativos com íons positivos, formando átomos neutros. A ligação ocorre quando os elétrons se combinam com átomos neutros, formando íons negativos. Esses processos reduzem a densidade de elétrons livres na ionosfera, pois os íons positivos e negativos são mais pesados que os elétrons e não interagem com as ondas de rádio (McNAMARA, 1991). A recombinação e a ligação ocorrem continuamente, enquanto a fotoionização depende da presença da radiação solar. Por isso, a densidade de elétrons na ionosfera é maior durante o dia, quando a fotoionização é mais intensa, e menor durante a noite, quando a recombinação predomina (McNAMARA, 1991). Ao amanhecer, o número de elétrons livres aumenta novamente por meio da fotoionização (McNAMARA, 1991). O esquema da fotoionização é apresentado na


Figura 1.

Figura 1 - Fotoionização.

Fonte: Adaptado DAL POZ (2010).

2.1.1 Divisão de camadas da ionosfera

Segundo DAL POZ (2010), a ionosfera é composta por três camadas distintas, denominadas D, E e F, cada uma apresentando diferentes densidades de elétrons conforme a altitude. A divisão dessas camadas é ilustrada na **Figura 2**. A densidade volumétrica de elétrons livres nas regiões da ionosfera é expressa em número de elétrons por centímetro cúbico.

Figura 2 - Divisão da ionosfera em camadas.

Fonte: Adaptado de DAL POZ (2010).

A camada D, localizada entre 50 e 90 km de altitude, reflete sinais de baixa frequência, mas não afeta significativamente os observáveis GNSS (DAVIES, 1990; DAL POZ, 2010). A camada E, situada em torno de 100 km de altitude, foi a primeira a ser descoberta e é conhecida como “campo elétrico” (McNAMARA, 1991).

A camada F, que se estende de 150 a 1000 km de altitude, divide-se em F1 e F2. Durante a noite, as camadas D, E e F1 têm sua densidade eletrônica reduzida devido à predominância dos processos de recombinação e ligação sobre a fotoionização (DAL POZ, 2010). No entanto, a camada F2 apresenta uma maior variabilidade ionosférica, causando efeitos mais severos nos sinais GNSS, como as cintilações (DAL POZ, 2010).

A ionosfera apresenta comportamentos distintos nos períodos diurno e noturno, sendo essa diferença principalmente atribuída à variação na densidade de elétrons. Durante o dia, a radiação solar incide sobre a atmosfera terrestre, promovendo a ionização das partículas e, conseqüentemente, elevando a densidade de elétrons. No entanto, com o desaparecimento da radiação solar à noite, ocorre uma queda significativa nessa densidade, conforme ilustrado na **Figura 2**. Esse fenômeno é resultado do processo de recombinação, no qual os elétrons livres se recombinaem com íons positivos, reduzindo a quantidade de partículas ionizadas.

Segundo Seeber (1993), as características das camadas ionosféricas variam consideravelmente entre o dia e a noite. A **Tabela 1** resume essas diferenças, evidenciando, por exemplo, o desaparecimento quase completo da camada D durante o período noturno. Além disso, observa-se que a concentração máxima de elétrons, que durante o dia pode atingir valores da ordem de 10^6 el/m³ na camada F2.

Tabela 1- Características das camadas ionosféricas.

Camadas	Início e término das camadas (km)	Concentração máxima de elétrons (el/m ³) - dia	Concentração máxima de elétrons (el/m ³) – noite
D	50 - 90	$10^2 - 10^4$	—
E	90 - 140	10^5	2×10^3
F ₁	140 - 200	5×10^5	5×10^4
F ₂	200 - 1000	10^6	3×10^5

Fonte: Seeber (1993).

É importante destacar que a estrutura da ionosfera é apresentada em função da altitude, mas suas camadas são concêntricas à Terra e sofrem variações também em função da latitude. Nesse contexto, a região F equatorial, localizada em baixas

latitudes, assume papel fundamental na análise dos efeitos ionosféricos sobre os sinais GNSS, devido à sua dinâmica altamente complexa.

A característica mais marcante da ionosfera é, sem dúvida, a elevada variabilidade da densidade de elétrons. Essa variabilidade, juntamente com as irregularidades ionosféricas, constitui a principal fonte de interferência nos sinais de posicionamento por GNSS, afetando diretamente a precisão e a confiabilidade desses sistemas.

Entre as camadas ionosféricas, a região F2 assume maior relevância neste estudo por concentrar a maior variabilidade eletrônica e por estar diretamente associada às perturbações que afetam a propagação dos sinais GNSS.

2.1.2 Influência da Atividade Solar na Ionosfera

O sol é uma estrela de tamanho médio, com um raio cerca de 100 vezes maior que o da Terra e uma massa aproximadamente 300.000 vezes superior à do nosso planeta. A influência do sol na ionosfera pode ser analisada sob dois aspectos: sol em estado estável e sol em estado ativo. Na maior parte do tempo, o sol permanece em estado estável e não provoca efeitos relevantes nas comunicações de rádio de alta frequência. No entanto, qualquer pequena perturbação no sol pode interromper esse tipo de serviço (McNAMARA, 1991).

As manchas solares, a emissão de radiação ultravioleta e raios X e o transporte de plasma solar constituem indicadores relevantes desse processo. Em especial, o vento solar, formado por partículas carregadas emitidas pela coroa solar, atua sobre a magnetosfera terrestre, alterando o campo geomagnético e favorecendo a ocorrência de tempestades espaciais. Tais perturbações podem modificar a distribuição da densidade de elétrons, influenciar a estabilidade da ionosfera e aumentar a probabilidade de efeitos adversos sobre os sinais GNSS.

Atualmente, as manchas solares são utilizadas para estudar os efeitos do sol na ionosfera. Existem centros de observação que classificam diariamente o número de manchas solares, como a National Oceanic and Atmospheric Administration (NOAA). O número de manchas solares (Sunspot Number – SSN) é obtido pela contagem do número de grupos de manchas solares e do número de manchas individuais, seguindo a fórmula (McNAMARA, 1991):

$$SSN=10N_G+N_I \quad (2.1)$$

onde N_G e N_I referem-se respectivamente ao número de grupos de manchas e ao número de manchas individuais.

Segundo McNamara (1991), as manchas solares tendem a surgir em grupos localizados em torno de 30° de latitude ao norte e ao sul do equador solar, sendo ausentes nas regiões polares. Essas manchas se destacam por sua aparência escurecida, resultado de estarem situadas em áreas mais frias da superfície solar, com temperaturas em torno de 4000°C , em contraste com os 6000°C das regiões ao redor.

Outra forma de observar o sol é utilizando telescópios que operam fora da atmosfera terrestre e em comprimentos de onda muito curtos, como raios X e ultravioleta extremo. Nesses comprimentos de onda, é possível visualizar a coroa solar, uma camada externa e brilhante que envolve o sol. A coroa solar também pode ser vista durante eclipses solares totais, quando a Lua oculta o disco solar, deixando apenas a coroa visível (McNAMARA, 1991).

A coroa solar emite um fluxo contínuo de partículas eletricamente carregadas que se propagam pelo espaço interplanetário, conhecido como vento solar. Esse vento solar tem uma influência significativa na formação da ionosfera terrestre, uma camada da atmosfera, compostas por íons e elétrons (KIRCHHOFF, 1991; DAL POZ, 2010). O vento solar transporta milhões de toneladas de matéria solar e atinge velocidades de cerca de 400 km/s . As partículas do vento solar levam cerca de cinco dias para chegar à Terra e, devido à sua baixa densidade, não são percebidas diretamente por nós. No entanto, elas causam variações elétricas que afetam o campo magnético terrestre e a ionosfera (McNAMARA, 1991).

A pressão de fluxo de partículas solares, também chamada de pressão dinâmica do vento solar, corresponde à pressão exercida pelo plasma emitido continuamente pela coroa solar sobre o campo magnético terrestre e a ionosfera. Essa pressão depende, principalmente, da densidade de partículas carregadas e do quadrado da velocidade com que o vento solar alcança a magnetosfera: aumentos na densidade ou na velocidade do fluxo resultam em maior compressão da magnetosfera e intensificação das correntes elétricas e das perturbações geomagnéticas. Como discutido por McNAMARA (1991) e KIRCHHOFF (1991), esse fluxo contínuo de partículas provenientes do Sol é um dos principais agentes desencadeadores de tempestades geomagnéticas, que podem evoluir para tempestades ionosféricas e modificar significativamente a distribuição de densidade de elétrons na ionosfera


(FEDRIZZI, 2003; DAL POZ, 2010). Essas variações na pressão de fluxo afetam diretamente a propagação dos sinais GNSS, aumentando a probabilidade de cintilação e de perdas de bloqueio em receptores de posicionamento de alta precisão, especialmente em regiões de baixas latitudes, como o território brasileiro.

Outro fenômeno solar observável em comprimentos de onda curtos são as explosões solares, que são liberações repentinas e intensas de energia na superfície ou atmosfera do sol. Essas explosões solares produzem alterações na radiação solar, emitindo raios ultravioleta e raios X, que podem afetar as comunicações e os satélites artificiais (McNAMARA, 1991).

2.1.2.1 Variação da radiação solar

A radiação solar apresenta variações em diferentes escalas temporais, desde flutuações de curta duração até oscilações associadas ao ciclo solar. Tais mudanças afetam a taxa de ionização da atmosfera e, conseqüentemente, a estrutura eletrônica da ionosfera (WEBSTER, 1993). Três fenômenos principais estão relacionados a essas variações. O primeiro refere-se às explosões solares, conhecidas como solar flares, que resultam de um súbito aumento de energia na superfície solar, liberada principalmente nas faixas de raios-X e ultravioleta. O segundo fenômeno está associado aos chamados buracos coronais, como mostra a, **Figura 3** que são regiões da coroa solar que funcionam como fontes de ventos solares de alta velocidade, especialmente frequentes durante a fase de declínio da atividade solar. Nesses casos, o vento solar escapa por essas áreas aquecidas da coroa, contribuindo para a formação da heliosfera. Durante esse processo, as partículas solares são aceleradas, atingindo velocidades significativamente maiores, aumentando a pressão de fluxo dessas partículas no meio interplanetário. Por fim, o terceiro tipo de variação está associado às manchas solares, conforme discutido na subseção anterior. No Apêndice B é possível observar uma descrição mais detalhada das manchas solares.

Figura 3 - Exemplo de buraco coronal, que aparece na imagem como região mais escura.



Fonte: https://solarscience.msfc.nasa.gov/images/Yohkoh_920508.jpg

Uma característica notável dos buracos coronais é sua localização predominante nas regiões polares do Sol, onde as linhas do campo magnético permanecem abertas. Essa configuração permite um fluxo mais intenso de vento solar nessas áreas, em comparação com as regiões onde o campo magnético é fechado (WEBSTER, 1993). Como resultado, os buracos coronais passam a emitir fluxos de vento solar intensificados, capazes de desencadear tempestades espaciais. Essas tempestades apresentam propriedades distintas daquelas causadas por explosões solares ou pelo desaparecimento repentino de filamentos.

Embora indicadores como o F10.7 sejam amplamente utilizados na literatura para caracterizar a atividade solar, esta dissertação privilegia variáveis mais diretamente associadas ao acoplamento Sol-magnetosfera-ionosfera, como pressão de fluxo, componentes do campo magnético interplanetário e campo elétrico

interplanetário, por sua aderência ao comportamento de curto prazo das perturbações analisadas.

2.2 Densidade de elétrons

A densidade de elétrons é um dos parâmetros mais representativos do estado ionosférico, pois expressa a quantidade de elétrons livres disponíveis para interagir com as ondas eletromagnéticas que atravessam a atmosfera superior. Sua variação resulta da ação combinada da radiação solar, das condições geomagnéticas, da latitude e de processos dinâmicos de transporte e recombinação.

Do ponto de vista dos sistemas GNSS, a densidade eletrônica é diretamente responsável pelos atrasos ionosféricos e pela suscetibilidade do sinal a instabilidades. Em condições de maior irregularidade, essas variações podem comprometer tanto a medida de código quanto a de fase, afetando a acurácia e a continuidade do rastreo. Por essa razão, a densidade de elétrons constitui elemento central para a compreensão do fenômeno investigado nesta pesquisa.

2.2.1 Oscilações temporais

A densidade eletrônica da ionosfera apresenta oscilações temporais em diferentes escalas, incluindo variações diurnas, sazonais e associadas ao ciclo solar. Durante o dia, a incidência de radiação solar intensifica a fotoionização e eleva a quantidade de elétrons livres, ao passo que, durante a noite, a recombinação reduz progressivamente essa densidade (WEBSTER, 1993). Como resultado, a ionosfera exhibe padrões horários bem definidos, com implicações diretas sobre a propagação dos sinais GNSS.

Além da escala diária, a densidade de elétrons também responde à variação sazonal, em razão das mudanças no ângulo zenital solar, e a escalas mais longas associadas ao ciclo de atividade solar. Esses comportamentos são particularmente importantes para estudos aplicados, pois demonstram que a variabilidade ionosférica não ocorre de forma aleatória, mas segundo padrões temporais que podem ser observados, analisados e incorporados à modelagem.

No contexto desta dissertação, essa discussão oferece suporte teórico à análise de padrões temporais e à construção de atributos derivados da série

observacional, uma vez que a variabilidade ionosférica influencia diretamente o comportamento dos sinais coletados ao longo do tempo.

2.2.2 Índices Geomagnéticos

A atividade geomagnética da Terra e seus componentes pode ser descrita por meio de alguns indicadores, que são índices que quantificam as variações do campo magnético terrestre ao longo do tempo e do espaço. Esses indicadores são úteis para caracterizar os efeitos das perturbações solares e do vento solar sobre o ambiente espacial e a atmosfera terrestre. Os indicadores mais comumente utilizados na literatura são: (i) o índice DST (Disturbance Storm Time), que mede o efeito das tempestades geomagnéticas sobre o campo magnético equatorial; (ii) o índice K_p (Planetary Kennziffer), que mede a atividade geomagnética global em intervalos de três horas; e (iii) o índice AE (Auroral Electrojet), que mede a atividade geomagnética nas regiões aurorais, onde ocorrem as correntes elétricas denominadas eletrojetos (DAL POZ, 2010).

O índice Dst, expresso em nanoTesla (nT), corresponde à envoltória das curvas obtidas por meio de registros magnetométricos de uma rede de magnetômetros distribuídos ao longo da região equatorial do planeta (YAMASHITA, 1999). Esse índice é amplamente utilizado para caracterizar tempestades geomagnéticas, pois apresenta um comportamento típico antes, durante e após esses eventos. No início da tempestade, observa-se um aumento súbito na intensidade do índice, conhecido como “fase inicial” ou “início súbito”. Em seguida, ocorre a “fase principal”, marcada por uma queda acentuada nos valores do Dst. Após atingir seu ponto mínimo, o índice começa a se recuperar gradualmente, entrando na chamada “fase de recuperação”, até retornar a níveis considerados calmos, indicando a ausência de tempestade (YAMASHITA, 1999). A **Tabela 2** classifica as tempestades geomagnéticas.

Tabela 2 - Classificação de uma tempestade geomagnética.

Condição da Tempestade Geomagnética	Valor do índice Dst (nT)
Fraca	-30 nT a -50 nT
Moderada	-50 nT a -100 nT
Intensa	-100 nT a -250 nT
Muito intensa	< -250 nT

Fonte: Fedrizzi (2003).

O índice K_p é derivado do índice K , que é um índice local que representa as mudanças na atividade geomagnética em uma determinada estação observatória. O índice K está associado à atividade geomagnética, assumindo valores entre 0 e 9, esse índice é calculado a partir das flutuações no componente horizontal do campo magnético, medidas por magnetômetros espalhados pelo mundo. Os valores do índice K são padronizados para diferentes localidades distribuídas pelo mundo, levando em conta as características geográficas e geomagnéticas de cada local. O índice K_p é obtido a partir da média aritmética dos índices K de 13 estações observatórias selecionadas, que cobrem uma faixa de latitudes médias. O índice K_p , portanto, também varia de 0 a 9, sendo 0 o valor muito calmo e 9 o valor muito perturbado, conforme a **Tabela 3**, para atividade geomagnética global. Existem oito valores de K_p para cada dia, começando na zero hora e terminando na vigésima primeira hora (DAL POZ, 2010).

Tabela 3 - Valores dos índices K_p e condições da atividade geomagnética.

