



# Aplicação de SVM para a previsão de ocorrência de cintilação ionosférica

Otávio Carvalho<sup>1</sup>, Alex Oliveira Barradas Filho<sup>2</sup>

<sup>1</sup> Universidade Federal do Maranhão, São Luís, MA, Brasil  
Mestrando do programa de Pós-graduação em Engenharia Aeroespacial,  
Rede Nordeste Aeroespacial, polo Maranhão

<sup>2</sup> Universidade Federal do Maranhão, São Luís, MA, Brasil  
Programa de Pós-graduação em Engenharia Aeroespacial,  
Rede Nordeste Aeroespacial, polo Maranhão

otavio.carvalho@darti.ufma.br

---

**Resumo.** *A cintilação ionosférica é um fenômeno que impacta diretamente as comunicações por satélites, os sistemas de telecomunicação e as aplicações baseadas em sinais GNSS. No Brasil, a camada ionosférica é considerada um ponto crítico e requer estudos que permitam o monitoramento e a previsão da ocorrência de cintilação. Nesse trabalho, aborda-se tal problema pela aplicação de técnicas de aprendizagem de máquina. Para tanto, os autores utilizam dados de receptores GNSS disponíveis no Brasil para a construção e avaliação de modelos preditivos da ocorrência de cintilação ionosférica. Ademais, o desempenho dos modelos obtidos foi contextualizado com informações encontradas na literatura.*

---

**Palavras-chave:** Cintilação ionosférica; Aprendizagem de máquina; SVM.

## 1. Introdução

A ionosfera terrestre é uma das camadas da atmosfera localizada entre 80 e 1.000 km de altura [Hagfors and Schlegel 2001], a qual contém elétrons livres que impactam diretamente na propagação de ondas de rádio que trafegam pela camada [Matsuoka et al. 2009]. Em geral, todas as comunicações de rádio frequência que transitam pela camada ionosférica são afetadas, principalmente em baixas frequências, o que resulta na degradação do desempenho de sistemas dependentes de tais tecnologias [Cannon 2009].

Nesse contexto, variações rápidas de fase e amplitude observadas quando ondas de rádio trafegam por irregularidades na densidade do plasma ionosférico são conhecidas como cintilação ionosférica [Conker et al. 2003]. De forma mais específica, a cintilação ionosférica impacta diretamente e negativamente na performance de sistemas de comunicações por satélites, sistemas de telecomunicações e aplicações baseadas no Sistema Global de Navegação por Satélite (GNSS) [He et al. 2016, Kintner et al. 2007, Rezende et al. 2010].

No Brasil, a camada ionosférica é um ponto crítico e requer estudos que permitam o monitoramento e a previsão da ocorrência de cintilação ionosférica, pois o país está localizado em uma das áreas mais afetadas por tal fenômeno [Vani et al. 2017]. Ademais, a Agência



Espacial Brasileira indica como prioridade, dentre as demandas do setor espacial, o tratamento das interferências ionosféricas que afetam a transmissão de sinais de satélites no país [Onohara et al. 2019].

No entanto, a modelagem matemática da cintilação ionosférica apresenta uma natureza complexa devido às inúmeras causas do fenômeno (atividade solar, tempestades magnéticas, campos elétricos locais, condutividade do meio, entre outros agentes) [Liu et al. 2018]. Na literatura, encontra-se a aplicação de técnicas de aprendizagem de máquina como alternativa para o desenvolvimento de modelos preditivos da ocorrência de cintilação ionosférica [Sridhar et al. 2017], [McGranaghan et al. 2018], [Liu et al. 2018] e [Linty et al. 2018].

Dessa forma, os autores possuem como objetivos a aplicação do método máquina de vetores de suporte (SVM, do inglês: *support vector machine*) para a construção do modelo preditivo e a contextualização dos resultados obtidos com trabalhos da literatura, além de demonstrar a viabilidade do uso de tal abordagem no contexto nacional.

