

INSTITUTO DE ENGENHARIA NUCLEAR

KÉLCIO JOSÉ GOMES

**APLICATIVO MÓVEL BASEADO EM REDES NEURAIS ARTIFICIAIS PARA
PREVISÃO DE DOSES EM CASOS DE EMERGÊNCIAS NUCLEARES COM
LIBERAÇÃO DE MATERIAL RADIOATIVO**

**Rio de Janeiro
2018**

KÉLCIO JOSÉ GOMES

**APLICATIVO MÓVEL BASEADO EM REDES NEURAIS ARTIFICIAIS PARA
PREVISÃO DE DOSES EM CASOS DE EMERGÊNCIAS NUCLEARES COM
LIBERAÇÃO DE MATERIAL RADIOATIVO**

Dissertação apresentada ao
Programa de Pós-Graduação em
Ciência e Tecnologia Nucleares do
Instituto de Engenharia Nuclear da
Comissão Nacional de Engenharia
Nuclear como parte dos requisitos
necessários para a obtenção do
Grau de Mestre em Ciência e
Tecnologia Nucleares

Orientadores: Prof. Dr. Cláudio Márcio N. A. Pereira (PPGCTN/IEN/CNEN) e
Prof. Dr. Roberto Schirru (PEN/COPPE/UFRJ)

Rio de Janeiro
2018

**APLICATIVO MÓVEL BASEADO EM REDES NEURAIS ARTIFICIAIS PARA
PREVISÃO DE DOSES EM CASOS DE EMERGÊNCIAS NUCLEARES COM
LIBERAÇÃO DE MATERIAL RADIOATIVO**

KÉLCIO JOSÉ GOMES

DISSERTAÇÃO SUBMETIDA AO PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA
E TECNOLOGIA NUCLEARES DO INSTITUTO DE ENGENHARIA NUCLEAR DA
COMISSÃO NACIONAL DE ENERGIA NUCLEAR COMO PARTE DOS
REQUISITOS NECESSÁRIOS PARA OBTENÇÃO DO GRAU DE MESTRE EM
CIÊNCIA E TECNOLOGIA NUCLEARES

Aprovada por:

Prof. Cláudio Márcio do Nascimento Abreu Pereira, D.Sc.

Prof. Roberto Schirru, D.Sc.

Prof. César Marques Salgado, D.Sc

Prof. André Przewodowski Filho, D.Sc

Prof. Alan Miranda Monteiro de Lima, D.Sc

RIO DE JANEIRO, RJ – BRASIL
ABRIL DE 2018

GOME Jose Gomes, Kelcio

Aplicativo móvel baseado em Redes Neurais Artificiais para
previsão de doses em casos de emergências nucleares com liberação
material radioativo/

Kélcio José Gomes -- Rio de Janeiro: CNEN/IEN, 2018.

xiii, 64 f.: il.; 31 cm

Orientadores: Cláudio Márcio do Nascimento Abreu Pereira
Roberto Schirru

Dissertação (Mestrado em Ciência e Tecnologia Nucleares) –
Instituto de Engenharia Nuclear,PPGIEN, 2018

1. Previsão de Dose. 2. Dispersão Atmosférica de Radionuclídeo.
3. Rede Neural Artificial. 4. Smartphone. 5. Emergência Nuclear.

"We are going to die, and that makes us the lucky ones. Most people are never going to die because they are never going to be born. The potential people who could have been here in my place but who will in fact never see the light of day outnumber the sand grains of Arabia. Certainly those unborn ghosts include greater poets than Keats, scientists greater than Newton. We know this because the set of possible people allowed by our DNA so massively exceeds the set of actual people. In the teeth of these stupefying odds it is you and I, in our ordinariness, that are here. We privileged few, who won the lottery of birth against all odds, how dare we whine at our inevitable return to that prior state from which the vast majority have never stirred?"

Richard Dawkins

AGRADECIMENTOS

Aos meus pais Neusa e José Raimundo aos quais devo tudo que sou.

A minha irmã Vanessa pelos incentivos diários para que eu concluísse esse trabalho.

Aos meus orientadores Cláudio Márcio e Roberto Schirru pelo incentivo, pelo conhecimento compartilhado, por compreenderem meus sumiços mesmo quando não havia justificativas e por, muitas das vezes, acreditarem mais em mim do que eu mesmo.