Atividade Geomagnética	Valor do índice K_p
Muito calmo	0 a 1
Calmo	1 a 2-
Normal	2 a 3+
Perturbado	3+ a 4+
Muito perturbado	4+ a 9

Fonte: Adaptado de FEDRIZZI (2003).

O indicador AE permite avaliar a atividade geomagnética nas regiões aurais, que são as regiões polares onde ocorrem as auroras boreais e austrais. As auroras são fenômenos luminosos que resultam da interação entre as partículas do vento solar e os átomos e moléculas da atmosfera terrestre. As regiões aurais também são as áreas onde se formam as correntes elétricas denominadas eletrojetos, que são fluxos de elétrons que circulam ao longo das linhas do campo magnético terrestre. O indicador AE mede as variações na componente horizontal do campo magnético terrestre causadas pelos eletrojetos, utilizando dados de estações observatórias localizadas no hemisfério norte. O indicador AE é expresso em nanotesla (nT), e quanto maior seu valor, maior é a intensidade do eletrojetos e da atividade geomagnética nas regiões aurais (DAL POZ, 2010).

Para analisar a atividade geomagnética nas regiões aurais, é necessário utilizar um índice magnético que evidencie a influência do eletrojetos auroral. Nesse contexto, o índice AE é amplamente empregado, sendo calculado a partir das variações na componente horizontal do campo magnético terrestre, medidas por uma rede de observatórios estrategicamente posicionados ao longo da zona auroral do hemisfério norte (YAMASHITA, 1999).

Os índices Kp e AE, apresentados nesta subseção, serão posteriormente utilizados como variáveis de entrada nos modelos de aprendizado de máquina (Capítulo 3), permitindo investigar sua correlação com episódios de cintilação na área de estudo.

Durante a fase inicial de uma tempestade geomagnética, o campo magnético interplanetário (IMF) encontra-se orientado para o norte. No entanto, quando o IMF se inverte para o sul, ocorre a entrada de plasma na magnetosfera interna. Nessa condição, as linhas do campo magnético terrestre se conectam às do IMF sobre as calotas polares, sendo então arrastadas pelo vento solar para o lado noturno do planeta, onde se reconectam na cauda da magnetosfera.

Uma subtempestade pode ser desencadeada por uma inversão rápida do IMF para o sul, com duração entre 30 e 60 minutos. Caso essa orientação sul persista por um período mais prolongado, a atividade geomagnética se intensifica, gerando uma sequência de subtempestades que culminam em uma tempestade geomagnética. As partículas injetadas na magnetosfera interna se deslocam em direções opostas, prótons para oeste e elétrons para leste, formando a chamada corrente de anel, que circula no sentido oeste. Essa corrente provoca uma redução significativa na componente horizontal do campo magnético em escala global, caracterizando a fase principal da tempestade.

Enquanto houver injeção de plasma, a corrente de anel se intensifica até atingir um ponto de equilíbrio, no qual a taxa de entrada de partículas se iguala à de perda. Quando o IMF enfraquece ou retorna à orientação norte, a corrente deixa de crescer e a perturbação magnética começa a diminuir, marcando o início da fase de recuperação da tempestade. Segundo Batista (2003b), essas tempestades podem durar de um a cinco dias.

A fase inicial pode variar de alguns minutos até mais de 15 horas, enquanto a fase principal costuma durar cerca de um dia. Já a fase de recuperação pode se estender por vários dias. Como mencionado anteriormente, a intensificação da


corrente de anel, composta por partículas do cinturão de Van Allen, localizado entre 3 e 5 raios terrestres é responsável pela fase principal. A fase de recuperação, por sua vez, decorre da perda dessas partículas, o que enfraquece a corrente de anel.

Nesta dissertação, os índices Kp e AE assumem importância particular por integrarem o conjunto de variáveis explicativas empregado na modelagem. Seu uso justifica-se pela capacidade de representar, de forma sintética, o estado geomagnético do sistema terrestre e sua possível correlação com condições favoráveis à degradação do sinal GNSS.

2.2.3 Influência geomagnética

A influência geomagnética sobre a ionosfera decorre da interação entre o campo magnético terrestre, o vento solar e o campo magnético interplanetário. Quando essa interação se intensifica, ocorrem perturbações que modificam o transporte de partículas carregadas e a distribuição da densidade de elétrons, favorecendo o surgimento de tempestades geomagnéticas e ionosféricas. O campo magnético da Terra pode ser descrito por diferentes sistemas de coordenadas, que dependem da definição dos polos magnéticos e do equador magnético. A **Figura 4** apresenta as linhas de força do campo geomagnético, evidenciando que o eixo do dipolo magnético terrestre não está alinhado com o eixo de rotação do planeta (McNAMARA, 1991).

Figura 4 - Estrutura do campo magnético da Terra.



Fonte: Adaptado de McNamara (1991).

Um aspecto central desse processo é a orientação da componente sul do campo magnético interplanetário. Quando essa componente se torna favorável à reconexão magnética, a transferência de energia do vento solar para a magnetosfera é intensificada, desencadeando subtempestades e, em casos mais severos, tempestades geomagnéticas. Tais eventos podem repercutir diretamente sobre a estabilidade ionosférica e sobre o comportamento dos sinais de navegação.

Além dos índices geomagnéticos clássicos, a presente pesquisa também considera parâmetros do meio interplanetário que antecedem ou acompanham essas perturbações. Entre eles destacam-se as componentes do campo magnético interplanetário em sistemas de coordenadas geocêntricas, como GSE e GSM, especialmente a componente B_z , cuja orientação sul favorece o acoplamento entre vento solar e magnetosfera terrestre. Essas variáveis complementam a interpretação física dos índices K_p e AE e justificam sua utilização como atributos do modelo preditivo.


Paralelamente, o campo elétrico interplanetário também constitui um parâmetro relevante, pois expressa a interação entre a velocidade do vento solar e o campo magnético interplanetário, funcionando como indicador da transferência de energia para o sistema magnetosfera-ionosfera. Em conjunto com a pressão dinâmica do vento solar, esse parâmetro oferece uma descrição mais direta das condições físicas que podem anteceder episódios de perturbação ionosférica, justificando sua inclusão entre as variáveis explicativas utilizadas no Capítulo 3.

O campo magnético terrestre pode ser comparado ao de um ímã em forma de barra, apresentando dois polos principais: o Polo Norte Magnético, localizado na região ártica do Canadá, e o Polo Sul Magnético, situado próximo à costa da Antártica, ao sul da Austrália (NRCAN, 2025). Observação importante: trata-se de uma convenção, pois, do ponto de vista físico, o “norte magnético” estaria localizado na região sul e vice-versa. Já os polos geomagnéticos, que são definidos com base em um modelo idealizado do campo magnético, encontram-se aproximadamente nas coordenadas 79° N e 70° O para o norte, e 79° S e 110° L para o sul.

O equador geomagnético é definido como o plano perpendicular ao eixo magnético, de maneira semelhante ao equador geográfico, que é ortogonal ao eixo de rotação da Terra. No entanto, esses dois eixos não coincidem, o que implica que os planos equatoriais também não são coplanares. A inclinação entre os eixos geomagnético e geográfico é de cerca de 11° , a **Figura 5** apresenta um mapa onde o

equador geomagnético derivado do referido modelo é destacado, assumindo-se como época de referência o ano de 2020.

Figura 5- Equador geomagnético no hemisfério Norte no ano de 2020.



Fonte: Adaptado do World Data Center for Geomagnetism Kyoto (2025).


Assim como existem latitudes e longitudes baseadas no equador geográfico, também há um sistema de coordenadas geomagnéticas, que utiliza os polos e o equador definidos pelo campo magnético idealizado (McNAMARA, 1991). É importante destacar que, assim como as coordenadas geográficas, as geomagnéticas também sofrem variações ao longo do tempo.

O campo magnético terrestre desempenha um papel fundamental na variação da densidade de elétrons presentes na atmosfera superior. Na ionosfera e na magnetosfera, ele atua como um regulador do movimento das partículas carregadas,

de modo que qualquer alteração nesse campo pode impactar significativamente o transporte dessas partículas no meio ionizado. As mudanças mais frequentes no campo geomagnético estão associadas às correntes elétricas que circulam nas camadas inferiores da ionosfera. Além dessas variações regulares, também podem ocorrer alterações abruptas e intensas, geralmente desencadeadas por tempestades solares (KIRCHHOFF, 1991).

Durante períodos de maior atividade solar, quando o vento solar se intensifica, ocorrem alterações significativas nas linhas de força do campo magnético terrestre. Essas mudanças impactam diretamente a ionosfera, podendo desencadear tempestades geomagnéticas, que por sua vez resultam em perturbações ionosféricas associadas (KIRCHHOFF, 1991). A **Figura 6** apresenta a influência do vento solar no campo geomagnético.

Figura 6 - Influência do vento solar no campo geomagnético.




Fonte: <https://sci.esa.int/web/cluster/-/36645-solar-wind>. Acesso em 18/05/2025.

As tempestades geomagnéticas podem ser classificadas de acordo com a forma como se manifestam. Existem dois tipos principais: aquelas que têm início súbito e as que se desenvolvem de maneira gradual. As tempestades de início súbito estão relacionadas a explosões solares ou (SDF), enquanto as de início gradual são provocadas por Fluxos de Alta Velocidade (HSS), conforme descrito por McNamara (1991). A **Figura 7** ilustra essas distinções, evidenciando que a principal diferença

entre os dois tipos está na maneira como se inicia a tempestade, especialmente em função da componente horizontal do campo magnético terrestre.

Figura 7- Tempestades com início súbito e gradual.




Fonte: Adaptado de McNamara (1991).

A **Figura 7a** ilustra uma tempestade geomagnética típica de início súbito, geralmente provocada por uma explosão solar ou por (SDF). Já a **Figura 7b** apresenta um exemplo de tempestade com início gradual, associada à atuação de (HSS). Um aspecto marcante desse segundo tipo é sua ocorrência periódica, aproximadamente a cada 27 dias, intervalo que corresponde ao ciclo de rotação do Sol. Por essa razão, as tempestades geradas por HSS também são conhecidas como tempestades recorrentes (McNamara, 1991).

Conforme ilustrado na **Figura 8** uma grande explosão solar pode desencadear três tipos distintos de eventos no espaço interplanetário. Na Figura 8a, observa-se um aumento quase imediato da radiação solar, especialmente na faixa de raios X, que alcança a Terra em cerca de 8 minutos após a explosão. Na Figura 8b, verifica-se que prótons energéticos, por serem partículas rápidas, podem atingir o planeta em um intervalo que varia de alguns minutos a algumas horas. Esses prótons são seguidos por uma nuvem de material ejetado que se desloca mais lentamente, sendo precedida por uma onda de choque que se forma no ponto de encontro entre essa nuvem e o vento solar em condições estáveis. Por fim, a Figura 8c mostra que essa nuvem de ejeção pode alcançar a Terra em poucos dias após o evento solar. É importante ressaltar que ejeções de massa coronal também podem ocorrer independentemente da presença de explosões solares. Informações mais detalhadas sobre as origens interplanetárias das tempestades geomagnéticas podem ser encontradas em Gonzalez et al. (1999).

Figura 8 – Consequências de uma grande explosão solar.



Fonte: Adaptado de McNamara (1991).

As emissões contínuas de plasma em alta velocidade, conhecidas como vento solar, interagem com o campo magnético da Terra, comprimindo-o e moldando-o em uma estrutura alongada no lado oposto ao Sol, que pode se estender por centenas de raios terrestres (FEDRIZZI, 2003). Em essência, eventos solares como explosões solares, fluxos de alta velocidade (HSS) e desaparecimentos súbitos de filamentos (SDF) alteram parâmetros importantes do vento solar, como sua velocidade e densidade. Essas mudanças impactam diretamente o campo geomagnético, desencadeando tempestades geomagnéticas, que, por sua vez, provocam tempestades ionosféricas como resposta a essas perturbações.

As tempestades geomagnéticas mais severas estão frequentemente associadas às ejeções de massa coronal (CMEs), que são grandes bolhas de plasma aquecido, contendo bilhões de toneladas de material solar, impulsionadas pelos campos magnéticos do Sol (FEDRIZZI, 2003). Essas ejeções podem atingir velocidades próximas a 1 milhão de km/h, levando de um a quatro dias para alcançar a Terra (FEDRIZZI, 2003). Em geral, as explosões solares são os principais gatilhos dessas ejeções.


Além das tempestades geomagnéticas, ocorrem também as sub-tempestades, que são eventos transitórios iniciados no lado noturno da Terra. Durante esses episódios, uma quantidade significativa de energia, proveniente da interação entre o vento solar e a magnetosfera, é transferida para a magnetosfera e a ionosfera auroral. Embora sub-tempestades intensas possam acompanhar tempestades geomagnéticas severas, elas também podem ocorrer de forma isolada (FEDRIZZI, 2003). Ambos os fenômenos têm origem em processos físicos que redistribuem a energia do vento solar no sistema magnetosfera-ionosfera (GONZALEZ et al., 1994 apud FEDRIZZI, 2003).

Conforme mencionado, as tempestades geomagnéticas e ionosféricas compartilham as mesmas causas solares: explosões solares, ventos solares de alta velocidade oriundos de buracos coronais e desaparecimentos súbitos de filamentos (McNAMARA, 1991).

Os filamentos, por sua vez, podem ser confundidos com proeminências, pois são essencialmente uma estrutura idêntica observada de ângulos diferentes. Uma proeminência é uma nuvem de gás relativamente frio suspensa acima da superfície solar por campos magnéticos. Quando vista de lado, aparece brilhante e é chamada de proeminência; quando observada de frente, parece escura e é denominada filamento (McNAMARA, 1991).

Esses filamentos podem atingir comprimentos de até 300 milhões de quilômetros e alturas de cerca de 100 mil quilômetros acima da fotosfera. Embora possam permanecer estáveis por meses, também podem entrar em erupção repentinamente, lançando material solar no espaço. Caso esse material atinja a Terra, pode provocar alterações no campo magnético terrestre e, conseqüentemente, na ionosfera. Em resumo, os filamentos são estruturas extensas e relativamente frias da cromosfera solar que, ao desaparecerem de forma abrupta, podem gerar efeitos semelhantes aos das explosões solares, sendo indicativos de elevada atividade solar, conforme mostra **Figura 9**.

Figura 9 – Matéria de uma área desaparecida de filamento.



Fonte: Adaptado de McNamara (1991).

Quando uma onda de choque atinge o campo magnético terrestre, pode desencadear um início súbito, marcando o começo da fase principal de uma tempestade geomagnética. A presença de uma nuvem de filamento composta por plasma e semelhante àquela liberada durante uma explosão solar tem o potencial de gerar uma tempestade geomagnética e, possivelmente, uma tempestade ionosférica subsequente. É importante destacar que a frente de impacto constitui uma característica constante do campo magnético terrestre, resultante da interação contínua com o vento solar. O **Quadro 1** apresenta os fenômenos associados ao desaparecimento súbito de filamentos, assim como o tempo estimado de propagação entre o Sol e a Terra (McNAMARA, 1991).

Quadro 1 - fenômenos associados ao desaparecimento súbito de filamentos.

Fenômeno	Tempo de propagação	Efeitos Terrestres
Onda de impacto	3 - 4 dias	Início súbito (Sudden commencement)
Nuvem de filamento	3 - 10 dias	Tempestade geomagnética Tempestade ionosférica Auroras

Fonte: McNamara (1991).


De modo geral, os efeitos geomagnéticos provocados por explosões solares, fluxos de alta velocidade (HSS) ou ejeções de massa coronal (SDF) tendem a ser mais intensos durante os equinócios do que nos solstícios. Esse mesmo princípio se aplica aos impactos ionosféricos observados nos sistemas GNSS. Como consequência, mesmo eventos solares de baixa intensidade ocorridos próximos aos equinócios podem gerar perturbações geomagnéticas mais significativas do que explosões solares de grande magnitude que acontecem perto dos solstícios (McNamara, 1991).

Portanto, diferentes tipos de eventos solares têm potencial para influenciar o campo geomagnético da Terra. Esses distúrbios são acompanhados por meio de estações terrestres localizadas em observatórios magnéticos, que monitoram continuamente essas variações (Komjathy, 1997).

