

Application of Kohonen Self-Organizing Map for Clustering Negative Cloud-to-Ground Lightning Electric Field Waveforms

Elton Rafael Alves and Adônis Ferreira Raiol Leal

Abstract—Lightning electric field (E-field) waveforms are widely used in understanding the physical processes that take place during different lightning events and for improving engineering return-stroke models that helps the design of better lightning protection systems. The Lightning Detection and Waveform Storage System (LDWSS) is a low cost system that record relatively wideband E-fields of lightning. In this work we use the Kohonen self-organizing map for clustering electric field waveforms of negative cloud-to-ground lightning (-CGs) recorded by the LDWSS. This approach allowed us to determine a standard/typical E-field waveform for distinct range of distance. The data was splitted into two subsets, one for events recorded under daytime conditions and other for events recorded at nighttime. The results showed that it is possible to identify twenty-five standard/typical E-field waveforms of -CGs, being 15 groups of waveforms that occurred during daytime and 10 groups that occurred at nighttime conditions

Index Terms—Lightning, lightning detection, LDWSS and Kohonen self-organizing map..

I. INTRODUÇÃO

Uma descarga atmosférica ou raio pode ser definida como um transiente eletromagnético de alta corrente (geralmente dezenas de quiloampères) que atravessa o ar, transferindo cargas entre a atmosfera e à Terra ou entre diferentes partes da atmosfera. A principal fonte de raios no planeta Terra são as nuvens denominadas *cumulonimbus* ou simplesmente nuvens de tempestade.

A ocorrência de um raio envolve a criação de um canal ionizado (plasma) carregando dezenas de quiloampères de corrente elétrica que pode atingir uma temperatura de 30.000° K. Devido a essa característica, pode tornar-se uma ameaça para diversos serviços - como aviação, transmissão e distribuição de energia elétrica, sistemas de telecomunicações e até mesmo para a vida humana. Por outro lado, a ocorrência de raios influencia no balanço global de NO_x (Óxidos de nitrogênio, como NO e NO₂) controlando grandemente a quantidade de ozônio na atmosfera [1].

Os tipos de raios mais relatados são: nuvem-solo, intra-nuvem, nuvem-nuvem e nuvem-ar. Os raios nuvem-solo são classificados em 4 subgrupos: raios negativos descendentes, raios negativos ascendentes, raios positivos descendentes e

raios positivos ascendentes. Cerca de 90% dos raios nuvem-solo são raios negativos descendentes. Neles, cargas negativas são efetivamente transportadas para o solo, e seu processo se inicia na nuvem, se desenvolvendo até o solo [1].

O *Lightning Detection and Waveform Storage System* (LDWSS) é um sistema que permite o registro da componente vertical do campo elétrico radiado por um raio, permitindo analisar uma determinada descarga atmosférica. Além disso, em sua versão mais recente, possui um maior alcance dinâmico de detecção, possibilitando detectar e armazenar formas de onda de campos elétricos distantes e próximos, radiados por descargas atmosféricas [2], [3].

A região amazônica, no Brasil, possui uma carência de sistemas de monitoramento de descargas atmosféricas. Os únicos sistemas que conseguem monitorar a atividade elétrica na Amazônia são de longo alcance, ou seja, tem baixa eficiência de localização e detecção. Assim, o LDWSS se apresenta como uma alternativa para complementar os dados de raios na região amazônica.

As formas de onda dos campos elétricos radiados por descargas atmosféricas são diferentes para distâncias distintas de observação. O campo elétrico radiado por um raio é dividido em componentes eletrostática, de indução e de radiação, sendo que cada uma dessas componentes decai de forma diferente com a distância [4]. Para curtas distâncias, a componente predominante é a eletrostática e, para longas distâncias (maiores que 50 km), a componente predominante é a radiação. Além disso, o perfil da forma de onda do campo elétrico de um raio também varia de acordo com o período de observação (diurno e noturno). Isso ocorre para raios observados a longas distâncias (maiores que 50 km), pois a propagação do sinal eletromagnético ocorre dentro da cavidade formada pela terra e a ionosfera. O sinal sofre reflexões na ionosfera até chegar no sensor, e essas reflexões são diferentes de dia e de noite devido às propriedades elétricas da ionosfera [5], [6], [7], [8].

Lin et al. [9] apresentaram um dos primeiros trabalhos relacionados às formas de onda dos campos eletromagnéticos gerados por raios, associando com a distância entre o ponto de observação e o local de ocorrência da descarga. A Fig. 1 exibe formas de onda típicas do campo elétrico radiado por raios nuvem-solo negativos registrados a diferentes distâncias. Lin et al. [9] observaram que, quanto mais distante o raio ocorria em relação ao ponto de observação, mais reflexões eram observadas nas formas de onda dos campos elétricos.

Bermúdez et al. [10] apresentaram a utilização de Mapa

Elton Rafael Alves é professor da Faculdade de Computação e Engenharia Elétrica da Universidade Federal do Sul e Sudeste do Pará, Marabá, Pará, Brasil, e-mail: eltonalves@unifesspa.edu.br

Adônis Ferreira Raiol Leal é professor da Faculdade de Engenharia Elétrica e Biomédica da Universidade Federal do Pará, Belém, Pará, Brasil, e-mail: adonisleal@ufpa.br

Auto-Organizável de Kohonen (KSOM) para reconhecer e classificar raios, a partir de formas de onda de campos elétricos registrados na Suíça pelo *Lightning Positioning and Tracking System* (LPATS). Recentemente, Mostajabi et al. [11] combinaram o método de Reversão de Tempo Eletromagnético e Redes Neurais Profundas para localização de raios. Karami et al. [12] apresentam uma análise baseada em aprendizado de máquina para localizar raios através de cálculos de tensões induzidas por raios em linhas de transmissão de energia elétrica.