A todos funcionários e alunos do Laboratório de Monitoração de Processos (LMP - Coppe).

Aos servidores do Instituto de Engenharia Nuclear pela cordialidade que demonstraram desde o primeiro dia que pisei na Instituição. E, em especial, à Dona Cláudia sempre com seu jeito afável ao nos receber.

Aos professores que transmitiram de forma magistral o conhecimento.

Aos colegas e amigos de sala de aula pelo companheirismo.

À Universidade do Estado do Rio de Janeiro por incentivar de forma indireta a minha formação e, em especial, à Dona Zélia Maria Pereira.

Aos meus irmãos de comunidade Ednaldo e Lucas pela convivência diária.

Aos meus amigos Cristhian, Luciano, Karen e Augusto por fazerem a vida mais doce e divertida.

Muito obrigado!

RESUMO

Este trabalho apresenta um aplicativo móvel de previsão de doses para casos de emergências em Centrais Nucleares com liberação de material nuclear. O objetivo consiste em prover um suporte extra para a tomada de decisões de equipes de campo quando a os sistemas de informações da planta estiverem indisponíveis. Contudo, a previsão de doses devido a dispersão de radionuclídeos na atmosfera requer a execução de modelos físicos altamente complexos e computacionalmente intensos. Para que essas previsões sejam possíveis de serem feitas usando recursos computacionais limitados como, por exemplo, telefone celular é proposto neste trabalho o uso de Redes Neurais Artificiais (RNA) previamente treinadas (modo off-line) com dados obtidos por simulações precisas utilizando-se do Sistema de Dispersão Atmosférica. Para isso, foram consideradas situações típicas para cada acidente postulado, bem como uma ampla gama de condições meteorológicas. Como passo inicial, foram investigadas diversas arquiteturas de RNA para avaliar a capacidade de previsão de dose em cenários hipotéticos nas vizinhanças da Central Nuclear Brasileira da CNAAB, em Angra dos Reis, Rio de Janeiro. Como resultado, obteve-se um ótima generalização e um coeficiente de correlação de 0,99 para um conjunto de dados de avaliação (padrões não usados em treinamento). Diante disso, as RNAs selecionadas foram codificadas na Linguagem de Programação Java para serem executadas em um aplicativo da plataforma *Android* destinado a traçar a distribuição da dose espacial no mapa da região em questão. Neste trabalho, descreve-se a arquitetura geral do sistema proposto, resultados numéricos e comparações entre as arquiteturas investidas de RNA são discutidas. Além disso, o desempenho e limitações da execução numa plataforma de celular móvel são avaliados e possíveis melhorias e trabalhos futuros são apontados.

Palavras-chave: previsão de dose, dispersão atmosférica de radionuclídeo,, *smartphone*, Rede Neural Artificial, emergência nuclear, *Android*.

ABSTRACT

This work presents the approach of a mobile dose prediction system for NPP emergencies with nuclear material release. The objective is to provide extra support to field teams decisions when plant information systems are not available. However, predicting doses due to atmospheric dispersion of radionuclide generally requires execution of complex and computationally intensive physical models. In order to allow such predictions to be made by using limited computational resources such as mobile phones, it is proposed the use of artificial neural networks (ANN) previously trained (offline) with data generated by precise simulations using the NPP atmospheric dispersion system. Typical situations for each postulated accident and respective source terms, as well as a wide range of meteorological conditions have been considered. As a first step, several ANN architectures have been investigated in order to evaluate their ability for dose prediction in hypothetical scenarios in the vicinity of CNAAA Brazilian NPP, in Angra dos Reis, Brazil. As a result, good generalization and a correlation coefficient of 0.99 was achieved for a validation data set (untrained patterns). Then, selected ANNs have been coded in Java programming language to run as an Android application aimed to plot the spatial dose distribution into a map. In this work, the general architecture of the proposed system is described; numerical results and comparisons between investigated ANN architectures are discussed; performance and limitations of running the Application into a commercial mobile phone are evaluated and possible improvements and future works are pointed.

Keywords: Dose prediction, Atmospheric dispersion of radionuclide, Mobile, Smartphone, Artificial neural network, Nuclear emergency, Android.