## 2. Metodologia

A base de dados utilizada na pesquisa foi obtida pelo software *Web ISMR Query Tool*, a ferramenta permite a análise e a coleta de dados referentes à cintilação ionosférica de diferentes redes de estações de monitoramento [Vani et al. 2017]. No entanto, os autores extraíram os dados de apenas duas regiões de coleta, São Luís - MA (2,52°S, 44.3°W) e Presidente Prudente - SP (22,1°S, 51,4°W).

No primeiro caso, a região é localizada próxima ao Equador Magnético e em uma região equatorial, onde a ocorrência de eventos intensos de cintilação é comum [de Lima et al. 2015, de O. Moraes et al. 2017]. No segundo caso, a região é localizada próxima ao pico da anomalia de ionização equatorial, onde também há ocorrência de eventos extremos de cintilação ionosféricas [de O. Moraes et al. 2018, Rezende et al. 2010].

O intervalo de tempo considerado para a extração dos dados foi de 01/11/2014 a 30/03/2015, o qual corresponde ao período do atual ciclo solar em que os receptores GNSS são afetados por uma maior interferência da cintilação ionosférica [de O. Moraes et al. 2018, Taylor et al. 2012]. A frequência considerada durante a pesquisa foi a L1 (1575,42 MHz) e os dados possuem informações de satélites das constelações GALILEO, GLONASS, GPS e SBAS [Vani et al. 2017]. O código utilizado está disponível em <https://github.com/OtavioCarvalho1/WETE-code>.

### 2.1. Preparo das amostras

A primeira etapa da preparação dos dados consiste em verificar se as amostras atendiam aos seguintes critérios: *Lock time* > 60 segundos [de O. Moraes et al. 2017] e ângulo de elevação  $\theta_{elev} > 30^\circ$  [de O. Moraes et al. 2017, Linty et al. 2018]. Posteriormente, as amostras aptas para o pré-processamento foram submetidas às seguintes ações:

1. Filtrar os dados de acordo com a constelação de cada satélite.
2. Corrigir o índice  $S_4$  devido ao ruído ambiente [Cokrljic et al. 2012, Van Dierendonck et al. 1993].

$$S_4 = \begin{cases} \sqrt{[S_4^T]^2 - [S_4(N_0)]^2} & \text{se } [S_4^T]^2 - [S_4(N_0)]^2 > 0 \\ 0 & \text{se } [S_4^T]^2 - [S_4(N_0)]^2 \leq 0 \end{cases} \quad (1)$$

Onde as parcelas  $S_4^T$  e  $S_4(N_0)$  são fornecidas na base de dados coletada.



3. Realizar a projeção do índice  $S_4$  na direção vertical usando a equação (2) a fim de levar em consideração efeitos geométricos variáveis relacionados às medições feitas em diferentes ângulos de elevação [Spogli et al. 2013, Alfonsi et al. 2013].

$$S_4^{\text{vert}} = \frac{S_4^{\text{slant}}}{F^a} \quad (2)$$

Onde  $a = (p + 1)/4$ , com  $p$  sendo a inclinação espectral de fase. Nos casos em que  $p$  não esteja disponível,  $a = 0,9$  [Spogli et al. 2013, Alfonsi et al. 2013]. O termo  $F$  é dado na equação (3) [Mannucci et al. 1993].

$$F = \frac{1}{\sqrt{1 - \left(\frac{R_E \cos \theta_{elev}}{R_E + H_{IPP}}\right)^2}} \quad (3)$$

Onde  $R_E$  é o raio da Terra,  $\theta_{elev}$  é o ângulo de elevação do satélite e  $H_{IPP}$  é a altura do ponto de perfuração ionosférica. Neste trabalho  $R_E = 6378,137$  km [Williams 2020] e  $H_{IPP} = 350$  km [Spogli et al. 2013].

4. Tomar a mediana dos sinais dos satélites pertencentes a uma constelação específica em um dado instante de tempo [McGranaghan et al. 2018].