2.2.4 Amplitude geomagnética

A análise da amplitude geomagnética e das coordenadas associadas ao campo magnético terrestre é particularmente relevante para estudos de cintilação ionosférica, uma vez que a ocorrência do fenômeno depende fortemente da latitude geomagnética. Diferentemente da latitude geográfica, a latitude geomagnética é definida com base na estrutura do campo magnético da Terra, cujos polos e equador não coincidem exatamente com os geográficos. O equador magnético é a linha que divide a superfície terrestre em dois hemisférios magnéticos, e se desloca ao longo do tempo. A **Figura 10** apresenta as mudanças dos polos magnéticos e do equador magnético no hemisfério norte ao longo dos últimos séculos, baseadas em dados do WORLD DATA CENTER FOR GEOMAGNETISM, Kyoto (2025) e de Tauxe et al. (2014).

Figura 10 - Variação dos polos magnéticos e geomagnético no hemisfério Norte.



Fonte: Adaptado do World Data Center for Geomagnetism Kyoto (2025).

As coordenadas geomagnéticas de um ponto na superfície terrestre (ou próximo a ela) podem ser definidas por meio de um sistema de coordenadas geomagnéticas, que utiliza um modelo do campo magnético da Terra para determinar

a posição de um ponto em relação aos polos magnéticos e ao equador magnético. Um sistema de coordenadas geomagnéticas amplamente utilizado na avaliação de fenômenos geofísicos, como as cintilações ionosféricas, é o Corrected GeoMagnetic (CGM). Esse sistema utiliza um modelo do campo magnético da Terra que leva em conta as variações do campo magnético ao longo do tempo, inclusive as variações seculares, que são as mudanças de longo prazo do campo magnético.

Modelos como o DGRF/IGRF e sistemas como o Corrected GeoMagnetic permitem representar com maior rigor essa geometria, sendo amplamente utilizados na avaliação de fenômenos geofísicos. Essa abordagem torna-se especialmente importante em regiões de baixa latitude geomagnética, como o território brasileiro, onde a dinâmica ionosférica apresenta comportamento próprio e maior suscetibilidade a irregularidades associadas à anomalia equatorial.

Assim, a caracterização geomagnética complementa a compreensão da área de estudo ao mostrar que a posição relativa em relação ao equador magnético influencia a frequência e a intensidade dos efeitos ionosféricos sobre os sinais GNSS).

2.3 Conteúdo Total de Elétrons

O Conteúdo Total de Elétrons (TEC) representa a quantidade integrada de elétrons livres ao longo do caminho percorrido pelo sinal entre o satélite e o receptor. Por essa razão, trata-se de um dos parâmetros mais utilizados na caracterização do efeito ionosférico sobre os sistemas GNSS. Como a ionosfera é um meio dispersivo, o atraso imposto ao sinal depende da frequência da portadora e do número de elétrons presentes ao longo da trajetória. O GPS utiliza três frequências de transmissão: L1 (1575,2 MHz), L2 (1227,6 MHz) e L5 (1176,45 MHz). O efeito da ionosfera sobre as ondas de rádio é proporcional ao número de elétrons presentes na ionosfera e inversamente proporcional à frequência das ondas de rádio (DAL POZ, 2010). Para o GPS, que opera na frequência L1 (1575,2 MHz), a ionosfera pode causar um atraso nas ondas de rádio de até 300 ns no pior caso, resultando em um erro de 100 metros na distância medida entre o satélite e o receptor (KLOBUCHAR, 1993). Esse atraso afeta tanto o código quanto a fase das ondas de rádio, aumentando o comprimento aparente do caminho para o código e diminuindo o comprimento aparente do caminho para a fase (LEICK, 2004; DAL POZ, 2010).

Um parâmetro importante para estimar o atraso ionosférico nas ondas de rádio é o conteúdo total de elétrons (TEC), que é uma medida da densidade de coluna de

elétrons na ionosfera. O TEC representa o número de elétrons em uma coluna de seção transversal de 1 metro quadrado que se estende ao longo do caminho entre o satélite e o receptor. O TEC depende de diversas variáveis, como os parâmetros de atividade solar, o índice geomagnético, a estação do ano, a localização geográfica e a hora do dia. O TEC é geralmente expresso em unidades TEC (TECU), sendo que 1 TECU equivale a 10^{16} elétrons/m² (KLOBUCHAR, 1993; MARQUES, 2012).

Os valores médios do TEC e do atraso ionosférico variam ao longo do globo terrestre, sendo mais significativos em uma região em torno de 15° ao norte e ao sul do equador magnético. O equador magnético é a linha que divide a superfície terrestre em dois hemisférios magnéticos e se desloca ao longo do tempo devido às variações do campo magnético da Terra. Para satélites com ângulo de elevação mínimo projetado para o GPS (5°), o atraso ionosférico é aproximadamente três vezes maior em relação aos satélites no zênite (KLOBUCHAR, 1993). Para usuários que não dispõem de receptores de dupla ou de multi-frequência, que podem realizar diferenciações para diminuir os efeitos da ionosfera, para atenuar o efeito do atraso ionosférico no sinal GPS. Esse modelo utiliza oito coeficientes que são transmitidos como parte das mensagens de navegação GPS e proporciona uma correção de aproximadamente 50% em relação ao erro médio quadrático devido à ionosfera nas distâncias satélite-receptor que são medidas.

Uma forma de reduzir a influência da ionosfera nos sinais de rádio do GPS é utilizar frequências múltiplas, que permitem calcular a diferença entre os observáveis em frequências diferentes. Os observáveis são as quantidades medidas pelos receptores de GPS, como o código e a fase das ondas de rádio. A diferença entre os observáveis em frequências diferentes permite estimar e corrigir o atraso ionosférico nos sinais de rádio. A frequência L1 é a mais antiga e a mais utilizada, e contém os sinais de código C/A (Coarse/Acquisition) e P (Precise). A frequência L2 contém apenas o sinal de código P e não é utilizada para a aviação, pois não está dentro de uma faixa protegida. A frequência L5 é a mais recente e a mais moderna, e contém os sinais de código C (Civil) e M (Military). A combinação linear das três frequências permite eliminar ou reduzir os efeitos da ionosfera, da troposfera e dos erros orbitais nos sinais de rádio do GPS (POLEZEL, 2010).

Nesta dissertação, o TEC é considerado como variável explicativa do modelo preditivo, por representar o estado integrado da ionosfera ao longo do trajeto do sinal.

Seu uso se justifica pela relação direta com a variabilidade ionosférica e pela relevância na interpretação das perturbações que afetam a propagação GNSS.

2.3.1 Pseudodistância GNSS e sensibilidade aos efeitos ionosféricos

A pseudodistância corresponde à estimativa da distância entre satélite e receptor obtida a partir do tempo de propagação do sinal. Embora seja um observável fundamental para o posicionamento GNSS, seu valor é influenciado por múltiplos fatores, incluindo erros orbitais, de relógio, troposféricos, ionosféricos e instrumentais. Em razão disso, a pseudodistância não deve ser interpretada como medida puramente geométrica, mas como um observável sujeito a perturbações do meio de propagação.

A ionosfera exerce influência particularmente relevante sobre esse observável, uma vez que o atraso ionosférico afeta de maneira distinta as diferentes frequências transmitidas pelos satélites. Assim, as pseudodistâncias medidas em L1 e L2 apresentam sensibilidades diferentes aos efeitos dispersivos da ionosfera, o que justifica o uso combinado dessas frequências em procedimentos de correção e análise. Em condições ionosféricas perturbadas, variações rápidas no meio podem produzir instabilidades observacionais, degradando a qualidade das pseudodistâncias e, por consequência, a acurácia do posicionamento.

No presente estudo, a variação temporal da pseudodistância L1 é adotada como proxy da degradação do sinal GNSS associada às condições ionosféricas, enquanto observações relacionadas a L1 e L2 são utilizadas na engenharia de atributos temporais. Essa escolha metodológica decorre do fato de que o modelo não utiliza diretamente os índices S4 e Sigma-Phi como variável-resposta, optando por uma abordagem indireta, baseada em um observável GNSS efetivamente medido em campo. Tal estratégia permite aproximar a modelagem do comportamento real do sistema em operação, preservando aderência à base observacional empregada.

2.4 Cintilação Ionosférica


A cintilação ionosférica é um fenômeno caracterizado por variações rápidas e aleatórias na amplitude e/ou na fase dos sinais de rádio que atravessam a ionosfera. Essas flutuações são causadas por irregularidades na densidade eletrônica do plasma ionosférico, frequentemente associadas a bolhas ionosféricas e a estruturas de diferentes escalas espaciais. Essas variações são causadas pela presença de irregularidades na densidade do plasma ionosférico, conhecidas como bolhas

ionosféricas, que são regiões de rarefação do plasma. As bolhas ionosféricas podem ter diferentes dimensões e velocidades, provocando atenuações na amplitude e fase dos sinais de rádio do GNSS, comprometendo a qualidade e precisão do posicionamento (CONKER et al., 2003; SKONE et al., 2005).

As bolhas ionosféricas podem ter diferentes dimensões e velocidades, provocando atenuações na amplitude e fase dos sinais de rádio do GNSS, comprometendo a qualidade e precisão do posicionamento (CONKER et al., 2003; SKONE et al., 2005).

As bolhas ionosféricas são mais frequentes e intensas na região equatorial, onde ocorre a anomalia equatorial, um fenômeno que consiste no aumento da densidade eletrônica na ionosfera em latitudes próximas a 15° ao norte e ao sul do equador magnético, como mostra a **Figura 11**. As bolhas ionosféricas se formam na anomalia equatorial e se propagam para latitudes mais altas, seguindo o sentido Leste-Oeste. Essas bolhas podem ter uma extensão de cerca de 80 km no sentido Leste-Oeste e uma altura total de cerca de 1000 km, deslocando-se a velocidades que variam de 50 a 150 m/s, formando manchas irregulares na ionosfera. As bolhas ionosféricas contêm irregularidades de grande e pequena escala, sendo as de pequena escala (cerca de 100 m) responsáveis pela cintilação ionosférica. No território brasileiro, essas ocorrências são mais intensas entre os meses de outubro e março, apresentando uma redução gradual em sua frequência até atingirem um mínimo por volta de junho ou julho. Em alguns casos, essas irregularidades aparecem de forma intermitente à medida que os sinais dos satélites se propagam através delas (REZENDE et al., 2007; WALTER et al., 2010).

Figura 11 - Comportamento temporal e espacial das irregularidades ionosféricas.




Fonte: <<https://brazilianspace.blogspot.com/2010/05/experimentos-ionosfericos-ocorrem-no.html>>. Acessado em: jan. 10, 2025.

Nos sistemas GNSS, esse fenômeno pode comprometer a qualidade do rastreamento e das observações, reduzindo a confiabilidade do posicionamento, especialmente em aplicações que requerem elevada precisão. Dependendo da intensidade da perturbação, a cintilação pode provocar atenuação do sinal, flutuação de fase, aumento do erro de medida e até perda de bloqueio do satélite. Dessa forma, trata-se de um dos processos ionosféricos mais relevantes para a navegação por satélite em regiões suscetíveis a irregularidades.

A cintilação ionosférica pode afetar diferentes satélites do GNSS em um determinado momento, dependendo da posição e trajetória dos satélites e das bolhas ionosféricas. A **Figura 12** mostra um gráfico que compara a intensidade da cintilação ionosférica em diferentes satélites do GNSS em uma determinada estação observatória. Nesse gráfico, é possível observar que alguns satélites são mais afetados do que outros pela cintilação ionosférica. Anomalias de grande escala, como a que afeta o Satélite 1, podem fazer com que o satélite perca o contato de rastreamento com o receptor. Anomalias de pequena escala, como as que afetam o Satélite 6, podem comprometer a integridade do sinal, levando a erros de medição na distância entre o satélite e o receptor. Em situações extremas, a disponibilidade dos

serviços de posicionamento pode ser comprometida na ausência de satélites (CONKER et al., 2003). Além disso, a ocorrência de cintilações repetidas e variações significativas na densidade eletrônica podem resultar em perda de sincronização em receptores de frequência única e dupla (DATTA-BARUA et al., 2003). No contexto do GPS, que é um dos componentes do GNSS, também foi identificada a perda de sincronização na nova frequência de transmissão (L5), uma das três frequências utilizadas pelo sistema para mitigar os efeitos da ionosfera (POLEZEL, 2010).

Figura 12 - Esquematisação da cintilação nos sinais GNSS.




Fonte: Adaptado de Walter et al. (2010).

Esses índices têm comportamentos específicos e podem ser correlacionados de região para região. Assim como o TEC, os índices de cintilação variam de acordo com a frequência do sinal, a localização geográfica, a hora local, a estação do ano, a atividade magnética e o ciclo solar.

A cintilação ionosférica é mais significativa em uma região próxima de 10° a 20° do equador magnético, onde ocorre a anomalia equatorial. Os efeitos da cintilação ionosférica são mais pronunciados em todas as regiões durante os períodos de maior atividade solar, com a maior parte da cintilação ocorrendo algumas horas após o pôr do sol, no pico do ciclo solar. Durante os períodos de menor atividade solar, espera-se o mesmo comportamento, mas com menor intensidade. A **Figura 13** mostra a frequência da cintilação ionosférica em função da localização geográfica global.


Figura 13 - Frequência de ocorrência de cintilação de acordo com a localização geográfica.



Fonte: Adaptado de Kintner Jr., Humphreys e Hinks (2009).

Nessas áreas, a ionosfera é caracterizada pela interação entre o campo magnético da Terra, o vento solar e o campo magnético interplanetário. À noite, nas regiões polares, partículas de alta energia presas nas linhas do campo magnético terrestre são depositadas, formando anéis de intensa atividade iônica que causam luminescência. Esse anel é chamado de oval auroral. A **Figura 14** mostra o diagrama do ciclo da cintilação ionosférica na América do Norte. Em altas latitudes, como no Canadá, esses efeitos persistem mesmo durante períodos de baixa atividade solar, pois a cintilação está associada a auroras intensas (SKONE et al., 2005; WALTER et al., 2010). Nessas regiões, a fotoionização é mais fraca do que nos trópicos, tornando a cintilação de amplitude menos significativa. No entanto, as irregularidades evoluem dez vezes mais rápido, podendo causar cintilação de fase significativa (WALTER et al., 2010).

Figura 14 - Oval auroral sobre a América do Norte.



Fonte: Skone e Hoyle (2005).

A cintilação ionosférica varia conforme a localização geográfica, e menos significativa em latitudes médias, como nos Estados Unidos. No entanto, durante tempestades geomagnéticas, que são perturbações do campo magnético da Terra causadas pela interação com o vento solar e o campo magnético interplanetário, a ionosfera nessas regiões pode ser perturbada, resultando em cintilações nos sinais de rádio do GNSS. Durante essas tempestades, o elipsoide original, que é uma superfície que delimita a região de maior densidade eletrônica na ionosfera, se expande em direção ao equador, trazendo o efeito de cintilação ionosférica das regiões equatoriais para as latitudes médias (CONKER et al., 2003; WALTER et al., 2010).

2.5 Estimativas da cintilação ionosférica

A estimação da cintilação ionosférica pode ser realizada por diferentes abordagens. Entre elas, destacam-se a densidade espectral de potência do sinal e os índices específicos desenvolvidos para quantificar as flutuações de amplitude e fase. Esses indicadores permitem representar a intensidade do fenômeno e comparar seu comportamento em diferentes contextos geográficos e temporais.

Embora tais métricas sejam amplamente utilizadas na literatura, sua interpretação requer cautela, uma vez que fatores como ruído, multicaminho e características instrumentais podem interferir nas medições. Ainda assim, os índices de cintilação continuam sendo referências centrais na caracterização do fenômeno e na comparação entre estudos.

No presente trabalho, essas estimativas são tratadas como base conceitual para a compreensão da cintilação ionosférica. Contudo, a modelagem desenvolvida nesta dissertação adota uma variável observacional indireta como proxy da degradação do sinal, em vez de utilizar diretamente esses índices como variável-alvo.

2.5.1 Cintilação de Amplitude e Índice S4

A cintilação de amplitude decorre, principalmente, da difração do sinal de rádio causada por irregularidades na densidade do plasma ionosférico. Esse processo provoca flutuações rápidas na intensidade do sinal recebido, podendo comprometer o rastreamento e a qualidade das observações GNSS.

Esses índices podem ser calculados a partir da densidade espectral de potência do sinal (PSD) (CONKER et al., 2003).