LISTA DE FIGURAS

Figura 1. Geração por vias nucleares de eletricidade e capacidade em construção (adaptado de World Nuclear Association, 2017).....	15
Figura 2. Zonas de Planejamento de Emergência da CNAEA (ELETROBRÁS, 2017)	157
Figura 3. Diagrama do SCA usado neste trabalho (PEREIRA, 2017)	23
Figura 4. Esquema do reticulado tridimensional usado para a região de abrangência do SCA. (COPPE/UFRJ - NUCLEAR, LABORATÓRIO DE ANÁLISE E SEGURANÇA, 1987).....	25
Figura 5. Exemplo de modelação da topografia. (COPPE/UFRJ - NUCLEAR, LABORATÓRIO DE ANÁLISE E SEGURANÇA, 1987).....	25
Figura 6. Um neurônio e suas principais partes	28
Figura 7. Modelo não-linear de um neurônio artificial (Haykin, 1999).....	29
Figura 8: Grafo de uma Rede de Múltiplas Camadas (Adaptado de Haykin, 1999) ..	31
Figura 9. Escopo de previsão de cada RNA. (a) RNA-Norte (b) RNA-Leste (c) RNA-Sul (d) RNA-Oeste (PEREIRA, 2017).....	34
Figura 10. A RNA proposta. (PEREIRA, 2017)	36
Figura 11. Malha da área de abrangência do SCA.....	37
Figura 12. Protótipo da aplicação de previsão de doses	38
Figura 13. Plotagem do maior valor de saída (dose). Valor simulado versus previsto pela RNA MLP-3Camadas	43
Figura 14. Plotagem do maior valor de saída (dose). Valor simulado versus previsto pela RNA MLP-5Camadas	43

Figura 15. Plotagem do maior valor de saída (dose). Valor simulado versus previsto pela RNA GRNN.....	44
Figura 16. Plotagem dos menores valores de saída (dose). Valores previstos pela RNA MLP-3Camadas	44
Figura 17. Plotagem dos menores valores de saída (dose). Valores previstos pela RNA MLP-5Camadas	45
Figura 18. Plotagem dos menores valores de saída (dose). Valores previstos pela RNA GRNN	45
Figura 19. RN-Norte com os ângulos para treinamento (em branco) e teste (em vermelho).	47
Figura 20. Mapa com a malha de 43 x 67 com os pontos utilizados para a RN-Norte	48
Figura 21. Mapa gerado pelo simulador	52
Figura 22. Mapa Gerado pela MLP de 5 Camadas	52
Figura 23. Mapa gerado pela GRNN	52
Figura 24. Escala de doses	52
Figura 25. Mapa gerado pelo simulador	54
Figura 26. Mapa gerado pela MLP de 5 Camadas com corte	54
Figura 27. Mapa gerado pela GRNN com corte	54
Figura 28. Escala de doses	54

LISTA DE TABELAS

Tabela 1: Entradas e Saída da RNA	35
Tabela 2. Faixas de valores e distribuição do conjunto de dados de treinamento e teste do pré-processamento.....	40
Tabela 3. Uso dos padrões gerados no pré-processamento.....	40
Tabela 4. Estatísticas do pré-processamento com padrões de produção.....	42
Tabela 5: Faixas de valores e distribuição do conjunto de dados de treinamento	46
Tabela 6: Faixas de valores e distribuição do conjunto de dados de teste	46
Tabela 7: Uso dos padrões gerados	48
Tabela 8: Características das RNAs	49
Tabela 9: Estatísticas de treinamento da GRNN.....	50
Tabela 10: Estatísticas de treinamento da MLP de 5 Camadas.....	50
Tabela 11: Tempo de execução na geração do mapa de doses	55