Ressalta-se que a ocorrência de cintilação ionosférica é dada quando  $S_4^{\text{vert}} > 0,1$  [Spogli et al. 2013]. No entanto, a base de dados gerada inicialmente era desbalanceada para o desenvolvimento adequado do modelo de classificação, entre a ocorrência de cintilação ionosférica (C) e a não ocorrência de cintilação ionosférica (NC). Dessa forma, para contornar o problema de desbalanceamento da base de dados foi aplicado o método *Synthetic Minority Over-sampling Technique* (SMOTE) que consiste na criação de amostras sintéticas na classe minoritária [Chawla et al. 2002], nessa etapa usou-se a biblioteca *imblearn* descrita em [Lemaître et al. 2017].

Em seguida, a divisão da base de dados para a etapa de treinamento do modelo foi realizada pelo método de validação cruzada  $k$ -fold estratificado, para  $k = 10$ , onde as amostras foram distribuídas aleatoriamente em dez partições criadas com aproximadamente a mesma quantidade de amostras e respeitando a relação entre as classes consideradas, em seguida o algoritmo foi treinado usando 9 partições e testado naquela não empregada na etapa de obtenção do modelo.

## 2.2. Classificador SVM

O modelo SVM foi aplicado para a classificação das classes C e NC, os parâmetros utilizados como entradas foram  $S_4^{\text{vert}}$ ,  $C/N_0$  e  $\theta_{elev}$ , onde  $C/N_0$  representa a razão sinal-ruído do sinal [Linty et al. 2018]. Para o desenvolvimento do método SVM e determinação dos hiperparâmetros foi utilizada a biblioteca *Scikit-learn* do Python. A Tabela 1 mostra os parâmetros e configurações utilizados no desenvolvimento do modelo.

**Tabela 1. Parâmetros dos modelo**

Kernel	Fórmula	Parâmetros do kernel
Função de base radial	$\exp(-\gamma \ x - x'\ ^2)$	$\gamma = 'scale'$

Na Tabela 1 a expressão  $\|x - x'\|$  denota a norma euclidiana.



### 2.3. Medidas de desempenho

Após o desenvolvimento do modelo classificador SVM, as medidas acurácia, precisão, sensibilidade, especificidade e medida F1 foram utilizadas para a avaliação dos resultados. A Equação de cada medida pode ser visualizada abaixo.

$$\text{Acurácia} = \frac{VP + VN}{VP + VN + FP + FN} \quad (4)$$

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (5)$$

$$\text{Sensitividade} = \frac{VP}{VP + FN} \quad (6)$$

$$\text{Especificidade} = \frac{VN}{VN + FP} \quad (7)$$

$$\text{Medida F1} = \frac{2 \cdot \text{Precisão} \cdot \text{Sensitividade}}{\text{Precisão} + \text{Sensitividade}} \quad (8)$$

Onde  $VP$  = Verdadeiros Positivos,  $VN$  = Verdadeiros Negativos,  $FP$  = Falsos Positivos e  $FN$  = Falsos Negativos.

### 3. Resultados e Discussão

Os resultados obtidos por meio da metodologia aplicada para lidar com o desbalanceamento de classes estão sumarizados na Figura 1.

Na parte inferior da Figura 1 é possível observar a quantidade de amostras pertencentes a cada classe, obtidas após a realização das etapas descritas na metodologia. Nota-se que o desbalanceamento de classes foi bastante reduzido, uma vez que antes de realizar a preparação das amostras havia uma proporção de aproximadamente 9 : 1 em relação às classes NC e C, alterando-se para 2 : 1 após o procedimento adotado.

Os resultados obtidos estão sumarizados na Tabela 2.