A cintilação de amplitude é causada pela difração do sinal de rádio pelas irregularidades na densidade eletrônica do plasma ionosférico. A difração ocorre quando uma onda de rádio encontra um obstáculo ou uma abertura com dimensões comparáveis ao seu comprimento de onda, fazendo com que a onda se desvie da sua trajetória original e se espalhe em diferentes direções. Esse fenômeno causa rápidas flutuações na intensidade do sinal de rádio, percebidas como cintilação de amplitude. Em alguns casos, ela pode ser forte o suficiente para que a intensidade do sinal de rádio recebido. Esse aspecto prejudica o processo de desambiguação na fase do portador, um método para determinar a distância entre o satélite e o receptor com maior precisão (DATTA-BARUA et al., 2003; WALTER et al., 2010).

O índice S4 é adimensional e alguns valores limites podem ser encontrados na literatura. Datta Barua et al. (2003) e Conker et al. (2003) definiram um valor de 0 para representar nenhuma cintilação e um valor de 1 para representar cintilação grave.

Hegarty et al. (2001) definem o limite superior do índice S4 como $1,414 (\sqrt{2})$. Tiwari et al. (2011), apresenta três níveis para classificar este indicador:

- Cintilação fraca: $S4 \leq 0,5$;
- Cintilação moderado: $0,5 \leq S4 < 1$;
- Cintilação alto: $S4 \geq 1$.


Hegarty et al. (2001) apresenta quatro níveis de classificação:

- Cintilação muito fraca: $0,1 \leq S4 < 0,4$;
- Cintilação fraca: $0,4 \leq S4 < 0,6$;
- Cintilação moderada: $0,6 \leq S4 < 0,9$;
- Cintilação forte: $S4 \geq 0,9$.

Em geral, os receptores podem fornecer valores superiores aos limites teóricos do índice S4. Por exemplo, o efeito do multicaminho pode aumentar o índice S4, indicando falsamente a incidência de cintilação ionosférica (DATTA-BARUA et al., 2003). Esse efeito ocorre principalmente no início ou no final do rastreamento de um satélite, caracterizado por baixos ângulos de elevação e, conseqüentemente, maior susceptibilidade ao efeito de multicaminho (WALTER et al., 2010). Portanto, em estações monitoras de cintilação, é essencial que se tenha um nível de multicaminho bem controlado; técnicas de remoção ou redução dos efeitos do multicaminho também podem ser adotadas, como a utilização do desvio-padrão da divergência código/fase (code-carrier divergence – σ_{ccd}) (VAN DIERENDONCK; KLOBUCHAR; HUA, 1993).

A **Figura 15** apresenta uma representação global do índice S4 para o dia 15 de setembro de 2002 às 21h local em qualquer lugar do planeta, obtida a partir do modelo WBMOD (definido na Subseção 2.7.1). Nesse dia, quando a atividade solar estava no auge, nenhuma erupção solar foi registrada. Essa notação é usada porque as cintilações mais significativas ocorrem após o pôr do sol. As áreas mais afetadas podem ser observadas ao redor do equador magnético, em altas latitudes e nas regiões aurorais (CONKER et al., 2003).

Figura 15 - Distribuição global do índice S4 em 15 de setembro de 2000 às 21h local.



Fonte: Conker et al. (2003).

Em síntese, o índice S4 depende da potência do sinal recebido e da atenuação de outros ruídos. A potência do sinal é a intensidade do sinal corrigida pela potência recebida medida, de forma que seu valor não flutue com a intensidade do ruído. Portanto, o índice S4 não pode ser baseado na relação sinal-ruído, e para determiná-lo é necessário remover o ruído ambiental (VAN DIERENDONCK; KLOBUCHAR; HUA, 1993).

Datta-Barua et al. (2003) descrevem as etapas para determinar o índice S4 em um receptor de monitoramento de cintilação chamado GPS Monitor de Cintilação de Íons do Vale do Silício (ISM). Primeiro, a variação da intensidade do sinal é normalizada pelo quadrado da intensidade média do sinal de 1 minuto para obter o índice S4_T:

$$S_{4T} = \sqrt{\frac{(SI^2) - (SI)^2}{(SI)^2}} \quad (2.1)$$

Onde:

- S_I é a intensidade do sinal amostrada a uma taxa de 50 Hz, esperado no intervalo de um minuto;
- S4_T é o índice “S4 total”, o qual inclui as flutuações de amplitude de qualquer causa (ou seja, abrange os ruídos);

Em seguida, é necessário remover o valor de S_4 proveniente de ruídos, resultando em um índice S_4 com valor teórico não superior a 1 (DATTA-BARUA et al., 2003; VAN DIERENDONCK; KLOBUCHAR; HUA, 1993):

$$s_4 = \sqrt{S_{4T}^2 - S_{4N}^2} \quad (2.2)$$

Onde:

- S_{4N} é o índice referente às flutuações de amplitude devido a ruídos do ambiente, o qual é obtido por meio da estimativa da densidade média da relação sinal-ruído ao longo do intervalo de 1 minuto;
- S_4 é o índice de cintilação de amplitude, adimensional.

O intervalo de integração de 1 minuto para o cálculo do índice S_4 é amplamente utilizado por razões práticas e de padronização, visando compatibilidade com receptores GNSS, redução do ruído estatístico e comparabilidade entre estudos. Por outro lado, o índice Sigma-Phi, que será abordado na próxima subseção, pode ser obtido em diferentes intervalos de tempo. Uma vez determinado o índice S_4 na frequência L1, o índice correspondente pode ser atribuído às frequências L2 e L5 utilizando a seguinte relação (HEGARTY et al., 2001; PENG et al., 2011):

$$S_4(L2) = S_4(L1) \left(\frac{f_1}{f_2} \right)^{1,5} = 1,454 \cdot S_4(L1) \quad (2.3)$$

$$S_4(L5) = S_4(L1) \left(\frac{f_1}{f_5} \right)^{1,5} = 1,550 \cdot S_4(L1) \quad (2.4)$$

Apesar de sua relevância, o índice S_4 não foi utilizado diretamente como variável-resposta nesta dissertação. Seu papel, neste trabalho, é oferecer base conceitual para a interpretação da cintilação de amplitude e de seus possíveis efeitos sobre os observáveis GNSS empregados na modelagem.

2.5.2 Cintilações de Fase e índice Sigma-Phi

A cintilação de fase é um fenômeno que ocorre quando o sinal de rádio que se propaga pela ionosfera sofre rápidas variações de fase devido às irregularidades na densidade do plasma ionosférico. Esse fenômeno pode afetar o rastreamento do sinal de satélite pelo receptor GNSS, causando perda de período e perda de sintonia

(DATTA-BARUA et al., 2003; WALTER et al., 2010). A cintilação de fase é mais intensa em altas latitudes, onde as irregularidades na densidade eletrônica são geradas por subtempestades aurorais, que se estendem a altitudes de cerca de 100–300 km (TIWARI et al., 2011).

Para quantificar a cintilação de fase, utiliza-se um índice chamado Sigma-Phi, também conhecido como Sigma-delta-Pfi (σ ou $\sigma\phi$). Esse índice é calculado pelo desvio padrão das observações prejudicadas das fases do sinal, coletadas em altas frequências (ex. 50 Hz) durante intervalos de 60 segundos (DATTA-BARUA et al., 2003). O Sigma-Phi também pode ser calculado com intervalos de 1, 3, 10 ou 30 segundos, fazendo-se uma média aritmética sobre 60 segundos (VAN DIERENDONCK; KLOBUCHAR; HUA, 1993). A eq. 2.5 apresenta o cálculo do Sigma Phi:

$$\sigma_{\phi} = \sqrt{(\phi)^2 - (\phi^2)} \quad (2.5)$$

O índice Sigma-Phi pode variar de 0.05 para cintilações baixas, chegando a 1 em altas cintilações (SKONE et al., 2005). Diferentemente do índice S4, que é adimensional, o índice Sigma-Phi é dado em radianos. Tiwari et al. (2011) apresentam a seguinte classificação:

- Cintilação forte: $\sigma\phi \geq 0,8$ rad;
- Cintilação moderada: $0,4 \leq \sigma\phi \leq 0,8$ rad;
- Cintilação fraca: $\sigma\phi \leq 0,4$ rad.

Hegarty et al. (2001) apresentam quatro níveis para o índice Sigma-Phi, que também são definidos para a frequência L1:

- Cintilação forte: $\sigma\phi \geq 0,6$ rad;
- Cintilação moderada: $0,3 \leq \sigma\phi < 0,6$ rad;
- Cintilação fraca: $0,2 \leq \sigma\phi < 0,3$ rad;
- Cintilação muito fraca: $0,05 \leq \sigma\phi < 0,2$ rad.

Uma vez definido o índice Sigma-Phi na frequência L1, o índice correspondente pode ser mapeado para as frequências L2 e L5 utilizando as seguintes relações (HEGARTY et al., 2001; PENG et al., 2011):

$$\sigma_{\varphi}(L2)=\sigma_{\varphi}(L1) \left(\frac{f_1}{f_2} \right) = 1,283 \cdot \sigma_{\varphi}(L1) \quad (2.6)$$

$$\sigma_{\varphi}(L5)=\sigma_{\varphi}(L1) \left(\frac{f_1}{f_5} \right) = 1,339 \cdot \sigma_{\varphi}(L1) \quad (2.7)$$

Assim como ocorre com o S4, o Sigma-Phi é tratado nesta dissertação como referência conceitual para a caracterização do fenômeno, e não como variável-resposta da modelagem. Embora os índices S4 e Sigma-Phi constituam referências clássicas para a quantificação da cintilação ionosférica, a abordagem proposta neste estudo utiliza a variação da pseudodistância L1 como proxy da degradação do sinal GNSS em condições ionosféricas perturbadas.

2.6 Influência da Cintilação Ionosférica no Posicionamento GNSS

Para caracterizar os efeitos da cintilação ionosférica no posicionamento, é necessário analisar diversos parâmetros, pois esse efeito varia de acordo com a localização geográfica, atividade solar, sazonalidade, entre outros fatores. Walter et al. (2010) enfatizam que o mais importante é o desempenho do sistema em condições não perturbadas e a intensidade da cintilação, ou seja, o quanto os sinais são afetados. Em geral, a cintilação ionosférica degrada o posicionamento, porque causa interferência no sinal. Além disso, os sinais das estações base também são afetados, diminuindo a qualidade e quantidade das observações dessas estações. Se a cintilação prejudica a recepção da informação ou degrada os dados, a infraestrutura de suporte online tem menos observações do que o usuário de um receptor simples, aumentando os erros (WALTER et al., 2010).

Os efeitos da cintilação ionosférica impedem que o GNSS seja a única opção de posicionamento em aplicações onde a segurança é crucial, como na navegação aérea. Nesse caso, além da necessidade de encontrar formas de mitigar os efeitos da cintilação ionosférica, é importante garantir a integridade do serviço de posicionamento. Nesse contexto, pode-se explorar o conceito de Monitoramento de Integridade Autônoma do Receptor (RAIM), que visa detectar erros e fornecer avisos ao usuário quando a integridade for comprometida (PRASAD, R; RUGGIERI, M, 2005).

A cintilação ionosférica pode causar perda de ciclo e perda de sincronização quando o receptor recebe sinais de satélite, impactando diretamente processos livres de ruído (WALTER et al., 2010).

Como pode ser visto na **Figura 12** Erro! Fonte de referência não encontrada. (apresentada na Seção 2), as irregularidades ionosféricas podem afetar os satélites observados pelo receptor de diferentes maneiras. Uma possível estratégia para mitigar o efeito da cintilação no posicionamento GNSS é descartar as observações mais afetadas. Em um cenário com vários satélites disponíveis (boa redundância de observações), mas apenas um satélite afetado pela cintilação, o posicionamento do usuário pode não ser significativamente prejudicado. No entanto, em um cenário oposto, com baixa cobertura de satélites e sem redundância de observações.

Nas redes GNSS - tanto estações terrestres como sistemas auxiliares - se a cintilação afetar apenas alguns satélites de estações individuais, o impacto no desempenho do usuário será provavelmente pequeno e limitado. Em casos extremos, quando muitas estações sofrem com cintilação severa, esse efeito pode se refletir em maior extensão em toda a rede (WALTER et al., 2010).

Para reduzir os efeitos da cintilação ionosférica no posicionamento, é necessário considerar diversos aspectos, como a cobertura dos satélites, a frequência dos sinais, a integridade dos dados e o tipo de receptor. Nesta seção, serão discutidos alguns desses aspectos, com base na literatura existente.

Um dos fatores que influencia a cintilação ionosférica é o número de satélites disponíveis para o usuário. Quanto maior for a cobertura dos satélites, maior será a possibilidade de garantir eficiência durante eventos de cintilação, uma vez que sinais degradados podem ser tolerados ou descartados. Além disso, a cintilação ionosférica pode comprometer o desempenho das redes GNSS e das estações de monitoramento em solo utilizadas como sistemas auxiliares, afetando diretamente a integridade, a disponibilidade e a densidade das observações fornecidas ao usuário final (WALTER et al., 2010).

Outro fator que influencia a mitigação da cintilação ionosférica é a frequência dos sinais. A cintilação ionosférica afeta de forma diferente as frequências L1, L2 e L5, sendo que a frequência L2 é mais sensível à cintilação de fase do que a frequência L1. Contudo, em alguns casos, a cintilação de amplitude na frequência L1 pode ser mais importante. Como a cintilação de fase baixa é mais comum que a cintilação de alta amplitude, a perda de dados em L2 é maior do que em L1. Como já mencionado,

a perda de dados devido à cintilação degrada a modelagem, como pseudodistância com suavização de fase e outras combinações lineares que podem ser realizadas com receptores multifrequenciais. Com a nova frequência de transmissão do GPS (L5), essa vulnerabilidade foi reduzida devido, entre outros fatores, à maior potência do sinal e à menor sensibilidade à cintilação. No entanto, fortes oscilações de fase e amplitude também são importantes nessa frequência (WALTER et al., 2010). Em geral, enfatiza-se que as oscilações de amplitude e fase estão bem correlacionadas, e os efeitos são menos significativos na frequência L1 do que nas frequências L2 e L5 (PENG et al., 2011).

No contexto da mineração de precisão, em que o posicionamento GNSS subsidia rotinas de controle geométrico e operação de lavra, a degradação do sinal pode impactar diretamente a qualidade técnica das atividades executadas. Por essa razão, a investigação de seus efeitos ultrapassa o interesse puramente teórico e se insere em uma perspectiva aplicada de monitoramento e apoio à decisão.

2.6.1 Detecção e Correção de Erros nas Mensagens de Navegação

Outro fator que influencia na redução da cintilação ionosférica é a integridade dos dados. O GPS possui bits de paridade que permitem a detecção de erros nas mensagens transmitidas pelos satélites. As mensagens duram 18 segundos e têm velocidade de 50 bits por segundo. Elas são transmitidas por satélite a cada 30 segundos e atualizadas a cada 2 horas. Testes com bits de paridade ou testes de comparação de retransmissão devem ser realizados para identificar a correta decodificação da nova mensagem. Se for detectado um erro de decodificação, o referido satélite pode ser descartado até que as mensagens sejam corretamente decodificadas, ou seja, novos dados devem ser obtidos ou mensagens de navegação anteriores devem ser utilizadas (WALTER et al., 2010). Sistemas adicionais – como os satélites SBAS – enviam mensagens que contêm informações mais detalhadas, como informações sobre a integridade de todos os satélites disponíveis. Portanto, esse tipo de sistema deve possuir métodos robustos de detecção de erros para garantir que os dados sejam decodificados corretamente. A utilização de satélites redundantes também é vista como uma alternativa, pois nesse caso a perda ocorre apenas quando a cintilação afeta todos os satélites (WALTER et al., 2010).

Finalmente, outro aspecto relevante que influencia a mitigação da cintilação ionosférica é o tipo de receptor. É importante que o usuário tenha receptores de

múltiplas frequências para modelar adequadamente os vários efeitos observados no caminho do sinal até o receptor, exceto para linhas de base muito curtas (cerca de 1 a 5 km). Os receptores de múltiplas frequências permitem realizar combinações lineares que eliminam ou reduzem os erros causados pela ionosfera, como o efeito de refração. Além disso, os receptores de múltiplas frequências podem utilizar técnicas de mitigação da cintilação, como o Monitoramento de Integridade Autônoma do Receptor (RAIM), que visa detectar erros e fornecer avisos ao usuário quando a integridade for comprometida (PRASAD, R; RUGGIERI, M, 2005).