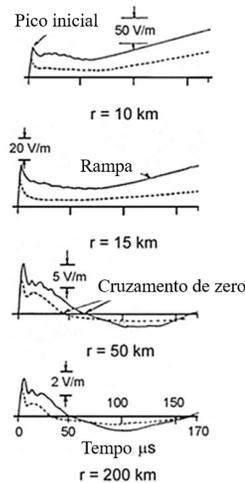


Fig. 1. Formas de onda típicas do campo elétrico radiado por raios nuvem-solo negativos registrados a 10 km, 15 km, 50 km e 200 km de distância, mostradas em uma janela de 170 microssegundos. A linha sólida representa a primeira descarga de retorno e a linha pontilhada as descargas subsequentes. Adaptado de [9].

Algoritmos inteligentes podem ser utilizados para agrupar dados de entrada que são semelhantes entre si, formando classes que são chamadas de *clusters*. Mapa Auto-Organizado de Kohonen é um método de aprendizado não supervisionado que pode ser aplicado para agrupar dados de entrada de alta dimensão, permitindo conduzir uma investigação completa sobre o espaço de entrada de alta dimensionalidade [13], [14].

Um método baseado no KSOM é apresentado neste artigo para agrupar formas de onda de campos elétricos radiados por raios nuvem-solo negativos obtidos através do LDWSS. Esse método não supervisionado foi implementado com objetivo de identificar automaticamente as semelhanças entre formas de onda dos campos elétricos de raios nuvem-solo negativos. A partir da identificação dessas semelhanças, diferentes *clusters* de formas de onda serão criados. Para cada *cluster* será investigado a variação da distância de ocorrência dos eventos. A principal contribuição deste trabalho é gerar uma forma de onda padrão para cada *cluster*, onde essa forma de onda está diretamente relacionada a um intervalo de distância de ocorrência de raios nuvem-solo negativos. As formas de onda padrão podem então ser aplicadas na validação de sistemas de detecção de raios, ou em sistemas de localização de descargas atmosféricas.

II. FUNDAMENTAÇÃO TEÓRICA

A. Lightning Detection and Waveform Storage System (LDWSS)

O LDWSS consiste em um sistema otimizado de registro de formas de onda de campos elétricos radiados por raios. Seu elemento sensor é uma antena *whip* que, associado a um circuito integrador, mede a componente vertical do campo elétrico radiado por um raio.

O sistema registra um evento com base no limiar da amplitude do sinal digitalizado e, caso seja detectada a ultrapassagem desse limiar, o sistema armazena (digitaliza) uma janela de 4 ms ou 5 ms (4000 ou 5000 amostras) no *buffer* de memória. Para cada janela, o sistema gera uma estampa de tempo. A base de tempo do sistema é composta por um RTC (relógio de tempo real), que por sua vez, é sincronizado por um módulo GPS. Quando o *buffer* de memória atinge o limite de cinco janelas, uma ação de transferência de dados é iniciada. O microcontrolador transfere os dados para um computador através de uma interface serial/USB. Mais detalhes sobre o LDWSS podem ser encontrados em [2], [3].

B. Mapa Auto-Organizado de Kohonen – KSOM

A rede de Kohonen faz parte de um grupo especial de redes neurais artificiais conhecidas como mapas auto-organizáveis [13], [14]. Estes mapas são baseados na aprendizagem competitiva, onde os neurônios de saída da grade competem entre si para serem ativados. O neurônio que vence a competição é denominado de neurônio vencedor. A Fig. 2 apresenta o modelo do mapa auto-organizado de Kohonen.

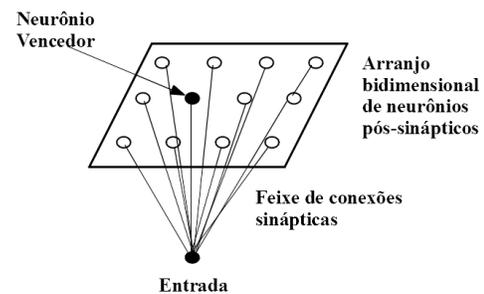


Fig. 2. Modelo do Mapa Auto-Organizado de Kohonen.

No modelo de Kohonen, os neurônios estão localizados em nós de uma grade, que geralmente possui uma ou duas dimensões. A grade procura estabelecer e preservar noções de vizinhança (preservação topológica). Durante o processo de aprendizado, é formado um mapa topográfico dos padrões de entradas. Neste mapa, as localizações espaciais dos neurônios nas grades são indicativas das características contidas nos padrões de entradas. Outra característica importante deste tipo de rede, é que elas utilizam treinamento não supervisionado. Neste tipo de treinamento, a rede busca encontrar similaridades baseando-se apenas nos padrões de entrada.

Para a formação do mapa auto-organizado de Kohonen, três processos essenciais estão envolvidos:

- 1) **Competição:** os neurônios da camada de saída competem entre si. Geralmente se utiliza a distância

euclidiana para encontrar um único neurônio vencedor. Utiliza-se o cálculo da função discriminante de cada neurônio da grade para um padrão de entrada.

- 2) **Cooperação:** o neurônio vencedor define sua vizinhança topológica determinando a base para a cooperação entre neurônios vizinhos
- 3) **Adaptação:** os vetores de código do neurônio vencedor e de sua vizinhança são ajustados, permitindo que os neurônios excitados aumentem seus valores individuais de função discriminante em relação ao padrão de entrada, através dos ajustes aplicados aos pesos sinápticos.

III. MATERIAIS E MÉTODOS

Este estudo proposto ficou dividido em três fases: obtenção e pré-processamento dos dados, treinamento do mapa auto-organizado de Kohonen e determinação da forma de onda padrão para cada *cluster*.

A. Fonte de Dados – LDWSS

Todas as formas de onda de campos elétricos gerados por raios utilizados nesse estudo foram obtidas pela estação LDWSS-UF, instalada no *Lightning observatory in Gainesville* (LOG), que pertence à Universidade da Flórida [15]. Os dados registrados por essa estação puderam ser comparados com os dados de uma rede de localização de raios de precisão, a *National Lightning Detection Network* (NLDN). A NLDN é constantemente avaliada e calibrada por autoridades Norte Americanas, principalmente utilizando raios trigados, seu erro de localização é inferior a 350 m [16]. A partir da comparação das estampas temporais da NLDN e do LDWSS, foi obtida a distância de ocorrência para cada forma de onda. A base de dados utilizada nesse trabalho é composta por um total de 6.597 eventos (dia e noite).