SUMÁRIO

1	INTRODUÇÃO	14
2	CONTEXTUALIZAÇÃO E TRABALHOS RELACIONADOS.....	19
2.1	RNAs EM PREVISÃO DE RADIAÇÃO E MODELAGEM DE DISPERSÃO ATMOSFÉRICA	19
2.2	SISTEMAS MÓVEIS PARA SUPORTE EM EMERGÊNCIAS EM CENTRAIS NUCLEARES	21
3	FUNDAMENTAÇÃO TEÓRICA	22
3.1	PREVISÃO DE DOSES E SISTEMA DE DISPERSÃO ATMOSFÉRICA EM CENTRAIS NUCLEARES	22
3.1.1	Módulo Termo Fonte	23
3.1.2	Módulo Campo de Vento	24
3.1.3	Módulo Dispersão de Pluma	26
3.1.4	Módulo Projeção de Pluma	26
3.2	REDES NEURAS ARTIFICIAIS.....	27
3.2.1	Características das RNAs utilizadas.....	30
3.2.2	Backpropagation Multilayer Perceptrons	30
3.2.3	General Regression Neural Network (GRNN)	32
4	METODOLOGIA.....	33
4.1	VISÃO GERAL DO APLICATIVO MÓVEL DE PREVISÃO	33
4.1.1	A Arquitetura da Rede Neural Artificial	33

4.1.2	A Aplicação Móvel de Previsão de Doses.....	37
4.2	DESENVOLVIMENTO E TESTE DAS REDES NEURAIS ARTIFICIAIS	39
4.2.1	Pré-processamento e pré-seleção de um conjunto de dados para treinamento, teste e produção.....	39
4.2.2	Resultados, análises e conclusões do pré-processamento	42
4.2.3	Preparação do conjunto de dados para treinamento, teste e produção	46
4.3	APLICAÇÃO DA REDE NEURAL ARTIFICIAL E SUA AVALIAÇÃO	49
4.3.1	Estatísticas de Treinamento das RNAS	49
4.3.2	Previsão da distribuição espacial de dose	51
4.4	EXECUÇÃO DAS RNA NA PLATAFORMA ANDROID	55
5	CONCLUSÕES FINAIS.....	56
6	TRABALHOS FUTUROS	57
7	REFERÊNCIAS.....	58

SIGLAS E ABREVIATURAS

WNA	- <i>World Nuclear Association</i>
CNAAA	- Central Nuclear Almirante Álvaro Alberto
ZPN	- Zona de Planejamento de Emergências
RNA	- Rede Neural Artificial
GRNN	- Rede Neural de Regressão Geral
SCA	- Sistema de Controle Ambiental
MLP	- <i>Backpropagation Multilayer Perceptron</i>
AG	- Algoritmo Genético

1 INTRODUÇÃO

Diante dos desafios atuais frente a crescente demanda cada vez maior por fontes de energias, novamente, a geração de energia por vias nucleares volta a entrar em voga devido ao impacto ambiental compensatório comparado a outras fontes de energia utilizadas massivamente no mundo.

Segundo relatório da *World Nuclear Association* (WNA) de 2017, no ano de 2016, mais de 9 GWe de capacidade energética foram disponibilizadas representando o maior crescimento dos últimos 25 anos. No fim do ano de 2016 existiam ao redor do mundo em operação aproximadamente 448 reatores contra 441 no início do mesmo ano. Dez reatores foram ativados para a produção energética enquanto outros 3 foram desativados gerando um crescimento na capacidade nuclear acima dos 8 GWe. Sendo o montante de eletricidade suprido por fontes nucleares aumentar de 35 TWh para 2476 TWh. Lembrando que esse aumento se deve não somente ao fato de novas instalações nucleares estarem a funcionar, mas também da melhoria daquelas instalações já existentes. Sem contar o número de reatores em construção pelo mundo era de 61 no final do ano de 2016. Sendo assim, houve uma grande expansão de Centrais Nucleares, como pode-se observar na Figura 1, nos últimos anos, segundo a *World Nuclear*, fazendo uma grande contribuição para a necessidade atual de fontes limpas, confiáveis e acessíveis.

Diante desse quadro de crescimento do uso da energia nuclear no mundo, a segurança em instalações nucleares é de suma importância para que a sua expansão dentro de um quadro mundial energético seja possível. E protocolos de segurança em Centrais Nucleares obedecem a inúmeras exigências de órgão governamentais locais assim como associações internacionais.

Como exemplo, a Central Nuclear Almirante Álvaro Alberto (CNAAA) localizada em Angra dos Reis, no Estado do Rio de Janeiro, Brasil, que engloba as usinas de Angra 1 e Angra 2, possui um Plano de Emergência que constam ações específicas a serem executadas nas chamadas Zonas de Planejamento de Emergência (ZPE).