No âmbito desta pesquisa, a relevância dessas técnicas está associada não apenas à correção do posicionamento, mas também à compreensão do comportamento dos observáveis GNSS utilizados na construção da variável-resposta e dos atributos temporais do modelo.

2.7 Métodos preditivos

A previsão de fenômenos ionosféricos representa um desafio relevante em razão de sua natureza dinâmica, multifatorial e fortemente dependente de condições externas. Modelos físicos e empíricos têm sido empregados com esse propósito, mas frequentemente enfrentam limitações associadas à necessidade de grandes volumes de dados, à complexidade computacional e à dificuldade em capturar padrões locais e temporais em tempo hábil para aplicações práticas. Os métodos tradicionais, fundamentados em modelos físicos baseados em equações diferenciais que descrevem a dinâmica da ionosfera, enfrentam limitações devido à complexidade dos fenômenos envolvidos e à alta variabilidade espacial e temporal do plasma ionosférico (SMITH et al., 2019).

Como alternativa a essas limitações, as abordagens de redes neurais artificiais e modelos estatísticos de regressão têm se mostrado mais eficazes na antecipação de padrões de cintilação. De acordo com Brown et al. (2020), modelos que utilizam redes neurais convolucionais alcançaram até 80% de precisão na previsão da ocorrência de cintilação, utilizando dados históricos relacionados à atividade solar e geomagnética.

Além disso, a utilização de dados GNSS em tempo real, juntamente com informações obtidas por ionossondas, tem contribuído para o aprimoramento das previsões de curto prazo, ao fornecer dados contínuos sobre a dinâmica do plasma ionosférico. Pesquisas apontam que a combinação de diferentes fontes de dados,

aliada a técnicas de seleção de atributos, pode elevar significativamente a precisão dos modelos preditivos (LEE et al., 2022).

Apesar dos avanços, ainda existem obstáculos na aplicação prática dessas metodologias, como a necessidade de ajustes constantes nos algoritmos para garantir um desempenho otimizado em diferentes cenários ionosféricos. A adaptação contínua dos modelos, considerando variações sazonais e regionais, é crucial para assegurar previsões confiáveis e úteis em contextos operacionais (GARCIA et al., 2021). Ainda assim, o desenvolvimento dessas tecnologias permanece como uma área promissora, especialmente para aplicações em comunicações e navegação por satélite em regiões com alta incidência de cintilação, como o território brasileiro.

Na presente dissertação, os métodos preditivos são empregados com foco em regressão supervisionada, buscando modelar uma variável observacional contínua associada à degradação do sinal GNSS a partir da integração entre dados rastreados e parâmetros geofísicos.

2.7.1 Aprendizado de máquina para predição

Técnicas de aprendizado de máquina têm sido amplamente exploradas em problemas de previsão envolvendo sistemas complexos, especialmente quando há grande volume de dados, múltiplas variáveis explicativas e relações não lineares. Em comparação com abordagens estritamente físicas, esses métodos oferecem maior flexibilidade para capturar padrões implícitos nos dados, inclusive em contextos nos quais a formulação do fenômeno é incompleta ou operacionalmente difícil de aplicar.

No caso da cintilação ionosférica e da degradação do sinal GNSS, essa característica é particularmente importante, pois a variabilidade do fenômeno depende da interação entre fatores solares, geomagnéticos, ionosféricos e observacionais. Nesse sentido, o aprendizado de máquina não substitui a compreensão física do problema, mas constitui uma ferramenta complementar para representar empiricamente seu comportamento.

Nesta pesquisa, o aprendizado de máquina é aplicado sob a perspectiva de regressão supervisionada, com o propósito de modelar a variação de um observável GNSS associado à degradação do sinal, utilizando como entrada atributos temporais, geofísicos e ambientais.

2.7.2 Algoritmos de aprendizagem

A escolha do algoritmo de aprendizado de máquina deve considerar a natureza do problema, o tipo de variável-resposta, a heterogeneidade dos dados e o grau esperado de não linearidade entre atributos e saída. Em problemas envolvendo múltiplas variáveis explicativas e possíveis interações complexas, métodos baseados em árvores costumam apresentar bom desempenho por sua flexibilidade e capacidade de capturar relações não lineares sem impor pressupostos rígidos de distribuição.

Considerando essas características, esta dissertação adota dois algoritmos amplamente reconhecidos na literatura aplicada: o Random Forest e o XGBoost. Ambos pertencem à família dos métodos baseados em árvores, porém utilizam estratégias distintas de aprendizado, o que torna sua comparação metodologicamente relevante.

2.7.2.1 Random Forest (RF)

O Random Forest é um algoritmo de aprendizado supervisionado pertencente à classe dos métodos de ensemble, no qual múltiplas árvores de decisão são construídas a partir de subconjuntos amostrais obtidos por reamostragem com reposição (bootstrap). Em problemas de regressão, a predição final corresponde à média das saídas produzidas pelas árvores individuais; em problemas de classificação, o resultado é obtido pelo voto majoritário.

A lógica do método baseia-se na combinação de múltiplos estimadores relativamente independentes, reduzindo a variância do modelo final e aumentando sua estabilidade preditiva. Além da amostragem bootstrap, a diversidade entre as árvores é favorecida pela seleção aleatória de subconjuntos de variáveis em cada divisão interna, o que contribui para diminuir a correlação entre os estimadores e melhorar a capacidade de generalização do conjunto.

Entre suas principais vantagens destacam-se a habilidade de lidar com relações não lineares, a robustez diante de atributos heterogêneos e a possibilidade de estimar a importância relativa das variáveis explicativas. No contexto desta dissertação, o Random Forest mostra-se especialmente adequado por sua capacidade de capturar interações complexas entre observáveis GNSS, variáveis geofísicas e atributos temporais, além de oferecer suporte interpretativo por meio da

análise da relevância dos atributos. A escolha por avaliar modelos adicionais, além do Random Forest, surgiu da necessidade de investigar se técnicas mais recentes poderiam proporcionar melhorias na previsão da cintilação ionosférica (LEE; PARK, 2021).

O Random Forest é um modelo de ensemble baseado na média (para regressão) ou no voto majoritário (para classificação) de múltiplas árvores de decisão construídas com amostragem bootstrap e subconjunto aleatório de variáveis, conforme a equação 2.8.

$$\hat{y}(x) = \frac{1}{T} \sum_{t=0}^T h_t(x) \quad (2.8)$$

Onde:

- T = número de árvores na floresta;
- $h_t(x)$ = predição da árvore t para a entrada (x) ;
- $\hat{y}(x)$ = predição final do Random Forest.

2.7.2.2 Extreme Gradient Boosting (XGBoost)

O XGBoost (Extreme Gradient Boosting) é um algoritmo de aprendizado supervisionado baseado em gradient boosting de árvores de decisão. Diferentemente de métodos baseados em bagging, nos quais os estimadores são treinados de forma paralela e independente, o XGBoost constrói suas árvores sequencialmente, de modo que cada nova iteração busca corrigir os erros residuais produzidos pelo conjunto anteriormente ajustado.

Essa estrutura aditiva permite elevada flexibilidade para representar padrões complexos e relações não lineares. Um de seus principais diferenciais reside na incorporação explícita de regularização, o que favorece o controle da complexidade do modelo e contribui para reduzir o risco de sobreajuste. Além disso, o algoritmo apresenta vantagens computacionais relevantes, como paralelização e eficiência em bases de dados de maior porte.

No âmbito desta pesquisa, a inclusão do XGBoost permite comparar duas estratégias distintas de modelagem baseadas em árvores: enquanto o Random Forest tende a reduzir a variância por meio da agregação de árvores independentes, o XGBoost busca refinar o ajuste por correção sequencial dos erros residuais. Essa

diferença torna a comparação entre ambos metodologicamente pertinente para o problema investigado.

Apesar do reconhecimento do XGBoost pelo seu elevado desempenho, tornou-se necessário avaliar se essa técnica poderia superar ou complementar os resultados obtidos pelo Random Forest (GARCIA et al., 2023).

O XGBoost pertence à classe dos modelos de boosting gradiente, onde o modelo final é uma soma de árvores fracas adicionadas sequencialmente para reduzir o erro residual anterior, conforme a equação 2.9.

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i), f_k \in F \quad (2.9)$$

Onde:

- K = número de árvores;
- f_k = árvore de decisão na iteração k ;
- F = espaço das funções de árvores.

2.8 Características gerais da área de estudo

A área de estudo localiza-se no município de Araxá, em Minas Gerais, conforme **Figura 16**, onde se encontra uma importante operação de lavra a céu aberto de nióbio. Trata-se de um ambiente de grande interesse para a presente dissertação, uma vez que o posicionamento GNSS integra diretamente atividades de monitoramento, controle geométrico e suporte operacional, exigindo elevado grau de confiabilidade nas observações.

A dinâmica da lavra, o uso contínuo de sistemas de posicionamento e a necessidade de precisão nas atividades executadas conferem à área de estudo relevância aplicada para a investigação dos efeitos da degradação do sinal GNSS. Nesse contexto, compreender a ocorrência de perturbações ionosféricas e sua relação com observáveis coletados em condições reais de operação é fundamental para aproximar a análise acadêmica das demandas práticas do ambiente minerário.

Embora a caracterização da área de estudo seja frequentemente apresentada no capítulo metodológico, sua inclusão neste ponto busca reforçar a conexão entre a revisão teórica e o cenário aplicado no qual o fenômeno investigado se manifesta. Ainda assim, do ponto de vista estrutural, essa subseção também será descrita no Capítulo 3.

Figura 16 - Imagem aérea da mina de nióbio em Araxá, MG, onde ocorre o estudo.



Fonte: Google Earth Pro, (2025).

3 METODOLOGIA

A metodologia proposta nesta dissertação foi elaborada para garantir solidez conceitual e aplicabilidade prática, abrangendo quatro etapas interligadas, conforme a **Figura 17**: (i) fundamentação teórica, (ii) coleta e pré-processamento de dados, (iii) critério e métricas de avaliação dos modelos preditivos e (iv) avaliação das métricas de desempenho dos modelos preditivos, visando definir a estrutura mais efetiva para o atingimento dos objetivos propostos.

Figura 17 - Fluxograma esquemático da metodologia proposta nesta dissertação.



Fonte: elaboração do próprio autor.

3.1 Fundamentação Teórica

Inicia-se com uma análise detalhada da ionosfera, descrevendo suas camadas (D, E F) e os processos físicos de ionização, recombinação e transporte de partículas. Em seguida, explora-se o fenômeno da cintilação ionosférica, distinguindo seus tipos (amplitude e fase), escalas temporais e espaciais, e impactos em sinais GNSS e sistemas de comunicação via satélite.

3.2 Coleta e Pré-Processamento de Dados

Os dados utilizados nesta pesquisa foram obtidos por meio de um sistema GNSS Trimble de alta precisão. A estrutura da base é composta pelo receptor Trimble SPS855, integrado a um rádio UHF interno e conectado à rede de internet, acoplado à antena Zephyr Geodetic Modelo 2, como mostra a **Figura 18**.

Figura 18 - Receptor Trimble SPS855 e antena Zephyr Geodetic Modelo 2.



Fonte: <https://www.xpertsurveyequipment.com/trimble-sps855-gps-glonass-900mhz-base-or-rover-zephyr-2-1161.html?srltid=AfmBOoqIPpL5NMwrcrjyl14tAd2wsmYHswe8EsvvNVvnQwTe4Y6LSFoC>.

Esse conjunto forma a estação base, responsável pela recepção e transmissão contínua do sinal GNSS de alta precisão, estrategicamente instalado em uma área livre de interferências físicas e eletromagnéticas, assegurando a qualidade das medições, conforme **Figura 19**.

Figura 19 - Estação base de recepção e transmissão GNSS.



Fonte: elaboração do próprio autor.

Para acessar o sistema e monitorar o funcionamento da estação, utilizou-se o endereço IP, diretamente no navegador, o que permitiu visualizar a web interface do receptor de controle que permite configurar rádio, rede, base RTK e demais configurações do sistema, conforme a **Figura 20**.

Figura 20 - Web interface do receptor.

Configuração do registo de dados?

Nome da sessão: DEFAULT

Activar: ☒

Programa: Manual

Duração: 60 Minutos

Intervalo de medição: 1 Seg

Pseudo intervalo regular: ☐

Fase regular: ☐

Intervalo entre pontos: 1 Seg

O registo recebeu conexões: ☐

Registar dados de navegação não processados: ☐

Registar dados de SOAS: ☐

Sistema de ficheiros: Internal

Estilo de caminh: YYYYMMDD

Estilo de nome: MMAA

Envio de FTP: ☐

Envio de e-mail: ☐

OK Cancelar

Fonte: elaboração do próprio autor.

Nessa página, foi observado o status do receptor, o número de satélites disponíveis na região e as configurações do receptor. As observações dos dados foram configuradas para coletar os registros em um intervalo de um segundo, abrangendo um período de doze horas a partir das 20:00 horas do dia 28/11/2023, com a cobertura das constelações GPS e GLONASS. Após o término do monitoramento do rastreamento dos dados foi gerado um arquivo com extensão no formato T02 criptografado, disponível para download, conforme **Figura 21**.

Figura 21 - Web interface de downloads do rastreo.

Arquivos de dados?

Directório: Internal/2025/10/03


Directório de nível superior

Directório superior

Nome do ficheiro	Criado	Tamanho
Seleccione todos		
Eliminar ficheiros seleccionados		
Baxar Arquivos Seleccionados		
Converter e Baxar Arquivos Seleccionados		
15632763.T02	2025-10-03T17:08:30 GPS	661.7 KB
15632762.T02	2025-10-03T12:57:21 GPS	2.534 MB

Fonte: elaboração do próprio autor.

Para tornar os dados utilizáveis em ambiente de modelagem e análise de dados, foi necessário converter o arquivo T02 para o padrão RINEX (Receiver Independent Exchange Format), utilizando o software Trimble Convert to RINEX conforme **Figura 22**.

Figura 22 - Software de conversão de arquivos Trimble GNSS.

Fonte: elaboração do próprio autor.

Essa conversão gerou arquivos complementares como as extensões, obs (observações dos satélites) e nav (dados de navegação), além de possíveis extensões, glo, gal, gps ou bds, conforme as constelações de satélites GNSS rastreadas. No arquivo de observação existem metadados essenciais, incluindo informações sobre o equipamento utilizado, modelo da antena, intervalo de rastreo, número de satélites rastreados e constelações envolvidas, conforme **Figura 23**.