B. Pré-Processamento

Primeiramente, através de inspeção manual, as formas de onda de campo elétrico referente a raios nuvem-solo negativos foram separadas da base de dados principal do LDWSS. Em seguida todas as formas de onda foram alinhadas de modo que o pico inicial referente a descarga de retorno ficasse em 100 microssegundos. O próximo passo foi a normalização das formas de onda. Este processo foi utilizado com o objetivo de facilitar a comparação e identificação de padrões semelhantes. Sendo assim, todos os valores de pico das formas de onda, foram estabelecidos como 1. Essa normalização facilitou o aprendizado da rede KSOM.

Após a normalização, os dados foram separados de acordo com o horário em que ocorreram: foram 5.217 eventos durante o dia e 1.380 durante a noite. Para eliminar a presença de ruídos entre os eventos, utilizou-se um filtro digital passa-baixas com frequência de corte igual a 50 kHz. A Fig. 3 exhibe exemplos de formas de onda de campos elétricos de eventos que ocorreram durante o dia e a noite, para uma distância de 487 km, sendo a imagem superior, forma de onda (dia e noite) antes de serem filtradas e a imagem inferior, forma de onda (dia e noite) após serem filtradas.

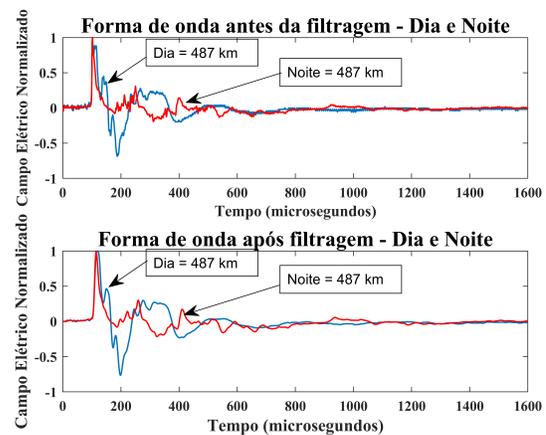


Fig. 3. Comparação entre formas de onda de campos elétricos de raios negativos (antes da filtragem e após a filtragem) que ocorreram durante o dia e noite, para uma distância de 487 km.

C. Aplicação do KSOM

Neste trabalho, o mapa Auto-Organizável de Kohonen foi utilizado para a definição dos agrupamentos e das distâncias de incidência dos raios nuvem-solo negativos. A literatura apresenta uma grande variedade de algoritmos de clusterização, dentre os quais se destacam: K-Means [17], Ward [17], FCM – *Fuzzy Clustering Method* [18] e o mapa auto-organizado de Kohonen [13]. O mapa de Kohonen é capaz de aliar a análise de agrupamento com uma representação gráfica para visualização das distâncias.

O programa para treinamento e simulação da rede KSOM foi o Matlab®. O treinamento dos dados de entrada foi realizado através do algoritmo *batch*, no qual todo conjunto de dados de entrada é apresentado ao mapa antes de qualquer ajuste. Além disso a função de limitação dos neurônios vizinhos usada para treinamento foi a hexagonal. Foram realizados diversos treinamentos com diferentes dimensões de matrizes do KSOM para encontrar a melhor resolução do mapa, permitindo assim uma maior precisão do mapa para os dados de entrada. Utilizou-se no processo de competição a distância Euclidiana.

O critério de parada de treinamento do KSOM adotado é dado em [19]:

- **Fase de Ordenação** = 1000 iterações;
- **Fase de convergência** = número de iterações no mínimo 500 vezes o número de neurônios da grade.

Dessa forma, garante-se que no processo cooperativo o raio da vizinhança diminua até o valor correspondente a um neurônio em torno do neurônio vencedor.

D. Determinação da Forma de Onda Padrão para cada Cluster.

A Fig. 4 resume os processos envolvidos na determinação da forma de onda padrão para um determinado *cluster*. Após o processo de formação dos *clusters*, a partir do emprego do KSOM nas formas de onda de campos elétricos de raios nuvem-solo negativos (fonte de dados), calculou-se a média aritmética da distância de ocorrência para cada *cluster* e o

desvio padrão. Ressalta-se que as formas de onda dos campos elétricos registrados variam com a distância entre o sensor e o local de ocorrência dos raios. Em seguida, obteve-se a média aritmética para cada instante de tempo da janela de 1600 microssegundos de todos os eventos em cada *cluster*, determinado, assim, a forma de onda média para cada *cluster*. Essa forma de onda média foi denominada de forma da onda padrão de cada *cluster*.

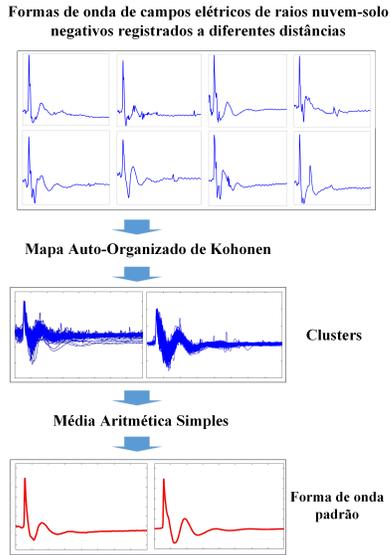


Fig. 4. Processos envolvidos na determinação das formas de onda padrão para diferentes distâncias de ocorrência de raios nuvem-solo negativos descendentes.