Figura 1. Geração por vias nucleares de eletricidade e capacidade em construção (adaptado de *World Nuclear Association*, 2017)

As ZPE são áreas próximas a Central Nuclear Almirante Álvaro Alberto delimitadas por círculos com raios que de 3 km, 5 km, 10 km e 15 km tendo como ponto central o reator da usina de Angra1 como pode ser observado na Figura 2.

Dentro do Plano de Emergência, existem classificações de eventos que possam ocorrer junto a uma Central Nuclear que atendem a um modelo internacional de comunicação que visam ações preventivas e antecipatórias. Esse modelo prevê quatro etapas que vão da mais simples (quando não atinge a saúde e segurança da população próxima) até as mais sérias, como por exemplo, com liberação de material radioativo para o meio ambiente.

O Plano de Emergência adotado para a CNAAB é acionado de forma gradual e tem as seguintes etapas:

1. Evento Não Usual: condição anormal na usina, porém, sem liberação de material radioativo. Não é previsto qualquer tipo de ação junto à população.

2. Alerta: indica uma degradação real ou provável nos níveis de segurança. Também não está previsto nessa etapa trabalhos junto à população local.
3. Emergência de Área: indica uma falha real ou possível nas funções de segurança. Não há indícios de falhas no núcleo do reator da Central Nuclear. Os funcionários que não estão envolvidos na emergência em questão são removidos da Central Nuclear.
4. Emergência Geral: indica liberação real ou possível de material radioativo, além de indicação de degradação iminente ou real do núcleo do reator. Nessa etapa, se faz necessário a evacuação da população da ZPE 3 km para a ZPE 5 km. Com algum agravamento da situação, uma nova evacuação é feita, removendo-se a população da ZPE 5 km para a ZPE 10 km.




Figura 2. Zonas de Planejamento de Emergência da CNAEA (ELETRONUCLEAR, 2017)

Sendo assim, o que se propõe nesse trabalho é um auxílio na ocorrência de emergência que atinja a etapa 4, Emergência Geral, ou seja, com liberação de material radioativo na atmosfera.

Um sistema preciso de previsão de dispersão atmosférica de material radioativo em emergências em Centrais Nucleares é de suma importância para a tomada de decisões relacionadas a evacuação de pessoas que estejam próximas a área atingida além da proteção ambiental envolvida. Porém, essas previsões, geralmente, requerem a simulação de complexos modelos físicos como, por exemplo, previsão de Termo Fonte, cálculos de campo de vento, dispersão da pluma, deposição de radionuclídeo e a previsão de dose equivalente. Esses modelos, em muitas das vezes, consomem muito tempo para execução e necessitam de poderosos computadores para atingir a qualidade desejada.

Neste trabalho, propõe-se a abordagem para dar um suporte extra às equipes de emergências em casos em que a comunicação com os Sistemas de Informação da Central Nuclear não estiverem disponíveis para acesso, independentemente do motivo.

Como forma de modernização das ferramentas disponíveis para as equipes de emergências, nesse trabalho, é proposto o uso de uma ferramenta instalada num *smartphone*. O uso abrangente de *smartphones* na sociedade atual pressupõe que é de ótima valia a sua incorporação a Sistemas de Segurança em Centrais Nucleares.

Com o objetivo de superar as necessidades de recursos computacionais durante emergências, é investigado nesse trabalho o uso de Redes Neurais Artificiais (RNA) na previsão da distribuição espacial de doses. As RNAs foram treinadas em modo *off-line* usando dados previamente gerados pelo Sistema de Dispersão Atmosférica (SDA) da Central Nuclear Almirante Álvaro Alberto (CNAAA) que é um preciso e realístico sistema computacional capaz de avaliar em tempo real a distribuição espacial de doses no entorno da usina ou mesmo realizar simulações com dados hipotéticos para uma ampla gama de condições atmosféricas e cenários de acidentes. As RNAs treinadas foram integradas numa aplicação *Android* permitindo assim sua execução em telefones celulares.

Os principais objetivos deste trabalho são:

- i. descrever de forma geral a arquitetura e as funcionalidades do sistema;

ii. avaliar a eficiência das diferentes arquiteturas de Redes Neurais Artificiais disponíveis na literatura para aprendizado e sua precisão na previsão de doses. A seleção e o pré-processamento de um apropriado conjunto de dados de treinamento também foram estudados. Resultados preliminares encontram-se publicados também em (PEREIRA, 2016) e na seção 4.2.1 deste trabalho.

iii. Investigar um apropriado grupo de dados selecionados e o pré-processamento necessário;

iv. avaliar a performance de execução do sistema proposto como uma aplicação para a plataforma *Android* em um *smartphone*.