**Tabela 2. Métricas de avaliação dos algoritmos**

Base de dados	Acurácia	Precisão	Sensitividade	Especificidade	Medida F1
GALILEO	0,9971	0,9917	0,9999	0,9958	0,9958
GLONASS	0,9977	0,9932	1,0000	0,9966	0,9966
GPS	0,9979	0,9936	1,0000	0,9967	0,9968
SBAS	0,9976	0,9929	1,0000	0,9964	0,9964
[Linty et al. 2018]	0,9260	1,0000	0,8455	1,0000	0,9163

Analisando a Tabela 2 nota-se que os algoritmos tiveram desempenhos semelhantes. Em especial, os modelos apresentam um bom nível de sensibilidade, indicando que a maioria das amostras pertencentes à classe C foi classificada corretamente pelo modelo usado, nota-se também um nível satisfatório de especificidade indicando que o modelo obtido teve um bom desempenho na classificação das amostras da classe NC. Além disso os valores de precisão e acurácia também se mostram satisfatórios.

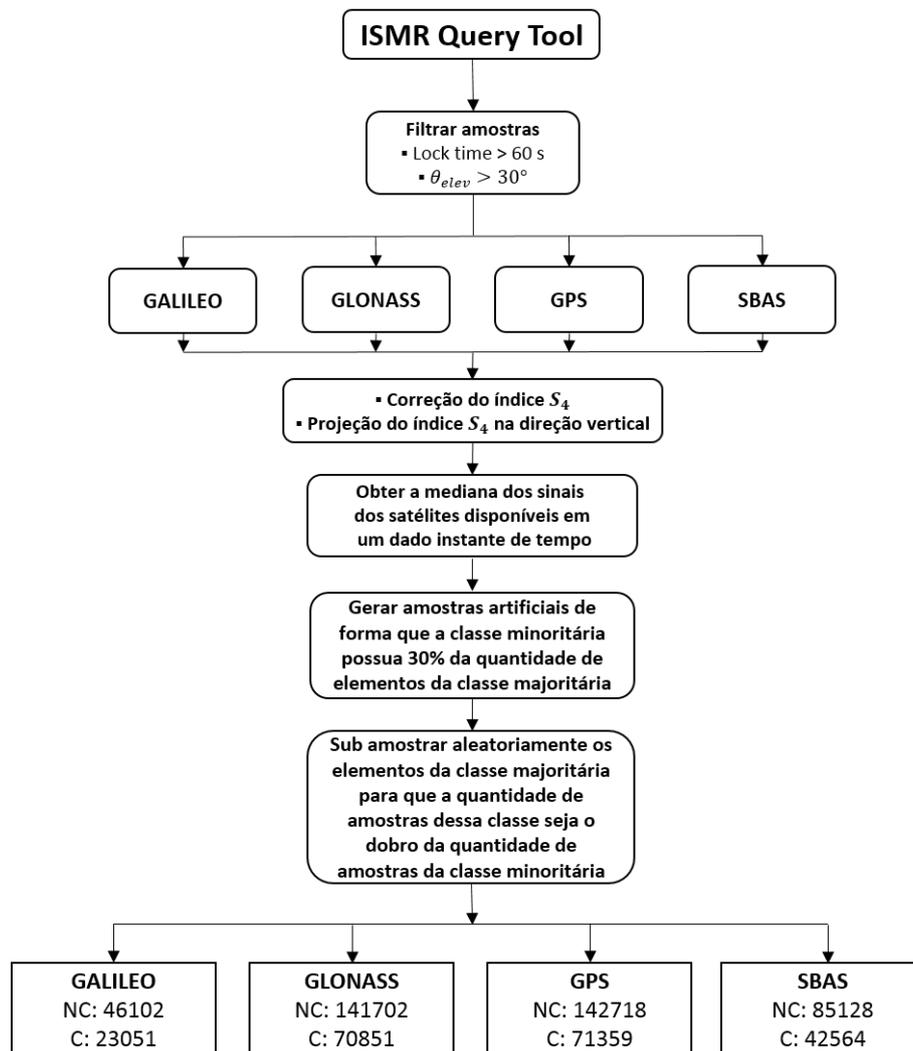


Figura 1. Resultados obtidos por meio da preparação das amostras

Em relação aos resultados obtidos em [Linty et al. 2018] sumarizados na Tabela 2, é necessário ressaltar que não é possível fazer uma comparação direta com os resultados dos modelos desenvolvidos neste trabalho, uma vez que as bases de dados usadas são diferentes, mas nota-se que os resultados obtidos são semelhantes, demonstrando a aplicabilidade da metodologia empregada.