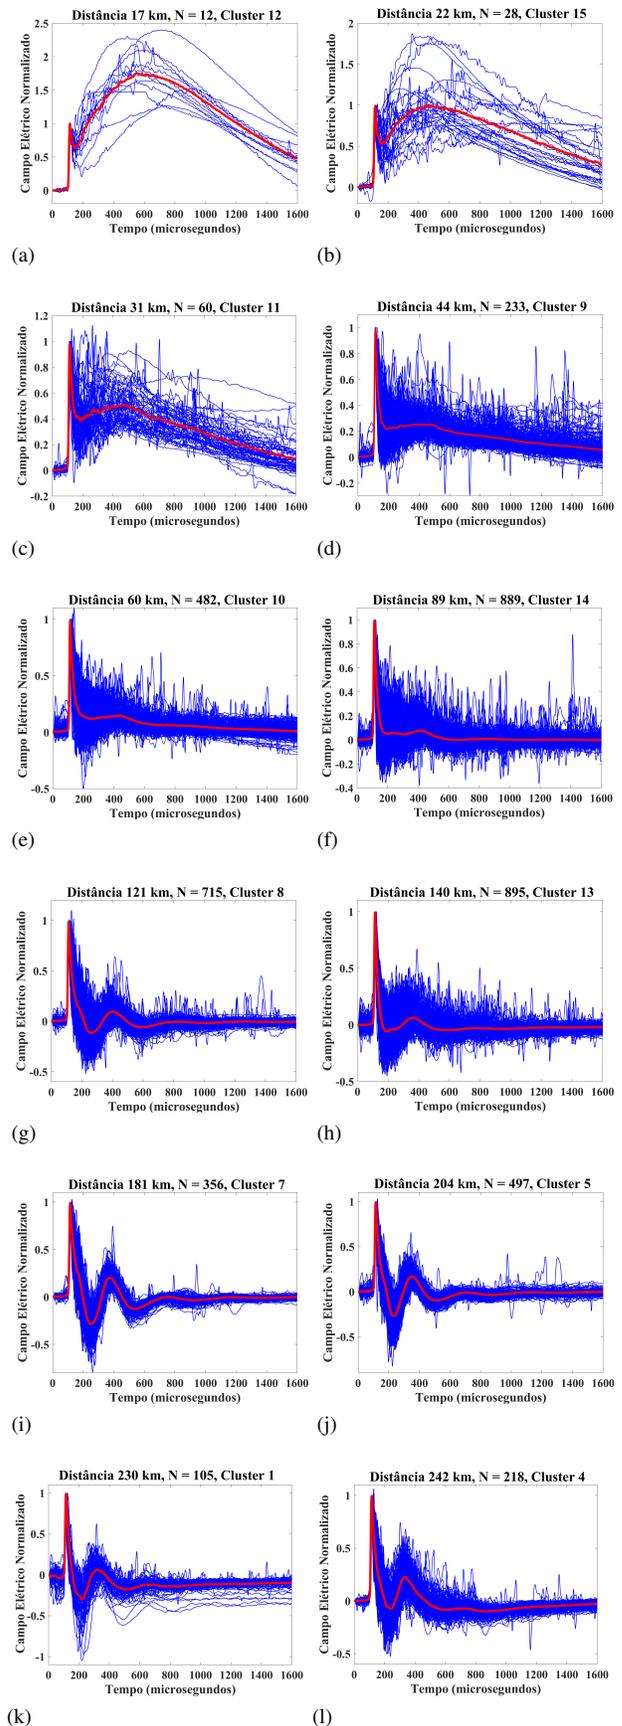
IV. RESULTADOS E DISCUSSÕES

Nesta seção, serão apresentados os resultados obtidos através do emprego do algoritmo do KSOM para encontrar a distância de ocorrência de raios nuvem-solo negativos, registrados e armazenados pelo LDWSS que ocorreram durante o dia e noite. Os critérios de treinamento do KSOM foram discutidos na seção III (subseção C).

A. Formas de Onda Padrão de Raios Nuvem-Solo Negativos Registrados de Dia.

Na Fig. 5, apresentam-se os agrupamentos formados com o uso do KSOM em ordem crescente da distância média de cada *cluster*. Em vermelho estão as curvas médias (formas de onda padrão). Todos os *clusters* são compostos por eventos que ocorreram durante o dia.

Neste estudo, o tamanho da grade do KSOM foi de 3x5, totalizando 15 neurônios da grade de saída. É importante ressaltar que diversos treinamentos de KSOM foram realizados, mudando-se o número de neurônios na grade de saída, sendo que a rede que apresentou melhor resultado de visualização dos grupos formados foi a rede com 15 neurônios na grade de saída, o que resultou na formação de 15 agrupamentos.



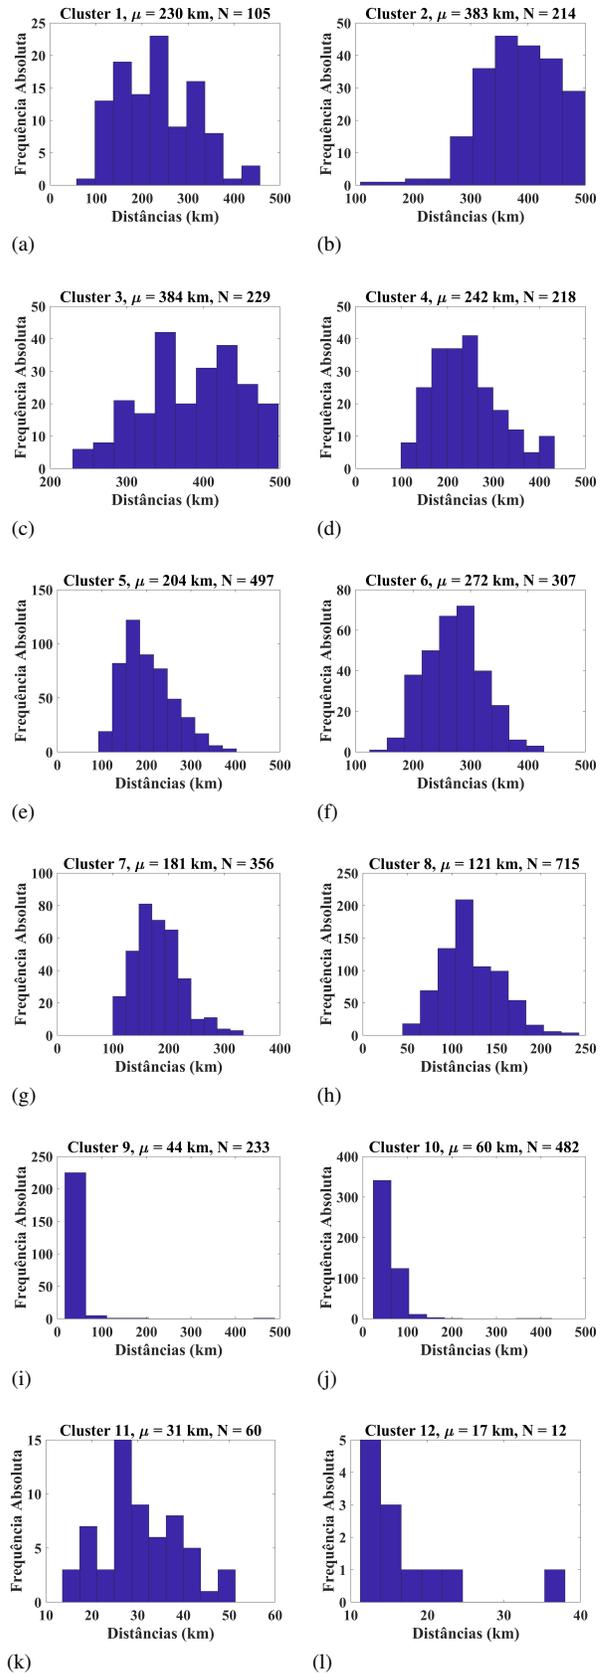
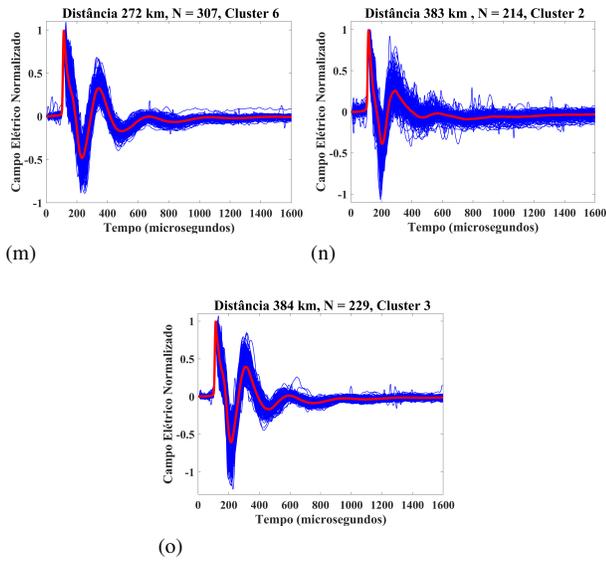