Uma vez, treinado, as RNAs selecionadas foram integradas a um aplicativo móvel para a plataforma *Android* e seus desempenhos avaliados. O sistema integrado na plataforma *Android*, sendo executado em um *smartphone* é descrito em (PEREIRA, 2017) e na seção 4.2.3 desse trabalho.

2 CONTEXTUALIZAÇÃO E TRABALHOS RELACIONADOS

Nesta seção, são contextualizadas as duas principais características do trabalho proposto que são:

i) o uso de Redes Neurais Artificiais na estimativa de doses de radiação e dispersão atmosférica e

ii) utilização de computação móvel (mais especificamente de *smartphones*) no suporte a emergências em Centrais Nucleares.

2.1 RNAs EM PREVISÃO DE RADIAÇÃO E MODELAGEM DE DISPERSÃO ATMOSFÉRICA

Atualmente, uma ampla variedade de aplicações de Redes Neurais Artificiais pode ser encontrada em quase todos os campos do conhecimento incluindo, obviamente, a Engenharia Nuclear. Porém, nessa seção, o foco será apenas nas aplicações de RNAs, na previsão de radiação e na modelagem de dispersão atmosférica.

Timonion e Savelieva (2005) aplicaram a Rede Neural de Regressão Geral (GRNN) para previsões espaciais de radioatividade e concluíram que a GRNN é uma ferramenta promissora para automatizar previsão espacial de radioatividade em situações rotineiras ou em casos emergenciais. Consideraram também que a GRNN é muito rápida, de fácil aplicação e interpretação, além de ela obter resultados razoáveis mesmo para dados complexos. Atestaram também em seus estudos que o uso do *smoothing factor* (característica da GRNN que será mais bem detalhada na Seção 3.2.3 desse trabalho) é visivelmente desvantajoso quando o interesse é a previsão de valores extremamente precisos.

Mól et al. (2011) fizeram o uso da GRNN para previsão de dose na área do reator de Pesquisa Argonauta localizado no Instituto de Engenharia Nuclear - IEN

(Brasil). Nesse trabalho, a previsão foi feita como uma função de operação do reator e posição espacial.

Swart e Helal (2013) propuseram o uso de GRNN para estimativa de dose interna de radiação em trabalhadores no trabalho com o ciclo de combustível. Eles apontaram que GRNN são boas RNAs para mapeamento de funções contínuas. Segundo Swart e Helal (2013), resultados de seus estudos mostraram que a GRNN obteve uma pequena porcentagem de erro quando comparado aos dados de monitoramento. Também destacaram as seguintes características da GRNN: rápido aprendizado, bom tratamento de dados esparsos. Sendo assim, o trabalho obteve sucesso nas respostas a aplicação proposta.

Cao et al. (2010) aplicaram Rede Neural Artificial na previsão a curto prazo da distribuição de concentração de aerossóis liberados de uma fonte. Em seu trabalho, ele concluiu que o desempenho da RNA foi comparável ou até mesmo superior a previsão de modelos Gaussianos.

Lauret et al. (2013) investigaram o uso de uma Rede Neural Artificial na dispersão atmosférica de gás e concluíram que o modelo de RNA obteve um bom resultado quando comparado com um software de Dinâmica de Fluidos Computacional (CFD), com a vantagem de ser mais rápido no processamento.

Houssain (2014) aplicou RNA para previsão de concentração de monóxido de carbono e matéria de partículas em atmosferas urbanas usando campo meteorológico e dados do trânsito. Nesse trabalho, Houssain (2014), modelos de RNAs foram desenvolvidos para vinte variáveis meteorológicas (que incluíam chuva/precipitação) e seis variáveis de trânsito que são significantes influências na emissão e dispersão de poluentes. A conclusão foi que modelos de RNAs baseadas em variáveis meteorológicas e de tráfego são capazes de resolver padrões de dispersão de poluentes na atmosfera de diferentes cidades uma vez que, em seus estudos, foram utilizados dados da cidade de Dhaka, Bangladesh para treinamento e teste e a robustez da previsão dos modelos propostos em seu trabalho, foram utilizados dados das cidades costeiras de Chittagong e Dhaka.