Diante dos fatos discutidos nota-se que a abordagem usada se mostrou válida, pois foi possível obter um desempenho satisfatório a partir do algoritmo empregado, demonstrando a possibilidade de usar métodos de aprendizagem de máquina a partir da infraestrutura já instalada no Brasil. Além disso, dentro do escopo analisado neste trabalho, não foi possível apontar uma diferença considerável entre os resultados obtidos com dados de diferentes constelações.

#### 4. Conclusão

Em vista dos argumentos apresentados é possível considerar que os objetivos propostos inicialmente foram alcançados pois, verificou-se a aplicabilidade da metodologia empregada, apesar de não ser possível uma comparação direta com os resultados observados na literatura, devido aos diferentes contextos de aplicação. No escopo deste trabalho, não foi possível identificar diferenças significativas nos resultados obtidos com bases de dados relacionadas a diferentes



constelações de satélite.

**Agradecimentos:** Os autores agradecem à Universidade Federal do Maranhão e ao Programa de Pós-graduação em Engenharia Aeroespacial, Rede Nordeste Aeroespacial, polo Maranhão, pela estrutura usada. Além disso, os autores agradecem pelo uso dos dados provenientes da rede CIGALA/CALIBRA. Estações de monitoramento da rede foram implantadas no contexto dos Projetos CIGALA e CALIBRA, ambos financiados pela Comissão Europeia (CE) no âmbito do FP7-GALILEO-2009-GSA e FP7-GALILEO-2011-GSA-1a, respectivamente, e Projeto FAPESP Número 06 / 04008-2.

## Referências

- Alfonsi, L., Spogli, L., Pezzopane, M., Romano, V., Zuccheretti, E., De Franceschi, G., Cabrera, M., and Ezquer, R. (2013). Comparative analysis of spread-f signature and gps scintillation occurrences at tucumán, argentina. *Journal of Geophysical Research: Space Physics*, 118(7):4483–4502.
- Cannon, P. S. (2009). Mitigation and exploitation of the ionosphere: A military perspective. *Radio Science*, 44(01):1–8.
- Chawla, N. V., Bowyer, K. W., Hall, L. O., and Kegelmeyer, W. P. (2002). Smote: synthetic minority over-sampling technique. *Journal of artificial intelligence research*, 16:321–357.
- Cokrljic, M., Wezka, K., Galas, R., and Jakowski, N. (2012). Ionospheric scintillation monitoring in a single station mode.
- Conker, R. S., El-Arini, M. B., Hegarty, C. J., and Hsiao, T. (2003). Modeling the effects of ionospheric scintillation on gps/satellite-based augmentation system availability. *Radio Science*, 38(1):1–1.
- de Lima, G. R. T., Stephany, S., de Paula, E. R., Batista, I. S., and Abdu, M. A. (2015). Prediction of the level of ionospheric scintillation at equatorial latitudes in brazil using a neural network. *Space Weather*, 13(8):446–457.
- de O. Moraes, A., Costa, E., Abdu, M. A., Rodrigues, F. S., de Paula, E. R., Oliveira, K., and Perrella, W. J. (2017). The variability of low-latitude ionospheric amplitude and phase scintillation detected by a triple-frequency gps receiver. *Radio Science*, 52(4):439–460.
- de O. Moraes, A., Vani, B. C., Costa, E., Sousasantos, J., Abdu, M. A., Rodrigues, F., Gladek, Y. C., de Oliveira, C. B. A., and Monico, J. F. G. (2018). Ionospheric scintillation fading coefficients for the gps 11, 12, and 15 frequencies. *Radio Science*, 53(9):1165–1174.
- Hagfors, T. and Schlegel, K. (2001). Earth’s ionosphere. In *The Century of Space Science*, pages 1559–1584. Springer.
- He, Z., Zhao, H., and Feng, W. (2016). The ionospheric scintillation effects on the beidou signal receiver. *Sensors*, 16(11):1883.
- Kintner, P. M., Ledvina, B. M., and De Paula, E. (2007). Gps and ionospheric scintillations. *Space weather*, 5(9).
- Lemaître, G., Nogueira, F., and Aridas, C. K. (2017). Imbalanced-learn: A python toolbox to tackle the curse of imbalanced datasets in machine learning. *Journal of Machine Learning Research*, 18(17):1–5.
- Linty, N., Farasin, A., Favenza, A., and Dovis, F. (2018). Detection of gnss ionospheric scintillations based on machine learning decision tree. *IEEE Transactions on Aerospace and Electronic Systems*, 55(1):303–317.