Fig. 5. Agrupamentos formados pelas formas de onda de campos elétricos que ocorreram durante o dia: (a) Cluster 12, (b) Cluster 15, (c) Cluster 11, (d) Cluster 9, (e) Cluster 10, (f) Cluster 14, (g) Cluster 8, (h) Cluster 13, (i) Cluster 7, (j) Cluster 5, (k) Cluster 1, (l) Cluster 4, (m) Cluster 6, (n) Cluster 2 e (o) Cluster 3.

A partir das formas de onda médias obtidas pela média aritmética simples para cada agrupamento formado, conseguiu-se definir os perfis de comportamento do campo elétrico para diferentes faixas de distâncias de ocorrência dos raios nuvem-solo negativos que ocorreram durante o dia. A Tabela I apresenta os valores de média (μ) e desvio padrão (σ) das distâncias de ocorrência dos eventos contidos em cada *cluster* no período do dia. Os valores de distâncias obtidos são representados pelas formas de onda padrão, visualizadas em vermelho na Fig. 5. O desvio padrão corresponde à variabilidade da distância de ocorrência dos eventos contidos em um *cluster* ao redor da média dessas distâncias.

TABLE I
MÉDIA E DESVIO PADRÃO DAS DISTÂNCIAS DOS CLUSTERS – DIA

Clusters	μ (km)	σ (km)	Clusters	μ (km)	σ (km)
Cluster 1	230	83,4	Cluster 9	44	32,8
Cluster 2	383	65,6	Cluster 10	60	28,7
Cluster 3	384	63,8	Cluster 11	31	8,8
Cluster 4	242	72,4	Cluster 12	17	7,7
Cluster 5	204	56,4	Cluster 13	140	53,3
Cluster 6	272	49,6	Cluster 14	89	33,2
Cluster 7	181	41,9	Cluster 15	22	8,1
Cluster 8	121	33,1			

A Fig. 6 exibe os histogramas de frequências absolutas das distâncias agrupadas durante o dia para cada *cluster* obtido. Nota-se que o algoritmo KSOM conseguiu, geralmente, identificar padrões de distâncias próximas, permitindo conectar formas de ondas semelhantes.

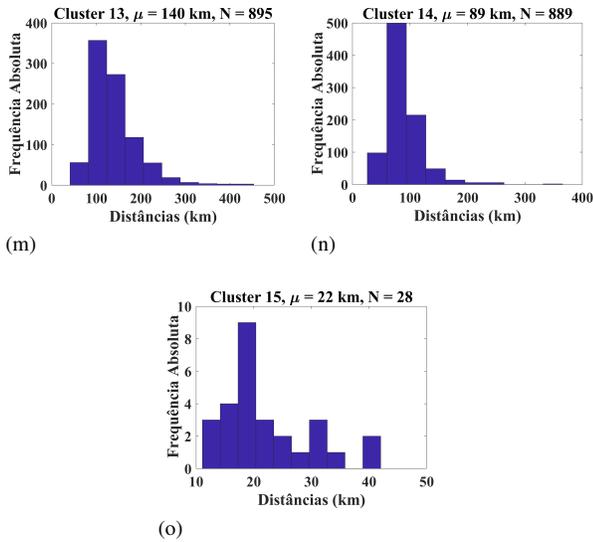


Fig. 6. Distribuição de frequências absolutas das distâncias resultantes do agrupamento pelo KSOM: (a) Cluster 1, (b) Cluster 2, (c) Cluster 3, (d) Cluster 4, (e) Cluster 5, (f) Cluster 6, (g) Cluster 7, (h) Cluster 8, (i) Cluster 9 (j) Cluster 10, (k) Cluster 11, (l) Cluster 12, (m) Cluster 13, (n) Cluster 14 e (o) Cluster 15.

B. Formas de Onda Padrão de Raios Nuvem-Solo Negativos Registrados de Noite

Na Fig. 7, apresentam-se os agrupamentos formados com uso do KSOM em ordem crescente da distância média de cada *cluster*. Em vermelho estão as curvas médias (formas de onda padrão). Todos os *clusters* são compostos por eventos que ocorreram durante a noite.