Figura 23 - Metadados de observação.

```

2.11 OBSERVATION DATA Mixed(MIXED) RINEX VERSION / TYPE
cnvtToRINEX 3.14.0 convertToRINEX OPR 20231204 201149 UTC PGM / RUN BY / DATE
----- COMMENT
BASE_SIR MARKER NAME
BASE_SIR MARKER NUMBER
GNSS Observer Trimble OBSERVER / AGENCY
TRIMBLE SPS855 5.44 REC # / TYPE / VERS
TRM115000.00 NONE ANT # / TYPE
APPROX POSITION XYZ
0.2500 0.0000 0.0000 ANTENNA: DELTA H/E/N
1 1 0 WAVELENGTH FACT L1/2
5 C1 C2 L1 L2 P2 # / TYPES OF OBSERV
1.000 INTERVAL
2023 11 28 20 12 59.0000000 GPS TIME OF FIRST OBS
2023 11 29 8 12 58.0000000 GPS TIME OF LAST OBS
0 RCV CLOCK OFFS APPL
18 LEAP SECONDS
48 # OF SATELLITES
G02 16166 0 16025 15440 15451 PRN / # OF OBS
G03 23336 23267 23301 23265 0 PRN / # OF OBS
G04 27282 27114 27198 27114 0 PRN / # OF OBS
G05 8306 8306 8306 8306 0 PRN / # OF OBS
G06 10643 10261 10481 10256 0 PRN / # OF OBS
G07 25674 25564 25628 25559 0 PRN / # OF OBS
G08 16683 16646 16667 16646 0 PRN / # OF OBS
G09 26016 25639 25881 25643 12 PRN / # OF OBS
G10 3380 3380 3380 3380 0 PRN / # OF OBS
G12 610 610 610 610 0 PRN / # OF OBS
G13 10960 0 10960 10960 10960 PRN / # OF OBS
G14 20766 20550 20588 20546 0 PRN / # OF OBS
G15 5710 5710 5710 5710 0 PRN / # OF OBS
G16 10486 0 10073 8158 8158 PRN / # OF OBS
G17 13799 13774 13777 13774 0 PRN / # OF OBS
G19 10882 0 10874 10818 10818 PRN / # OF OBS
G20 12716 0 12716 12716 12716 PRN / # OF OBS
G21 15706 0 15652 15606 15607 PRN / # OF OBS
G22 18021 0 17996 17809 17809 PRN / # OF OBS
G24 1540 1540 1540 1540 0 PRN / # OF OBS
G26 8840 8019 8397 8019 0 PRN / # OF OBS
G27 5720 5720 5720 5720 0 PRN / # OF OBS
G28 11298 11145 11279 11143 0 PRN / # OF OBS
G30 24702 24532 24625 24524 0 PRN / # OF OBS
G31 14902 14766 14860 14766 1 PRN / # OF OBS
G32 5750 5750 5750 5750 0 PRN / # OF OBS
R01 11851 11851 11851 11851 0 PRN / # OF OBS
R02 5371 5371 5371 5371 0 PRN / # OF OBS
R03 835 835 835 835 0 PRN / # OF OBS
R04 7721 7721 7721 7721 0 PRN / # OF OBS
R05 20088 20087 20088 20076 0 PRN / # OF OBS
R06 19001 0 18952 0 0 PRN / # OF OBS
R07 17474 17473 17473 17473 0 PRN / # OF OBS
R08 15917 15917 15917 15917 0 PRN / # OF OBS
R09 15851 15760 15760 15360 0 PRN / # OF OBS
R10 16641 0 16552 0 0 PRN / # OF OBS
R11 18785 18767 18777 18718 0 PRN / # OF OBS
R12 9151 9151 9151 9151 0 PRN / # OF OBS
R14 651 651 651 651 0 PRN / # OF OBS
R15 10297 10125 10269 9801 0 PRN / # OF OBS
R16 13746 13623 13710 13267 0 PRN / # OF OBS
R17 511 509 509 507 0 PRN / # OF OBS
R18 6260 6220 6260 6212 0 PRN / # OF OBS
R19 10344 10287 10306 10231 0 PRN / # OF OBS
R20 11289 11032 11168 10619 0 PRN / # OF OBS
R21 17707 17520 17628 17012 0 PRN / # OF OBS
R22 5229 5198 5213 5180 0 PRN / # OF OBS
R23 1111 0 1111 0 0 PRN / # OF OBS
CARRIER PHASE MEASUREMENTS: PHASE SHIFTS REMOVED COMMENT
END OF HEADER

```

Fonte: elaboração do próprio autor.

Esses metadados foram exportados em formato .csv, possibilitando a integração direta com as etapas de análise estatística e aprendizado de máquina. Além dos dados obtidos na região, foram incorporados parâmetros espaciais provenientes de estações de referência internacionais, como as da NOAA, abrangem indicadores geofísicos e espaciais fundamentais, entre eles:

- Número de TEC (Total Electron Content);
- Índice Kp (atividade geomagnética global);
- Índices GSE e GSM (componentes do campo magnético interplanetário);
- Pressão de fluxo de partículas solares;
- Campo elétrico interplanetário;
- Índice AE (Auroral Electrojet Index).

Esses parâmetros forneceram contexto físico ao comportamento ionosférico, sendo posteriormente integrados ao conjunto de variáveis explicativas do modelo.

O pré-processamento incluiu:


- Filtragem inicial: Foi realizada a limpeza de valores nulos e zeros, seguida da aplicação do método de detecção de outliers a fim de remover valores divergente que poderiam comprometer a modelagem;
- Engenharia de features temporais: Foram geradas variáveis derivadas da série temporal, incluindo defasagens (lags) das pseudodistâncias L1 e L2, além de estatísticas como médias móveis. Essa abordagem permitiu capturar relações temporais de curto prazo relevantes para o comportamento da variável alvo;
- Transformação da variável alvo: O modelo foi estruturado para prever as variações (deltas) da pseudodistância L1, ao invés de seus valores absolutos, com o objetivo de minimizar os efeitos de ruídos sistemáticos e melhorar a capacidade de generalização dos algoritmos;
- Inclusão de variáveis ambientais: As variáveis geofísicas (TEC, Kp, Bz GSE, Pressão de Fluxo, Campo Elétrico, Índice AE) foram integradas ao conjunto de features, visando enriquecer a entrada do modelo com informações sobre as condições espaciais que podem impactar as medições GNSS;

- Normalização dos dados: Foi aplicada a padronização das variáveis preditoras, utilizando o método de standardization (z-score). Esse processo consiste em subtrair cada valor da média da amostra e, em seguida, dividir pelo desvio padrão da amostra. Essa transformação coloca todas as variáveis na mesma escala, com média igual a zero e desvio padrão igual a um, o que contribui para a estabilidade e a convergência dos algoritmos de aprendizado de máquina.
- Tratamento de lacunas: As lacunas de dados geradas pelas operações de diferenciação e médias móveis, foram adequadamente tratadas com o descarte das linhas iniciais afetadas;
- Verificação final de consistência: Uma nova análise foi realizada para garantir que todas as amostras utilizadas no treinamento estivessem livres de valores inconsistentes ou não numéricos.

Neste trabalho, a cintilação ionosférica é modelada de forma indireta: por não utilizarmos diretamente os índices $S4/\sigma_f$ como variável-alvo, adotou-se a variação (delta) da pseudodistância L1 como proxy da degradação do sinal GNSS associada às condições ionosféricas.

A **Figura 24** apresenta o fluxograma das etapas de coleta e pré-processamento dos dados, incluindo filtragem, engenharia de atributos, transformação da variável-alvo e normalização, que antecedem a aplicação dos modelos de aprendizado de máquina.

Figura 24- Fluxograma das etapas de transformação dos dados.



Fonte: elaboração do próprio autor.

3.3 Modelos de Aprendizado de Máquina para Cintilação GNSS

Para antecipar episódios de cintilação ionosférica, utilizamos três abordagens complementares:

3.3.1 Random Forest

As florestas aleatórias combinam vários “especialistas” (árvores de decisão) e geram resultados estáveis mesmo na presença de ruído nos dados. Além de selecionar automaticamente as variáveis mais relevantes, esse modelo ajuda a revelar relações não lineares que, isoladamente, passariam despercebidas. Seu caráter “ensemble” também reduz o risco de sobreajuste, garantindo previsões consistentes ao longo do tempo (Bhattacharyya et al., 2021).

3.3.2 XGBoost (Extreme Gradient Boosting)

Baseado em árvores de decisão, o XGBoost destaca-se pela capacidade de modelar interações complexas entre variáveis. Em nosso estudo, usamos para avaliar quais fatores, como fluxos de partículas solares, conteúdo total de elétrons (TEC) e posição geográfica, exercem maior influência sobre a cintilação. Além de previsões precisas, o XGBoost oferece mecanismos de interpretação (via pesos de features e SHAP values), permitindo diagnosticar a origem dos distúrbios ionosféricos (Lundberg, S, M.; Lee, S, I, 2017).

Ao integrar **Random Forest** e o **XGBoost**, obtivemos um sistema com a robustez estatística do **Random Forest** e o poder de interpretação do **XGBoost**. Com isso, entregamos previsões mais confiáveis e ricas em insights, fundamentais para mitigar impactos da cintilação em sistemas de navegação.

3.4 Critério e Métricas de Avaliação dos Modelos Preditivos

A etapa de avaliação dos modelos preditivos é essencial para assegurar que as estimativas relacionadas à cintilação ionosférica sejam precisas e aplicáveis em distintos contextos operacionais. Para isso, foram adotadas métricas estatísticas amplamente utilizadas na literatura científica, com o objetivo de mensurar a acurácia, a robustez e a capacidade de generalização dos modelos analisados. Entre os indicadores escolhidos estão o **coeficiente de determinação (R^2)**, **erro quadrático médio (MSE)**, **erro médio absoluto (MAE)** e a **raiz do erro quadrático médio (RMSE)**. Esses parâmetros possibilitam uma análise abrangente do desempenho dos modelos sob diferentes perspectivas, oferecendo uma compreensão mais completa sobre sua eficácia na previsão da cintilação ionosférica, conforme discutido por Smith et al. (2022) e Garcia et al. (2023).

3.4.1 Coeficiente de determinação (R^2)

O **coeficiente de determinação (R^2)** é uma medida estatística que indica a proporção da variabilidade da variável dependente explicada pelo modelo preditivo. Embora, em teoria, valores próximos de 1 representem alta capacidade explicativa e valores próximos de 0 indiquem baixa representatividade, **R^2** pode assumir valores negativos quando o modelo apresenta desempenho insatisfatório. Essa métrica é

amplamente utilizada para avaliar a qualidade do ajuste e a adequação do modelo aos dados.

3.4.2 Erro Quadrático Médio (MSE)

O **Erro Quadrático Médio (MSE – Mean Squared Error)** é uma métrica amplamente utilizada para avaliar o desempenho de modelos preditivos, sendo calculado pela média dos quadrados das diferenças entre os valores estimados e os observados. Conforme discutido em estudos anteriores, essa abordagem atribui maior penalização a erros de maior magnitude, característica que a torna particularmente adequada para analisar a sensibilidade do modelo a grandes discrepâncias nas previsões e sua estabilidade geral.

3.4.3 Erro Médio Absoluto (MAE)

De acordo com a literatura especializada, o **Erro Médio Absoluto (MAE – Mean Absolute Error)** é amplamente adotado como métrica para avaliar a precisão de modelos preditivos. Essa medida, definida como a média das diferenças absolutas entre valores previstos e observados, possui interpretação direta e intuitiva, sendo expressa nas mesmas unidades da variável-alvo. Smith et al. (2020) destacam que o MAE é especialmente valioso por sua robustez a outliers e simplicidade de cálculo, o que facilita a comunicação dos resultados mesmo fora do contexto estatístico. Em termos operacionais, o MAE indica, em média, o quão distantes as previsões estão dos dados reais, servindo como um indicador claro e relevante da acurácia do modelo.

3.4.4 Raiz do Erro Quadrático Médio (RMSE)

A **Raiz do Erro Quadrático Médio (RMSE – Root Mean Squared Error)** é uma métrica estatística amplamente empregada na avaliação do desempenho de modelos preditivos, sendo particularmente relevante em estudos voltados à previsão de fenômenos geofísicos, como a cintilação ionosférica. Essa medida é obtida pela raiz quadrada da média dos quadrados das diferenças entre os valores estimados e os observados, fornecendo uma interpretação direta do erro em unidades da variável analisada, o que facilita a compreensão da magnitude das discrepâncias nas previsões.

Segundo Chai e Draxler (2014), o **RMSE** apresenta a vantagem de expressar os erros na mesma unidade da variável predita, o que facilita a interpretação dos resultados no contexto da aplicação prática. Além disso, por incorporar o quadrado dos erros antes da média, o **RMSE**, assim como o **MSE**, tende a penalizar de forma mais significativa os erros maiores, sendo uma medida sensível a grandes discrepâncias entre os valores estimados e os reais. Zhu (2022) também destaca que, devido a essas características, o **RMSE** é amplamente adotado em avaliações de desempenho de modelos ambientais e geofísicos.

No contexto deste estudo, a utilização do **RMSE** proporciona uma análise adicional da precisão dos modelos, permitindo comparar a magnitude média dos erros de predição em termos absolutos. Essa abordagem contribui para uma avaliação mais robusta da confiabilidade dos modelos na estimativa das variações da cintilação ionosférica, reforçando a consistência das análises de desempenho já estabelecidas pelas demais métricas adotadas.

3.5 Avaliação das Métricas de Desempenho dos Modelos Preditivos

A avaliação das métricas de desempenho dos modelos preditivos foi conduzida com base em métricas estatísticas amplamente consolidadas na literatura científica, conforme descrito na subseção anterior. Essas métricas — **Coeficiente de Determinação (R^2)**, **Raiz do Erro Quadrático Médio (RMSE)**, **Erro Quadrático Médio (MSE)** e **Erro Médio Absoluto (MAE)** — fornecem diferentes perspectivas sobre a qualidade das previsões, permitindo mensurar objetivamente a acurácia, a robustez e a capacidade explicativa dos modelos.

A utilização combinada dessas métricas possibilita uma análise abrangente, considerando tanto a magnitude absoluta dos erros quanto à adequação do ajuste do modelo aos dados observados. Em termos práticos:

- **R^2** avalia a proporção da variabilidade explicada pelo modelo, refletindo sua capacidade de generalização.
- **RMSE** e **MSE** oferecem uma visão da penalização de grandes discrepâncias, com o RMSE expressando o erro na mesma unidade da variável-alvo, facilitando a compreensão da magnitude das diferenças.
- **MAE** indica, em média, o quão distantes as previsões estão dos valores reais, sendo robusto a outliers e de fácil interpretação.

Esses indicadores são fundamentais para garantir a confiabilidade das estimativas no contexto da previsão da cintilação ionosférica, fenômeno que impacta diretamente sistemas de comunicação e navegação baseados em sinais GNSS. A cintilação ionosférica, caracterizada por variações rápidas na amplitude e fase dos sinais, pode comprometer a precisão de sistemas críticos, exigindo modelos robustos e precisos.

Apesar dos avanços tecnológicos, a previsão desse fenômeno ainda enfrenta desafios devido à alta variabilidade espacial e temporal da ionosfera. Nesse cenário, abordagens baseadas em aprendizado de máquina (ML) têm se mostrado promissoras, superando limitações de métodos tradicionais. Algoritmos como **Random Forest** e **XGBoost**, vêm sendo aplicadas com sucesso, permitindo maior precisão na antecipação de eventos de cintilação e melhor interpretação dos fatores físicos envolvidos.

Estudos recentes (Bhattacharyya et al., 2021; Liu et al., 2022) demonstram que a integração de dados GNSS com modelos de aprendizado profundo pode elevar a taxa de acerto das previsões para níveis superiores a 85%, reforçando a relevância dessas abordagens para aplicações operacionais. Além disso, a adoção de métricas robustas, como as mencionadas, assegura que os modelos não apenas apresentem alta acurácia, mas também mantenham estabilidade e capacidade de generalização em diferentes cenários.

Portanto, a avaliação de desempenho baseada em métricas estatísticas e técnicas modernas de ML é essencial para desenvolver sistemas de previsão confiáveis, capazes de mitigar os impactos da cintilação ionosférica em infraestruturas críticas e garantir a continuidade de serviços dependentes de sinais GNSS.

4 RESULTADOS

Este capítulo apresenta os resultados obtidos a partir da aplicação dos modelos de aprendizado de máquina propostos para a representação preditiva do fenômeno estudado, com base nas variáveis ambientais, geofísicas e observacionais selecionadas. Considerando a natureza multifatorial e não linear das perturbações que afetam o sinal GNSS, a avaliação dos modelos foi conduzida com apoio de métricas estatísticas consolidadas, a saber: coeficiente de determinação (R^2), raiz do erro quadrático médio (RMSE), erro quadrático médio (MSE) e erro médio absoluto (MAE). Essas métricas permitem analisar, de forma objetiva, o grau de aderência entre os valores estimados e os valores observados, bem como comparar o desempenho relativo entre os algoritmos testados.

A análise foi estruturada com foco comparativo entre os modelos Random Forest e XGBoost, ambos reconhecidos por sua capacidade de representar relações não lineares e interações complexas entre variáveis explicativas. Os resultados apresentados a seguir evidenciam o comportamento de cada abordagem e subsidiam a seleção do modelo com melhor desempenho no conjunto de dados analisado.

4.1 Análise de Desempenho do Random Forest

O modelo Random Forest foi adotado como uma das abordagens centrais deste estudo em razão de sua robustez frente à heterogeneidade dos dados e de sua reconhecida capacidade de modelar relações não lineares entre múltiplas variáveis explicativas. Durante a etapa de treinamento, foi realizada seleção de atributos com base em sua relevância para a variável-resposta, procedimento que contribuiu para reduzir a dimensionalidade do problema e favorecer maior eficiência computacional. Para a avaliação do modelo, o conjunto de dados foi particionado em 80% para treinamento e 20% para teste.

Os resultados obtidos indicam desempenho preditivo muito elevado para o Random Forest, com $R^2 = 0,9911$, RMSE = 0,0945, MSE = 0,0089 e MAE = 0,0504, conforme sintetizado posteriormente na Tabela 4. Tais valores evidenciam forte aderência entre os valores estimados e observados no conjunto analisado, bem como baixos níveis de erro residual. Em termos comparativos, trata-se do modelo com melhor desempenho entre os algoritmos avaliados nesta pesquisa.