- Liu, Y. L., Morton, Y. J., and Jiao, Y. J. (2018). Application of machine learning to the characterization of gps ll ionospheric amplitude scintillation. In *2018 IEEE/ION Position, Location and Navigation Symposium (PLANS)*, pages 1159–1166. IEEE.
- Mannucci, A. J., Wilson, B. D., and Edwards, C. D. (1993). A new method for monitoring the earth's ionospheric total electron content using the gps global network.
- Matsuoka, M. T., Camargo, P. d. O., and Batista, I. S. (2009). Análise da ionosfera usando dados de receptores gps durante um período de alta atividade solar e comparação com dados de digissondas. *Revista Brasileira de Geofísica*, 27(4):565–582.
- McGranaghan, R. M., Mannucci, A. J., Wilson, B., Mattmann, C. A., and Chadwick, R. (2018). New capabilities for prediction of high-latitude ionospheric scintillation: A novel approach with machine learning. *Space Weather*, 16(11):1817–1846.
- Onohara, A. N., de Lima, F. L. L. U., de Oliveira, G. F., de Macedo Rego, G. S. M., de Souza, I. T., Harada, M. A., and Toledo, R. (2019). *Demandas nacionais do setor espacial*. Disponível: <http://mtc-m21c.sid.inpe.br/col/sid.inpe.br/mtc-m21c/2019/09.18.19.23/doc/Demandas%20Nacionais%20ao%20Setor%20Espacial%202019.pdf>. Acesso: 03/07/2020.
- Rezende, L., de Paula, E., Stephany, S., Kantor, I., Muella, M., de Siqueira, P., and Correa, K. (2010). Survey and prediction of the ionospheric scintillation using data mining techniques. *Space Weather*, 8(6).
- Spogli, L., Alfonsi, L., Romano, V., De Franceschi, G., Francisco, G. M. J., Shimabukuro, M. H., Bougard, B., and Aquino, M. (2013). Assessing the gnss scintillation climate over brazil under increasing solar activity. *Journal of Atmospheric and Solar-Terrestrial Physics*, 105:199–206.
- Sridhar, M., Ratnam, D. V., Raju, K. P., Praharsa, D. S., and Saathvika, K. (2017). Ionospheric scintillation forecasting model based on nn-pso technique. *Astrophysics and Space Science*, 362(9):166.
- Taylor, S., Morton, Y., Jiao, Y., Triplett, J., and Pelgrum, W. (2012). An improved ionosphere scintillation event detection and automatic trigger for gnss data collection systems. *Proc. ION ITM*, pages 1563–1569.
- Van Dierendonck, A., Klobuchar, J., and Hua, Q. (1993). Ionospheric scintillation monitoring using commercial single frequency c/a code receivers. In *proceedings of ION GPS*, volume 93, pages 1333–1342.
- Vani, B. C., Shimabukuro, M. H., and Monico, J. F. G. (2017). Visual exploration and analysis of ionospheric scintillation monitoring data: the ismr query tool. *Computers & Geosciences*, 104:125–134.
- Williams, D. R. (2020). *Earth Fact Sheet*. Disponível: <https://nssdc.gsfc.nasa.gov/planetary/factsheet/earthfact.html>. Acesso: 03/07/2020.