Neste estudo, o tamanho da grade do KSOM foi de 2x5, totalizando 10 neurônios da grade de saída. Ressalta-se que diversos treinamentos de KSOM foram realizados, mudando-se o número de neurônios na grade de saída, sendo que a rede que apresentou melhor resultado de visualização dos grupos formados foi a rede com 10 neurônios na grade de saída, resultando na formação de 10 grupamentos.

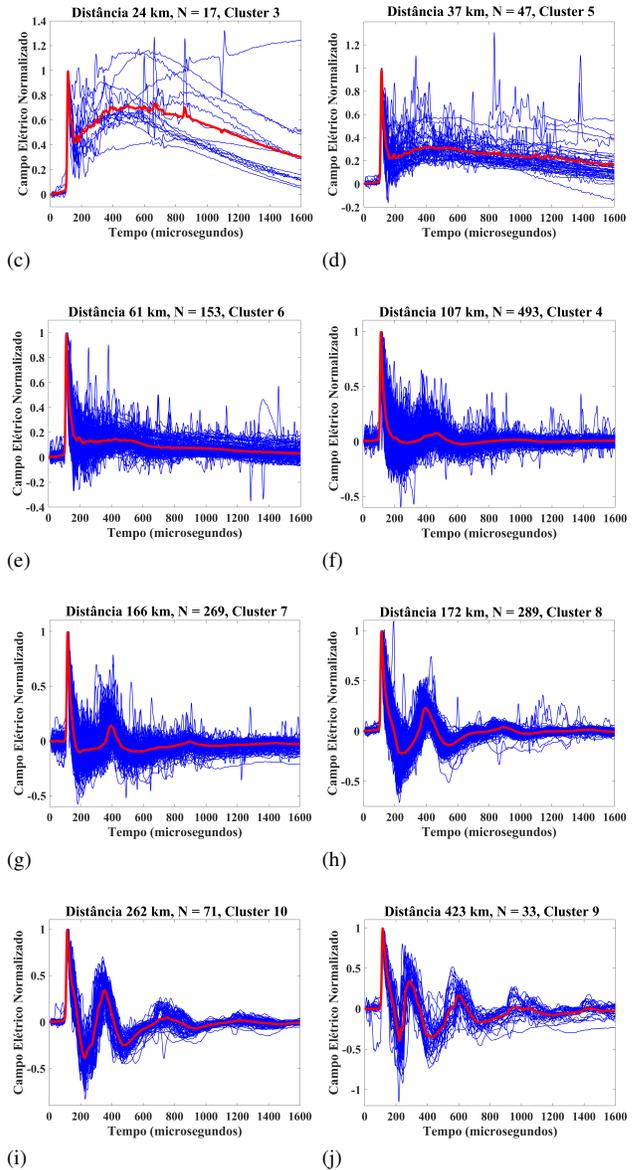
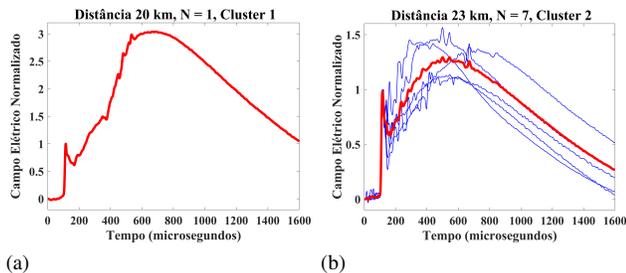


Fig. 7. Agrupamentos formados pelas formas de onda de campos elétricos que ocorreram durante a noite: (a) Cluster 1, (b) Cluster 2, (c) Cluster 3, (d) Cluster 5, (e) Cluster 6, (f) Cluster 4, (g) Cluster 7, (h) Cluster 8, (i) Cluster 10 e (j) Cluster 9.

A partir das formas de onda médias obtidas pela média aritmética simples para cada agrupamento formado, conseguiu-se definir um perfil de comportamento do campo elétrico para diferentes faixas de distância de ocorrências de raios nuvem-solo negativos que ocorreram durante a noite. A Tabela II apresenta os valores de média (μ) e desvio padrão (σ) das distâncias de ocorrência dos eventos contidos em cada *cluster* do período da noite. Os valores de distâncias obtidos são representados pelas formas de onda padrão, visualizadas em vermelho na Fig. 7.

TABLE II
MÉDIA E DESVIO PADRÃO DAS DISTÂNCIAS DOS CLUSTERS
– NOITE

Clusters	μ (km)	σ (km)	Clusters	μ (km)	σ (km)
Cluster 1	20	0	Cluster 6	61	31,4
Cluster 2	23	10,7	Cluster 7	166	34,4
Cluster 3	24	5,2	Cluster 8	172	30,8
Cluster 4	107	39,1	Cluster 9	423	64,4
Cluster 5	37	9,2	Cluster 10	262	55,7

A Fig. 8 exibe o histograma de frequências absolutas das distâncias agrupadas durante a noite. Nota-se que o algoritmo KSOM também conseguiu, geralmente, identificar padrões de distâncias próximas, permitindo conectar formas de ondas semelhantes.