Os indicadores obtidos sugerem que o Random Forest foi capaz de capturar, com elevada consistência, os padrões presentes nos dados utilizados na modelagem. Ainda assim, a interpretação desses resultados deve ser realizada com cautela, uma vez que métricas muito elevadas demandam atenção quanto à capacidade de generalização do modelo em bases externas ou em cenários operacionais distintos daqueles contemplados nesta dissertação. Desse modo, os resultados sustentam a adequação do modelo ao problema estudado, sem que isso implique afirmar comportamento perfeito ou generalização irrestrita.

No contexto desta pesquisa, o desempenho alcançado pelo Random Forest indica potencial para apoiar a análise preditiva de condições associadas à degradação do sinal GNSS na área de estudo, constituindo uma base técnica promissora para aplicações futuras voltadas ao monitoramento e à interpretação do fenômeno em ambiente minerário.

4.2 Análise de Desempenho do XGBoost

O modelo XGBoost foi avaliado como alternativa ao Random Forest em razão de sua estrutura de aprendizado sequencial, na qual cada nova árvore busca corrigir os erros residuais das anteriores. Essa característica torna o algoritmo particularmente relevante em problemas com padrões complexos e não lineares, além de favorecer elevado desempenho preditivo quando adequadamente ajustado. No presente estudo, foram exploradas diferentes combinações de hiperparâmetros, incluindo taxa de aprendizado, número de estimadores e profundidade das árvores, com o objetivo de otimizar o comportamento do modelo. Além disso, foram empregadas estratégias de validação e regularização para reduzir o risco de sobreajuste e melhorar sua estabilidade.

Os resultados obtidos para o XGBoost também evidenciaram desempenho preditivo elevado, com $R^2 = 0,9905$, $RMSE = 0,0977$, $MSE = 0,0095$ e $MAE = 0,0571$. Esses valores demonstram que o modelo apresentou alta capacidade de ajuste aos dados observados, mantendo erros reduzidos e comportamento bastante competitivo em relação ao Random Forest.

Embora o XGBoost tenha apresentado resultados muito próximos aos do modelo concorrente, observa-se que, em todas as métricas avaliadas, seus indicadores foram ligeiramente inferiores aos do Random Forest. Assim, ainda que o algoritmo tenha se mostrado tecnicamente adequado para a modelagem proposta,

seu desempenho foi discretamente menos favorável no conjunto específico de dados utilizado nesta dissertação.

De modo geral, os resultados obtidos com o XGBoost confirmam a pertinência do uso de métodos baseados em árvores para a análise preditiva do fenômeno estudado. Sua aplicação demonstrou capacidade de representar relações complexas entre variáveis ambientais, geofísicas e observacionais, reforçando a viabilidade do emprego de técnicas de aprendizado de máquina nesse contexto.

4.3 Comparação dos Modelos e Seleção do Mais Eficiente

A comparação entre os modelos Random Forest e XGBoost, sintetizada na Tabela 4, evidencia que ambos apresentaram desempenho preditivo muito elevado no conjunto de dados analisado. Os coeficientes de determinação próximos de 1 e os baixos valores de RMSE, MSE e MAE indicam forte concordância entre os valores estimados e observados, demonstrando que as duas abordagens foram capazes de representar adequadamente a variável modelada neste estudo.

Tabela 4 - Desempenho dos modelos avaliados.

Modelo	R²	RMSE	MSE	MAE
Random Forest	0,9911	0,0945	0,0089	0,0504
XGBoost	0,9905	0,0977	0,0095	0,0571

Fonte: elaboração do próprio autor

Apesar da proximidade entre os resultados, o modelo Random Forest apresentou desempenho ligeiramente superior em todas as métricas consideradas, com $R^2 = 0,9911$, RMSE = 0,0945, MSE = 0,0089 e MAE = 0,0504, enquanto o XGBoost apresentou $R^2 = 0,9905$, RMSE = 0,0977, MSE = 0,0095 e MAE = 0,0571. Essa diferença, embora pequena, é consistente e suficiente para indicar o Random Forest como a alternativa de melhor desempenho no âmbito desta pesquisa.

Do ponto de vista metodológico, os resultados reforçam a adequação de modelos baseados em árvores de decisão para a análise de fenômenos caracterizados por relações não lineares e por interação entre múltiplos fatores explicativos. Além do desempenho estatístico, o Random Forest oferece a vantagem adicional de permitir a análise da importância relativa das variáveis, o que favorece a interpretação do modelo e pode contribuir para o refinamento de futuras aplicações.

Com base nos resultados obtidos, conclui-se que o Random Forest foi o modelo mais eficiente entre os avaliados para a base considerada nesta dissertação. Todavia, essa superioridade deve ser interpretada no contexto específico dos dados e critérios adotados, sendo recomendável que estudos futuros ampliem a validação empírica em diferentes períodos, condições ionosféricas e contextos operacionais, de modo a verificar a estabilidade do desempenho observado.

5 CONCLUSÕES

Os resultados obtidos nesta pesquisa demonstram a viabilidade do uso de modelos de aprendizado de máquina para a representação preditiva de condições associadas à degradação do sinal GNSS a partir da integração entre variáveis ambientais, geofísicas e dados observacionais coletados na área de estudo, localizada em Araxá (MG). No conjunto analisado, a abordagem adotada mostrou-se consistente para estabelecer relações entre as variáveis explicativas e a variável-resposta considerada, oferecendo base quantitativa para o desenvolvimento de instrumentos de apoio ao monitoramento do fenômeno estudado.

Entre os modelos avaliados, Random Forest e XGBoost apresentaram desempenho preditivo muito elevado, conforme evidenciado na Tabela 4. O Random Forest obteve os melhores resultados em todas as métricas analisadas, com $R^2 = 0,9911$, RMSE = 0,0945, MSE = 0,0089 e MAE = 0,0504, enquanto o XGBoost apresentou $R^2 = 0,9905$, RMSE = 0,0977, MSE = 0,0095 e MAE = 0,0571. Esses resultados indicam que ambos os modelos foram adequados para o problema investigado, com ligeira superioridade do Random Forest no conjunto de dados utilizado.

À luz dos objetivos propostos, conclui-se que a pesquisa avançou na análise quantitativa da ocorrência do fenômeno e na avaliação do desempenho de abordagens preditivas aplicadas ao contexto minerário. Os resultados sustentam que a modelagem baseada em aprendizado de máquina constitui uma estratégia promissora para apoiar a interpretação de condições potencialmente associadas à perda de qualidade do sinal GNSS. Contudo, os benefícios operacionais decorrentes dessa aplicação devem ser compreendidos como potencial de uso e não como efeito já demonstrado de forma direta nesta etapa da investigação.

Sob a perspectiva aplicada, os achados deste estudo indicam que ferramentas preditivas dessa natureza poderão, em trabalhos futuros e mediante validação complementar, subsidiar o planejamento de atividades sensíveis à qualidade do posicionamento, especialmente em operações que dependem de maior rigor geométrico. Dessa forma, a principal contribuição prática da dissertação reside no fornecimento de uma base metodológica capaz de apoiar o desenvolvimento de sistemas de monitoramento e decisão mais aderentes às variabilidades que afetam o posicionamento GNSS em ambiente de lavra.

Como encaminhamento para trabalhos futuros, recomenda-se ampliar a base de dados, incorporar novas validações em diferentes intervalos temporais e condições ionosféricas, bem como integrar a modelagem preditiva a sistemas computacionais de apoio à decisão. Também se mostra pertinente investigar a inclusão de novas variáveis explicativas e a comparação com outras técnicas de aprendizado de máquina, de modo a aprofundar a robustez analítica e a aplicabilidade operacional da abordagem proposta.

6 REFERÊNCIAS BIBLIOGRÁFICAS

Batista, I.S. Notas de aula do curso “**Introdução à ionosfera e a propagação de ondas**” ministrado no Programa de Pós-Graduação em Ciências Cartográficas da Faculdade de Ciências e Tecnologia da Universidade Estadual Paulista, 2003.

BENIGUEL, Y. **Global Ionospheric Scintillation Model**. September 2011. Disponível em: <<http://www.ieea.fr/help/gism-technical.pdf>>. Acesso em: 26 out. 2023.

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.

BORA, Saradi. **Ionosfera e radiocomunicação**. *Ressonância*, v. 22, n. 2, pág. 123-133, 2017.

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, Otávio et al. **Predição de cintilação ionosférica de amplitude pela aplicação de métodos de aprendizagem de máquina, 2021**.

CHAI, T.; DRAXLER, R. R. Root mean square error (RMSE) or mean absolute error (MAE)? – arguments against avoiding RMSE in the literature. **Geoscientific Model Development**, v. 7, n. 3, p. 1247–1250, 2014. DOI: <https://doi.org/10.5194/gmd-7-1247-2014>.

CONKER, R. S. et al. **Modeling the effects of ionospheric scintillation on GPS/satellitebased augmentation system availability**. *RADIO SCIENCE*, v. 38, 2003. Disponível em: <<http://dx.doi.org/10.1029/2000RS002604>>.

CORDEIRO, Carlos et al. **IEEE 802.22: the first worldwide wireless standard based on cognitive radios**. In: First IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks, 2005. DySPAN 2005. Ieee, 2005. p. 328-337.

DAL POZ, W. R. **Investigações preliminares sobre a influência do clima espacial no posicionamento relativo com GNSS**. 159 f. Dissertação (Mestrado em Ciências Cartográficas) — Universidade Estadual Paulista, Presidente Prudente, 2010.

DATTA-BARUA, S. et al. **Ionospheric scintillation effects on single and dual frequency GPS positioning**. In: Proceedings of the ION GPS 2003. Portland (OR): [s.n.], 2003.

DAVIES, K. **Ionospheric Radio**. London: Peter Peregrinus, 1990. 580 p.

ESA (**European Space Agency**) – on line – endereço eletrônico: <https://sci.esa.int/web/cluster/-/36645-solar-wind>>. Acesso em maio de 2025.

FEDRIZZI, M. **Estudo do efeito das tempestades magnéticas sobre a ionosfera utilizando dados do GPS**. 2003. 223p. Tese (Doutorado em Geofísica Espacial) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos.

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.

GOOGLE. **Google Earth Pro**. Versão 2025. Disponível em: <<https://earth.google.com/>>. Acesso em: 18 maio 2025.

GONZALEZ, W. D.; JOSELYN, J. A.; KAMIDE, Y.; KROEHL, H. W.; ROSTOKER, G.; TSURUTANI, B. T.; VASYLIUNAS, V. M. **What is a geomagnetic storm?** *Journal of Geophysical Research: Space Physics*, v. 99, n. A4, p. 5771–5792, 1994. Disponível em: <<https://agupubs.onlinelibrary.wiley.com/doi/abs/10.1029/93JA02867>>.

HEGARTY, C. et al. **Scintillation modeling for GPS-Wide Area Augmentation System receivers**. *Radio Science*, v. 36, n. 5, p. 1221–1231, September/October 2001.

INSTITUT D'ÉTUDES ET D'EXPERTISES EN AÉRONAUTIQUE (IEEA). **Theoretical Studies in Electromagnetism**. 2010. Disponível em: <<http://www.ieea.fr/>>. Acesso em: 18 maio 2025.

KINTNER JR., P.; HUMPHREYS, T.; HINKS, J. **GNSS and ionospheric scintillation: How to survive the next solar maximum**. *Inside GNSS*, p. 22–30, 2009.

KLOBUCHAR, J. A. **Ionospheric time-delay algorithm for single-frequency GPS uses**. *IEEE TRANSACTIONS ON AEROSPACE AND ELECTRONIC SYSTEMS*, AES-23, n. 3, p. 325–331, May 1987.

Komjathy, A. **GLOBAL IONOSPHERIC TOTAL ELECTRON CONTENT MAPPING USING THE GLOBAL POSITIONING SYSTEM, 1997**.

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.

LEICK, A. **GPS satellite surveying**. Hoboken: John Wiley, 2004. 435 p.

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.

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

MARQUES, H. A. **PPP em tempo real com estimativa das correções dos relógios dos satélites no contexto de rede GNSS**. 244 f. Tese (Doutorado em Ciências Cartográficas) — Universidade Estadual Paulista, Presidente Prudente, 2012.

McNAMARA, L. F. **The Ionosphere: communications, surveillance, and direction finding**. Florida: Krieger, 1991. 237 p.

NATIONAL AERONAUTICS AND SPACE ADMINISTRATION (NASA). **Solar Science** – Yohkoh image (1992-05-08). Disponível em: <https://solarscience.msfc.nasa.gov/images/Yohkoh_920508.jpg>. Acesso em: 18 maio 2025.

NATIONAL OCEANIC AND ATMOSPHERIC ADMINISTRATION (NOAA). **Sunspots & Solar Cycle**. Disponível em: <<https://www.swpc.noaa.gov/phenomena/sunspots-solar-cycle>>. Acesso em: 18 maio 2025.

NORTHWESTM RESEARCH ASSOCIATES (NWRA). **SCINTMOD (WBMOD) – Example** Output. 2011. Disponível em: <<https://www.nwra.com/>>. Acesso em: 18 maio 2025.

NRCan (**Natural Resources Canada** – on line) – Endereço eletrônico: <<https://geomag.nrcan.gc.ca/lab/default-en.php>>. Acesso em 18 maio 2025.

NUNES, Jorge et al. **Precipitação de partículas carregadas na anomalia geomagnética brasileira, estudos de evidências, 1982**.

PENG, Y. et al. **Ionospheric scintillation effects on GPS receiver signal tracking performance**. In: PROCEEDINGS OF THE ION GNSS. Portland, OR: Institute of Navigation, 2011. p. 2588–2597.

POLEZEL, W. G. C. **INVESTIGAÇÕES SOBRE O IMPACTO DA MODERNIZAÇÃO GNSS NO POSICIONAMENTO**. 106 f. Dissertação (Mestrado em Ciências Cartográficas) — Universidade Estadual Paulista, Presidente Prudente, 2010.

PRASAD, R.; RUGGIERI, M. **Applied satellite navigation using GPS, GALILEO, and augmentation systems**. Boston, MA: Artech House, 2005.

RADICELLA, S. M. **The nequick model genesis, uses, and evolution**. *Annals of geophysics*, v. 52, n. 3/4, p. 417–422, 2009.

REZENDE, L. de et al. **Mapping and survey of plasma bubbles over brazilian territory**. *Journal of Navigation*, Cambridge Univ Press, v. 60, n. 01, p. 69–81, 2007.

ROHDE, R. A. **400 years of sunspot observations**. 2012. Imagem digital. Disponível em: <http://www.globalwarmingart.com/wiki/File:Sunspot_Numbers.png>. Acesso em: 25 out. 2023.

SEEBER, G. (1993). **Satellite Geodesy: foundations, methods, and applications**. Berlin, Walter de Gruyter.

SECAN, J. et al. **High-latitude upgrade to the wideband ionospheric scintillation model**. Radio Science, Wiley Online Library, v. 32, n. 4, p. 1567–1574, 1997.

SKONE, S.; HOYLE, V. **Canadian GPS network for ionosphere monitoring (CANGIM)**. GPS Solutions, Springer-Verlag, v. 9, n. 1, p. 59–62, 2005. ISSN 1080-5370. Disponível em: <<http://dx.doi.org/10.1007/s10291-004-0117-3>>.

SKONE, S. et al. **Investigating the impact of ionospheric scintillation using a GPS software receiver**. In: Proceedings of the ION GNSS 2005 Conference. Long Beach (CA): [s.n.], 2005.

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.

TAUXE, L. et al. **Essentials of Paleomagnetism. 2nd web edition. ed. [s.n.], 2014**. 512 p. Disponível em: <<http://magician.ucsd.edu/Essentials%5f2/WebBook2.html>>. Acesso em: 26 out. 2023.

TIWARI, R. et al. **WMod assisted PLL GPS software receiver for mitigating scintillation affect in high latitude region**. In: General Assembly and Scientific Symposium, 2011 XXXth URSI. Istanbul, Turkey: [s.n.], 2011. p. 1–4. Disponível em: <<http://dx.doi.org/10.1109/URSIGASS.2011.6050861>>.

VANI, Bruno César. **Análise da cintilação ionosférica no Brasil empregando GNSS e técnicas de mineração e visualização de dados, 2014**.