2.2 SISTEMAS MÓVEIS PARA SUPORTE EM EMERGÊNCIAS EM CENTRAIS NUCLEARES

Sistemas móveis de monitoramento assim como sistemas de comunicação móveis são amplamente usados por equipes de emergências. Entretanto, o uso de aparatos móveis como *smartphones* na tomada de decisão em sistemas de suporte é ainda muito incomum.

Silva et al 2013 desenvolveram um sistema de suporte de primeiros socorros para lidar com emergências radiológicas usando técnicas de análise de tarefas cognitivas. De acordo com os autores, os principais benefícios foram os controles gerais de resposta, além de atualizações instantâneas de informações, e suas verificações, e agilidade na condução de resposta ao problema.

O que parece é que, até o momento, sistemas de suporte na tomada de decisão em *smartphones* estejam sendo subutilizados na indústria nuclear, porém, devido a vertiginosa evolução dos *smartphones*, acredita-se que seu uso irá crescer rapidamente e em pouco tempo.

3 FUNDAMENTAÇÃO TEÓRICA

3.1 PREVISÃO DE DOSES E SISTEMA DE DISPERSÃO ATMOSFÉRICA EM CENTRAIS NUCLEARES

A previsão de doses devido à dispersão atmosférica e à liberação de material radioativo por Centrais Nucleares é realizada por meio de sistemas dedicados, compostos por complexos modelos físicos que geralmente são executados em computadores robustos.

Diante disso, este trabalho considera, como referência, o Sistema de Controle Ambiental (SCA), o sistema de dispersão atmosférica de radionuclídeos utilizado na Central Nuclear Almirante Álvaro Alberto. O SCA é basicamente composto por quatro módulos:

- i. Módulo Termo Fonte
- ii. Módulo Campo de Vento
- iii. Módulo Dispersão de Pluma e Cálculo de Dose
- iv. Módulo Projeção de Pluma

A Figura 3 mostra um diagrama simplificado do SCA.




Figura 3. Diagrama do SCA usado neste trabalho (PEREIRA, 2017)

O Módulo Termo Fonte realiza uma estimativa do material nuclear liberado e a sua taxa de liberação.

Já o Módulo Campo de Vento utiliza a topografia e informações meteorológicas para produzir um campo de vento não divergente.

O Módulo Dispersão da Pluma utiliza as saídas dos módulos de Termo Fonte e Campo de Vento para estimar a dispersão da pluma e calcular doses equivalentes.

O Módulo Projeção de Pluma faz projeções da dispersão da pluma para uma e duas horas depois do início do acidente.

3.1.1 Módulo Termo Fonte

O Módulo Termo Fonte recebe informações aproximadas do *status* da Central Nuclear (incluindo variáveis de processos monitoradas, diagnósticos de acidentes e inventário) e faz a previsão de concentrações e taxas de liberação de material radioativo.

3.1.2 Módulo Campo de Vento

O vento é o principal componente nesse modelo, pois é através dele que há transporte do material radioativo quando esse é liberado na atmosfera.

No Módulo Campo de Vento, é utilizado um campo de velocidade tridimensional e não-divergente para a região em questão, no caso, da Central Nuclear Almirante Álvaro Alberto. Esse módulo faz o cálculo da distribuição espacial do vento na região de interesse e nele é feita discretização do domínio computacional numa malha tridimensional, sendo assim, para cada célula dessa malha são efetuados cálculos dos campos de vento por interpolação e extrapolação de dados. Esses campos de vento são obtidos pelas torres meteorológicas disponíveis na área de abrangência do SCA. (COPPE/UFRJ - NUCLEAR, LABORATÓRIO DE ANÁLISE E SEGURANÇA, 1987)

Nesse módulo do SCA da CNAEA, o campo de vento é determinado por medidas de velocidades além de informações sobre a estabilidade atmosférica. Também são levados em consideração os efeitos da topologia do local (COPPE/UFRJ - NUCLEAR, LABORATÓRIO DE ANÁLISE E SEGURANÇA, 1987).