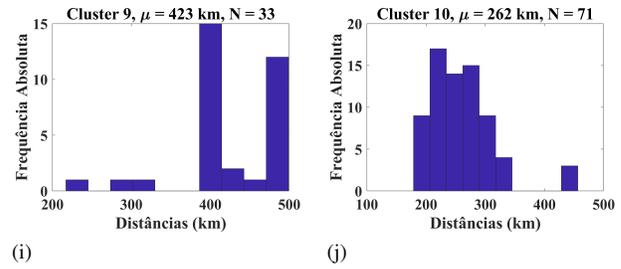
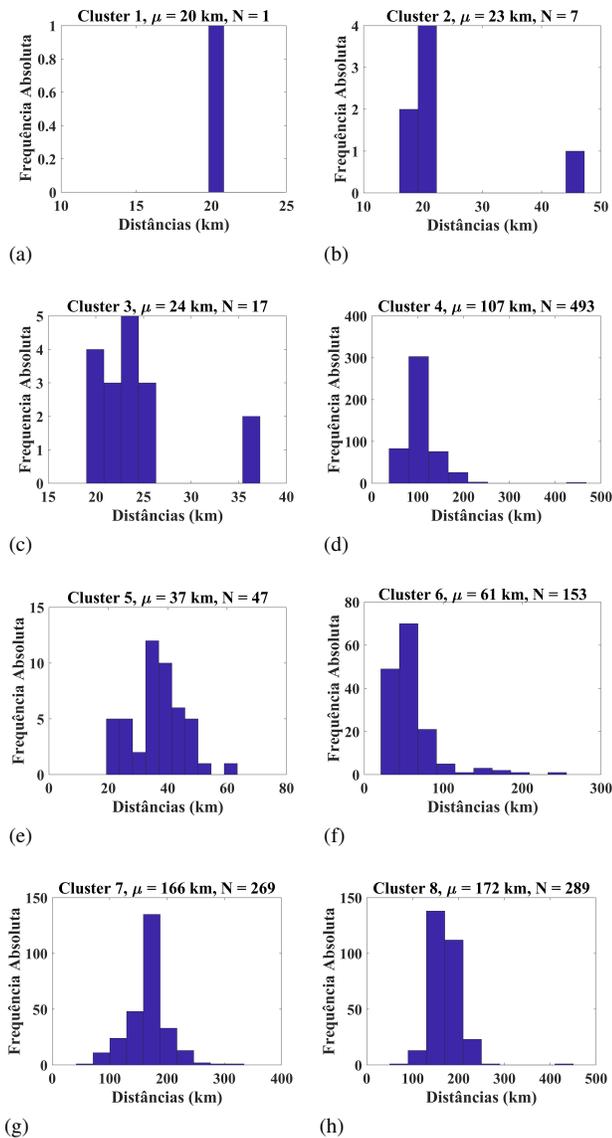


Fig. 8. Distribuição de frequências absolutas das distâncias resultantes do agrupamento pelo KSOM: (a) Cluster 1, (b) Cluster 2, (c) Cluster 3, (d) Cluster 4, (e) Cluster 5, (f) Cluster 6, (g) Cluster 7, (h) Cluster 8, (i) Cluster 9 e (j) Cluster 10.

C. Discussões

De uma forma geral, observou-se que, para uma mesma distância e mesmo período de observação (dia ou noite), as formas de onda de campos elétricos de raios nuvem-solo negativos, seguem um comportamento semelhante. Entretanto, o comportamento de tais campos elétricos é complexo e sofre influência de diversos fatores físicos e ambientais como a intensidade da corrente elétrica da descarga de retorno, a quantidade de cargas elétricas transportadas entre a nuvem e a Terra, condições da atmosfera e ionosfera, e o percurso de propagação do campo eletromagnético (por terra, por floresta, por água e etc.). Todos esses fatores, interferem na forma de onda do campo elétrico medido no sensor. De forma que, por exemplo, um raio com alta corrente elétrica registrado a 300 km de distância se pareça com um raio de baixa corrente elétrica registrado a 200 km. Assim, formas de onda de campos elétricos medidos em distâncias diferentes, podem ter características parecidas, conforme se observa nos histogramas das Fig. 6 e 8, e pelos valores dos desvios padrões nas Tabelas I e II.

Valer ressaltar que o *cluster 1* para eventos no período da noite, contém apenas um evento. Este evento foi registrado a curta distância e apresenta uma rampa após o pico inicial bem protuberante, característico da componente eletrostática ou de corrente contínua [20]. Não foi verificada uma componente eletrostática tão protuberante em nenhum outro evento, por isso, essa forma de onda foi agrupada de forma isolada.

Notou-se que os *clusters 2* e *3*, eventos diurnos, apresentaram valores de médias e desvios padrões próximos. Entretanto, as formas de onda padrões destes *clusters* possuem comportamentos diferentes, caracterizando distâncias desiguais.

As formas de onda representativas de cada *cluster*, identificadas nesse trabalho, podem ser utilizadas juntamente com algoritmos de inteligência artificial, ou equações analíticas para identificação da distância de ocorrência de descargas atmosféricas nuvem-solo negativas [21], [22]. Tais metodologias são importantes em regiões onde não existe cobertura de uma rede de localização de raios, ou onde o acesso a esses dados é limitado.

V. CONCLUSÕES

O agrupamento das formas de onda através do KSOM permitiu identificar formas de onda padrões do campo elétrico para diferentes distâncias de ocorrência de raios nuvem-solo negativos (diurno e noturno). Foram identificados 15 padrões para eventos que ocorreram de dia e 10 padrões para eventos que ocorreram de noite.

Os resultados obtidos pelo KSOM se mostraram satisfatórios. Essa rede neural conseguiu, em regra, agrupar formas de ondas com distâncias próximas, como visto pelo histograma de frequências (diário e noturno). Em poucos *clusters* o KSOM identificou e agrupou formas de ondas distantes. Ressalta-se que nesses casos havia poucos eventos na nossa base de dados.

A análise de medida de variabilidade, desvio padrão, proporcionou avaliar-se estatisticamente o desempenho dos *clusters* obtidos através do emprego do KSOM. Para os dados de dia, notou-se que, para *clusters* com distância média maior, os desvios padrões cresceram e, para *clusters* com distância média menor, houve uma redução dos desvios padrões. Em relação aos dados de noite, o desvio padrão tendeu também a diminuir conforme a distância média de cada *cluster* atenuava.

Dessa forma, os resultados poderão ser utilizados conjuntamente com um método inteligente para identificar a distância de ocorrência de raios nuvem-solo negativos. Contribuindo assim, para o desenvolvimento de sistemas de alarme e monitoramento de raios em regiões remotas, onde dados de rede de localização de raios não estejam disponíveis.