VAN DIERENDONCK, A. J.; KLOBUCHAR, J. A.; HUA, Q. **Ionospheric scintillation monitoring using commercial single frequency C/A code receivers**. In: Proceedings of the Institute of Navigation. Alexandria (VA): [s.n.], 1993. p. 1324–1333.

WALTER, T. et al. **Effect of ionospheric scintillations on GNSS: A white paper**. SBAS Ionospheric Working Group, 2010.

WALTER, T. et al. Robust detection of ionospheric irregularities. In: **PROCEEDINGS OF THE INSTITUTE OF NAVIGATION INTERNATIONAL TECHNICAL MEETING**. San Diego, CA: Institute of Navigation, 2010. p. 111–120.

WEBSTER, I. **A Regional Model for Prediction of Ionospheric Delay for Single Frequency Users of the Global Positioning System**. 1993. M.Sc. E Thesis – Department of Surveying Engineering, University of New Brunswick, New Brunswick, Canada.

WDC (**World Data Center for Geomagnetism**), **Kyoto**. Disponível em: <https://wdc.kugi.kyoto-u.ac.jp>. Acesso em: 04 dez. 2025.

XPERT SURVEY EQUIPMENT. **Trimble SPS855 GPS/GLONASS 900 MHz – Zephyr Geodetic 2**. Disponível em: <<https://www.xpertsurveyequipment.com/trimble-sps855-gps-glonass-900mhz-base-or-rover-zephyr-2-1161.html>>. Acesso em: 18 maio 2025.

YAMASHITA, C.S. **Efeito das tempestades magnéticas intensas na ionosfera de baixa latitude**. 1999. 75p. Dissertação (Mestrado em Geofísica Espacial) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos.

ZHU, W. **Statistical parameters for assessing environmental model performance related to sample size**: Case study in ocean color remote sensing. arXiv preprint arXiv:2208.05457, 2022. Disponível em: <https://arxiv.org/abs/2208.05457>. Acesso em: 23 jun. 2025.

APÊNDICE A – CÓDIGO EM LINGUAGEM PYTHON

```
import pandas as pd
import numpy as np

from sklearn.ensemble import RandomForestRegressor
from xgboost import XGBRegressor

from sklearn.metrics import mean_squared_error,
mean_absolute_error, r2_score
from sklearn.model_selection import train_test_split, KFold

# ===== 1. Carregar os dados direto do Excel =====
file_path = '/content/Base_Dados_Rastreados_L2.xlsx'
df = pd.read_excel(file_path, sheet_name='Dados Agrupados')

# ===== 2. Selecionar apenas as colunas necessárias =====
features = [
    'Pseudodistancia L2',
    'TEC',
    'Kp',
    'Bz GSE (nt)',
    'Bz GSM (nt)',
    'Pressão de Fluxo',
    'Campo elétrico',
    'Índice AE'
]

target = 'Pseudodistancia L1'

# Remover possíveis valores ausentes
df = df.dropna(subset=features + [target])

X = df[features]
y = df[target]

# =====
# 3. Random Forest com Validação Cruzada K-Fold (5 folds)
# =====
print("\n===== Random Forest com K-Fold (5 folds) =====")
```

```

rf_cv = RandomForestRegressor(
    n_estimators=100,
    random_state=42
)
kf = KFold(
    n_splits=5,
    shuffle=True,
    random_state=42
)
r2_scores = []
rmse_scores = []
mse_scores = []
mae_scores = []

for fold, (train_index, test_index) in enumerate(kf.split(X), start=1):

    X_train, X_test = X.iloc[train_index], X.iloc[test_index]
    y_train, y_test = y.iloc[train_index], y.iloc[test_index]

    rf_cv.fit(X_train, y_train)

    y_pred = rf_cv.predict(X_test)

    r2 = r2_score(y_test, y_pred)
    mse = mean_squared_error(y_test, y_pred)
    rmse = np.sqrt(mse)
    mae = mean_absolute_error(y_test, y_pred)

    r2_scores.append(r2)
    mse_scores.append(mse)
    rmse_scores.append(rmse)
    mae_scores.append(mae)

print(
    f"Fold {fold}: "
    f"R²={r2:.4f} | "
    f"RMSE={rmse:.4f} | "
    f"MSE={mse:.4f} | "
    f"MAE={mae:.4f}"
)

```

```

print("\n==== Média e Desvio Padrão - Random Forest K-Fold =====")
print(f"R²: Média={np.mean(r2_scores):.4f}, Std={np.std(r2_scores):.4f}")
print(f"RMSE: Média={np.mean(rmse_scores):.4f},
Std={np.std(rmse_scores):.4f}")
print(f"MSE: Média={np.mean(mse_scores):.4f},
Std={np.std(mse_scores):.4f}")
print(f"MAE: Média={np.mean(mae_scores):.4f},
Std={np.std(mae_scores):.4f}")

# =====
# 4. Divisão Treino/Teste para Random Forest e XGBoost
# =====

X_train, X_test, y_train, y_test = train_test_split(
    X,
    y,
    test_size=0.2,
    random_state=42
)

# =====
# 5. Random Forest com Train/Test Split
# =====

print("\n==== Random Forest - Train/Test Split =====")

rf = RandomForestRegressor(
    n_estimators=100,
    random_state=42
)

rf.fit(X_train, y_train)

pred_rf = rf.predict(X_test)

r2_rf = r2_score(y_test, pred_rf)
mse_rf = mean_squared_error(y_test, pred_rf)
rmse_rf = np.sqrt(mse_rf)
mae_rf = mean_absolute_error(y_test, pred_rf)

print(
    f"R²: {r2_rf:.4f} | "
    f"RMSE: {rmse_rf:.4f} | "

```

```

        f"MSE: {mse_rf:.4f} | "
        f"MAE: {mae_rf:.4f}"
    )

# =====
# 6. XGBoost
# =====

print("\n===== XGBoost =====")

xgb = XGBRegressor(
    n_estimators=100,
    random_state=42
)

xgb.fit(X_train, y_train)

pred_xgb = xgb.predict(X_test)

r2_xgb = r2_score(y_test, pred_xgb)
mse_xgb = mean_squared_error(y_test, pred_xgb)
rmse_xgb = np.sqrt(mse_xgb)
mae_xgb = mean_absolute_error(y_test, pred_xgb)

print(
    f"R²: {r2_xgb:.4f} | "
    f"RMSE: {rmse_xgb:.4f} | "
    f"MSE: {mse_xgb:.4f} | "
    f"MAE: {mae_xgb:.4f}"
)

print("\nFim do processo. Modelos Random Forest e XGBoost treinados com os
dados da planilha.")

print("\nFim do processo.")

===== Random Forest com K-Fold (5 folds) =====
Fold 1: R²=0.9911 | RMSE=0.0945 | MSE=0.0089 | MAE=0.0504
Fold 2: R²=0.9910 | RMSE=0.0947 | MSE=0.0090 | MAE=0.0503
Fold 3: R²=0.9911 | RMSE=0.0942 | MSE=0.0089 | MAE=0.0501
Fold 4: R²=0.9912 | RMSE=0.0940 | MSE=0.0088 | MAE=0.0497
Fold 5: R²=0.9911 | RMSE=0.0946 | MSE=0.0090 | MAE=0.0501

```

===== Média e Desvio Padrão - Random Forest K-Fold =====

R^2 : Média=0.9911, Std=0.0001

RMSE: Média=0.0944, Std=0.0002

MSE: Média=0.0089, Std=0.0000

MAE: Média=0.0501, Std=0.0002

===== Random Forest - Train/Test Split =====

R^2 : 0.9911 | RMSE: 0.0945 | MSE: 0.0089 | MAE: 0.0504

===== XGBoost =====

R^2 : 0.9905 | RMSE: 0.0977 | MSE: 0.0095 | MAE: 0.0571


Fim do processo. Modelos Random Forest e XGBoost treinados com os dados da planilha.

APÊNDICE B – CICLO SOLAR

B.1 Manchas solares

As manchas solares conforme a **Figura 25** são fenômenos observáveis na superfície do sol que revelam aspectos importantes sobre sua dinâmica e influência na Terra. Essas manchas são regiões mais escuras e frias em comparação ao restante da superfície solar, formadas pela interação entre o campo magnético e o plasma solar. Além disso, as manchas solares apresentam um comportamento periódico, variando de 0 a 100 a cada aproximadamente 11 anos. Esse ciclo de atividade foi registrado desde a época de Galileio ao observá-las com um telescópio (McNAMARA, 1991).

Figura 25 - Manchas solares.




Fonte: <https://www.swpc.noaa.gov/phenomena/sunspotssolar-cycle>. Acesso em: 18/05/2025.

As manchas solares podem ser analisadas de diferentes formas, utilizando diversos métodos de observação e indicadores de intensidade. Uma maneira de visualizar o ciclo de atividade das manchas solares é através de gráficos que mostram o número médio mensal ou anual de manchas solares ao longo do tempo. A **Figura 26** apresenta um gráfico que abrange um período de 400 anos, permitindo identificar períodos de maior ou menor atividade solar. A parte vermelha à esquerda do gráfico corresponde a um período de quase 70 anos, entre 1645 e 1715, onde quase não

houve manchas solares observadas. Esse período é conhecido como "Mínimo de Maunder", em homenagem ao astrônomo Walter Maunder, no final do século XIX (McNAMARA, 1991). Outro ponto de destaque é o valor máximo de manchas solares registrado em 1957, o maior até então.

Figura 26 - Manchas solares entre 400 anos.



Fonte: Adaptado de Rohde (2012).

É importante ressaltar que a atividade das manchas solares tem uma relação direta com a influência do sol na ionosfera terrestre. Quanto maior a atividade das manchas solares, maior é a emissão de radiação solar em comprimentos de onda curtas, como raios X e ultravioleta extremo, que afetam a ionização da atmosfera, as comunicações e os satélites artificiais (McNAMARA, 1991).

Além do número de manchas solares, existe outro indicador da atividade solar que pode ser medido de forma simples e contínua, o F10.7, que tem o comprimento de onda de 10,7 cm e frequência de 2800 MHz. Esse fluxo corresponde à intensidade da radiação eletromagnética emitida pelo sol nessa faixa de comprimento de onda, que está próxima da região do rádio no espectro eletromagnético. O fluxo solar na faixa de 10,7 cm tem uma forte correlação com o índice de manchas solares, ou seja, quanto maior o número de manchas solares, maior é o fluxo solar nessa faixa. Por isso, os observatórios astronômicos utilizam esse fluxo como um indicador da atividade solar, que pode ser monitorado facilmente com antenas e receptores de rádio (McNAMARA, 1991).

O estudo do ciclo solar e da atividade das manchas solares tem grande relevância para diversos campos do conhecimento e da tecnologia, pois os fenômenos solares afetam diretamente o ambiente espacial e a atmosfera terrestre. O GNSS é

uma tecnologia essencial amplamente empregada em diversas áreas, incluindo navegação terrestre, marítima e aérea, levantamentos geodésicos de alta precisão, agricultura de precisão, onde contribui para o uso eficiente de recursos e o aumento da produtividade, além de desempenhar papel fundamental no monitoramento e na resposta a desastres naturais, permitindo a localização rápida de áreas afetadas e a coordenação eficaz das operações de resgate. No entanto, o GNSS é sensível às variações da radiação solar e do vento solar, que podem causar erros de medição, interferências, atrasos e até perda de sinal. Por isso, é importante compreender como o ciclo solar e a atividade das manchas solares influenciam o funcionamento do GNSS e como mitigar seus efeitos (DAL POZ, 2010).

Assim, variações no ciclo solar e no fluxo F10.7 refletem-se na intensidade da ionização e, por consequência, na probabilidade de ocorrência de cintilação em regiões de baixa latitude, como a área de estudo desta dissertação.

APÊNDICE C – CÓDIGO EM LINGUAGEM PYTHON

C.1 Modelos de Cintilação Ionosférica

Estudos sobre cintilação ionosférica em relação ao posicionamento GNSS podem ser apoiados por modelos de cintilação. Esses modelos podem ser usados para estimar a capacidade de um sistema funcionar de acordo com determinados requisitos ou requisitos mínimos. Existem também modelos preditivos baseados na assimilação de dados (WALTER et al., 2010). Dois padrões de cintilação são destacados nas subseções a seguir.

C.1.1 WideBand (WBMOD)


O modelo de cintilação WBMOD é um modelo empírico desenvolvido por pesquisadores da Northwestern Research Associates, Inc. (NWRA), com o apoio do governo dos EUA. Esse modelo visa estimar a cintilação ionosférica em um cenário específico do usuário, definido pela localização, estação do ano, hora local e condições geofísicas. O WBMOD é composto por dois submodelos: o modelo de cintilação EDIM e o modelo de propagação SCNPROP (Secan et al., 1997).

O modelo de cintilação EDIM fornece a distribuição global e o comportamento geral das irregularidades na densidade eletrônica da ionosfera, responsáveis pela cintilação. Esse modelo é baseado em uma coleção de modelos que descrevem a geometria, orientação, intensidade e movimento das irregularidades ionosféricas, considerando vários parâmetros como localização, estação do ano, atividade solar e índices geomagnéticos. Um dos parâmetros gerados pelo EDIM é o CkL, que representa a irregularidade da densidade de elétrons integrada à altura e a intensidade do espectro de densidade de potência ao longo de um caminho vertical através de toda a ionosfera.

O modelo de propagação SCNPROP utiliza a descrição obtida pelo modelo de cintilação EDIM para calcular os efeitos da cintilação em um sistema definido pelo usuário. Esse modelo considera as características do sinal de rádio, do receptor, do satélite e da ionosfera para estimar os índices de cintilação de amplitude e de fase, bem como a perda de rastreamento do sinal. O SCNPROP pode ser usado para simular os efeitos da cintilação em diferentes cenários e aplicações.

A **Figura 27** mostra um exemplo de aplicação do modelo WBMOD, realizado com uma ferramenta chamada SCINTMOD, que é baseada no WBMOD. Nesse exemplo, pode-se observar a distribuição espacial e temporal da cintilação de fase na região equatorial, em um determinado dia e hora. As áreas verdes indicam ausência ou baixo nível de cintilação, as áreas amarelas indicam nível moderado de cintilação e as áreas vermelhas indicam nível alto de cintilação. Essa informação pode ser útil para avaliar o desempenho dos sistemas GNSS que operam nessa região.

Figura 27 - Exemplo do WBMOD.



Fonte: NorthWest Research Associates, Inc. (NWRA) (2011).

C.1.2 Modelo Global de Cintilação Ionosférica (GISM)


O GISM é um modelo empírico desenvolvido para estimar as cintilações ionosféricas e os erros médios no valor do TEC (Total Electron Content) em uma localização arbitrária. Esse modelo fornece características estatísticas do sinal de rádio transmitido pela ionosfera, como os índices de cintilação de amplitude (S4) e de fase ($\sigma\phi$), além da duração do decaimento do sinal. O modelo também gera mapas de desvio padrão da fase do sinal em diferentes regiões e horários (BENIGUEL, 2011).

O GISM utiliza como parâmetros de entrada a densidade espectral (p) das flutuações dos elétrons na ionosfera, a distância de correlação ($L0$) dessas flutuações e a velocidade e direção de migração das irregularidades ionosféricas. O coeficiente de correlação varia de acordo com as condições locais, considerando as características das diferentes camadas da ionosfera. A velocidade e direção de migração são derivadas a partir do padrão de difração dos sinais de rádio.

O GISM possui um submodelo avançado que utiliza o modelo NeQuick (RADICELLA, 2009) para calcular a densidade eletrônica média (latitude, longitude e altitude) de pontos da ionosfera. Esse modelo depende de parâmetros como ano, dia do ano, hora local e fluxo solar. Os parâmetros geomagnéticos também são calculados com base em um modelo harmônico esférico do campo magnético terrestre, que fornece a inclinação, declinação e intensidade vertical do campo magnético.

O algoritmo que calcula as cintilações e os erros médios no valor do TEC é baseado em uma técnica que divide a ionosfera em camadas perpendiculares ao eixo de propagação, chamadas de janelas. Cada janela é caracterizada por propriedades estatísticas homogêneas. A **Figura 28** mostra algumas das opções de saída que o GISM oferece, como gráficos e mapas de cintilação.

Figura 28 - Exemplos do GISM.



Fonte: IEEA - Theoretical Studies in Electromagnetism (2010).