REFERENCES

- [1] V. A. Rakov and M. A. Uman, "Lightning: Physics and Effects". New York: Cambridge University Press, 2003.
- [2] A. F. R. Leal, V. A. Rakov and B. R. P. da Rocha, "Upgrading the Low-Cost Lightning Detection and Waveform Storage System", *IEEE Transactions on Electromagnetic Compatibility*, vol. 61, no. 2, pp. 595-598, Apr. 2019.
- [3] A. F. R. Leal, V. A. Rakov, J. Pissolato Filho, Rocha, B. R. P. da Rocha and M. D. Tran, "A Low-Cost System for Measuring Lightning Electric Field Waveforms, its Calibration and Application to Remote Measurements of Currents", *IEEE Transactions on Electromagnetic Compatibility*, vol. 60, no. 2, pp. 414-422. Abr. 2018.
- [4] R. Thottappillil and V. A. Rakov, "On Different Approaches to Calculating Lightning Electric Fields", *J. Geophys. Res.*, vol. 10, no. D13, pp. 14191-14205, July 2001.
- [5] H. Volland, "Longwave Sferics Propagation Within the Atmospheric Waveguide", in: *Handbook of Atmospheric Electrodynamics*, vol. 2, pp. 65-93, CRC Press, 1995.
- [6] K. G. Budden, "The propagation of Radio Waves: The theory of radio waves of low power in the ionosphere and magnetosphere", UK: Cambridge University Press, 1988.
- [7] E. H. Lay and X.-M. Shao, "Multi-Station Probing of Thunderstorm-Generated D-layer Fluctuations by Using Time-Domain Lightning Waveforms", *Geophysical Research Letters*, vol. 38, no. 23, pp. 1-4, 2001.
- [8] A. F. R. Leal, V. A. Rakov and B. R. P. Rocha, "Estimation of Ionospheric Reflection Heights Using CG and IC Lightning Electric Field Waveforms", in *Proceedings of International Symposium on Lightning Protection*, 2017, pp. 212-217.
- [9] Y. T. Lin, M. A. Uman, J. A. Tiller, R. D. Brantley, W. H. Beasley, E. P. Krider and C. D. Weidman, "Characterization of Lightning Return Stroke Electric and Magnetic Fields from Simultaneous Two-Station measurements", *Journal of Geophysical Research*, vol. 84, n. C10, pp. 6307-6314, 1979.
- [10] J. L. Bermudez, A. Piras, M. Rubinstein, "Artificial Neural Network in Lightning Location Systems", in *Proceedings of the International Symposium on Neuro-Fuzzy Systems, AT '96*, Conference Report, Lausanne, Switzerland, 1996, pp. 177-178.
- [11] A. Mostajabi, *et al.*, "Single-Sensor Source Localization Using Electromagnetic Time Reversal and Deep Transfer Learning: Application to Lightning", *Scientific reports*, vol. 9, no. 1, pp. 1-4, 2019.
- [12] H. Karami, A. Mostajabi, M. Azadifar, M. Rubinstein, C. Zhuang and F. Rachidi, "Machine Learning-Based Lightning Localization Algorithm Using Lightning-Induced Voltages on Transmission Lines", *IEEE Transactions on Electromagnetic Compatibility*, pp. 1-8, Mar. 2020.
- [13] T. Kohonen, E. Oja, O. Simula, A. Visa and J. Kangas, "Engineering Applications of the Self-Organizing Map", *Proceedings of the IEEE*, vol. 84, no. 10, pp. 1358-1384, Oct. 1996.
- [14] T. Kohonen, "Self-organizing Maps". New York: Springer Berlin Heidelberg, 2001.
- [15] V.A. Rakov, S. Mallick, A. Nag and V.B. Somu, "Lightning Observatory in Gainesville (LOG), Florida: A review of recent results", *Electric Power Systems Research*, vol. 113, pp. 93-103, Aug. 2014.
- [16] S. Mallick *et al.*, "Performance characteristics of the NLDN for return strokes and pulses superimposed on steady currents, based on rocket triggered lightning data acquired in Florida in 2004-2012", *Journal of Geophysical Research*, vol. 119, no. 7, pp. 3825-3856, 2014.
- [17] M. S. Aldenderfer and R. k. Blashfield, Cluster Analysis, Sage University paper series on Quantitative Applications Social Science in the Social Science, series n°07-044, Newbury Park, California: Sage Publications, 1984.
- [18] J. S. R. Jang, C. T. Sun and E. Mizutami, Neuro-Fuzzy and Softcomputing: a computational approach to learning and machine intelligence. Prentice Hall, Inc., Simon & Schuster/A Viacom Company, Upper Saddle River, NJ 7458, 1997.
- [19] S. Haykin, Neural Network: A Comprehensive Foundation. NJ, USA: Prentice Hall PTR Upper Saddle River, 1994.
- [20] N. Kitagawa, M. Brook and E. J. Workman, "Continuing currents in cloud-to-ground lightning discharges", *Journal of Geophysical Research*, vol. 67, no. 2, pp. 637- 647, 1962.
- [21] N L. A. de Sá and R. A. Marshall, "Lightning Distance Estimation Using LF Lightning Radio Signals via Analytical and Machine-Learned Models", in *Proceedings of the IEEE Transactions on Geoscience and Remote Sensing*, vol. 58, no. 8, pp. 5892 - 5907, 2020.
- [22] A. F. R. Leal, V. A. Rakov, E. R. A. and M. N. G. Lopes, "Estimation of -CG lightning distances using single-station E-field measurements and machine learning techniques", in *Proceedings of the IEEE International Symposium on Lightning Protection (XV SIPDA)*, São Paulo, Brazil, Feb, 2019, pp. 1-8.



Elton Rafael Alves holds a degree in Computer Engineering from the Federal University of Pará and Doctor in Electrical Engineering (Energy System) from the Federal University of Pará. Is Adjunct Professor at the Federal University of the South and Southeast of Pará. His areas of interest are: computational intelligence, embedded systems and atmospheric discharges.



Adônís F. R. Leal received a Master and Doctor degree in electrical engineering (Power Systems) from the Federal University of Pará, Belem, Para, Brazil in 2014 and 2018 respectively. From 2016 to 2017, he worked as a visiting researcher in the Department of Electrical and Computer Engineering at the University of Florida, Gainesville, FL, USA. Since 2018 he is an Adjunct Professor at the Federal University of Para. His main interests are development of embedded systems, lightning physics, lightning detection and location systems and lightning occurrence in the Amazon.