A formulação computacional do Módulo Campo de Vento é representada por uma caixa retangular. A base inferior dessa caixa está localizada no ponto mais baixo da região em questão. Por sua vez, o volume dessa caixa é subdividido em outros volumes menores, também retangulares, com dimensões ΔX , ΔY e ΔZ nas direções X, Y e Z, respectivamente, sendo ΔX e ΔY constantes e ΔZ variável como mostra a Figura 4. Na Figura 5 tem-se a representação da topologia (COPPE/UFRJ - NUCLEAR, LABORATÓRIO DE ANÁLISE E SEGURANÇA, 1987)




Figura 4. Esquema do reticulado tridimensional usado para a região de abrangência do SCA. (COPPE/UFRJ - NUCLEAR, LABORATÓRIO DE ANÁLISE E SEGURANÇA, 1987)




Figura 5. Exemplo de modelação da topografia. (COPPE/UFRJ - NUCLEAR, LABORATÓRIO DE ANÁLISE E SEGURANÇA, 1987)

Sendo assim, com o sistema de coordenadas cartesianas usado, a coordenada X está na direção Leste-Oeste aumentando para o sentido leste. Já a coordenada Y está orientada na direção Norte-Sul e tem seu aumento no sentido para norte e a coordenada Z é a direção vertical e aumenta no sentido do topo do caixa retangular.

3.1.3 Módulo Dispersão de Pluma

O Módulo de Dispersão de Pluma utiliza-se do campo de vento tridimensional divergente gerado pelo Módulo de Campo de Vento para efetuar o cálculo de transporte e difusão do material radioativo na atmosfera. O transporte e a difusão de radionuclídeos é determinado por meio de um modelo de bufadas tridimensional com trajetória lagrangeana variável e difusão gaussiana. (COPPE/UFRJ - NUCLEAR, LABORATÓRIO DE ANÁLISE E SEGURANÇA, 1987)

O modelo aplicado nesse módulo (FABRICK et al,1987) considera que a dispersão atmosférica de uma pluma pode, por assim dizer, ser simulada pela sequência de várias bufadas radioativas liberadas dentro de determinados intervalos de tempo contendo uma mesma quantidade. Essas bufadas radioativas, obviamente, são resultados de uma liberação contínua de radionuclídeos de fontes pontuais numa área de interesse distribuídas numa malha tridimensional. (COPPE/UFRJ - NUCLEAR, LABORATÓRIO DE ANÁLISE E SEGURANÇA, 1987)

3.1.4 Módulo Projeção de Pluma

Com a ocorrência de um acidente com liberação de material radioativo na atmosfera, os resultados do cenário atual são utilizados como base para uma estimativa das doses para tempos futuros de até 2 horas.

A projeção de doses é realizada supondo duas premissas:

- I. de que não há mudança nas condições meteorológicas: o campo de velocidade de vento que realiza o transporte do material na atmosfera e a estabilidade atmosférica são os mesmos do ciclo atual.
- II. e de que as taxas de emissão de radionuclídeos que seriam liberados em todo o período de projeção são conhecidas, assim como o tempo de duração da liberação.

3.2 REDES NEURAIS ARTIFICIAIS

O cérebro é composto por bilhões de células denominadas *neurônios* que se comunicam entre si através das *sinapses*. Já as sinapses são unidades estruturais que intermedeiam as interações entre os neurônios (Haykin, 1999).

Um neurônio por si só é constituído basicamente de três outras partes: corpo, dendritos e axônio. Cada uma dessas partes possuem funções distintas. Os dendritos ficam a cargo de captar os estímulos recebidos num determinado instante do tempo e transmitir ao corpo do neurônio para processamento. Já o corpo do neurônio, quando os estímulos recebidos atingem determinado limite, envia outro estímulo através do axônio alcançando células vizinhas por meio das sinapses. Todo esse processo de comunicação pode se repetir em vários níveis de neurônios. A Figura 6 representa de forma bem simplificada a composição de um neurônio.




Figura 6. Um neurônio e suas principais partes

Sendo assim, desde o início, o cérebro humano tem sido a motivação para o trabalho em Redes Neurais Artificiais, pois ele processa informações de uma maneira totalmente diferente dos computadores convencionais. Desse modo, o cérebro é um sistema de processamento de informação imensamente complexo, não-linear e paralelo (Haykin, 1999). Ele tem a capacidade de percepção, de controle motor e de reconhecer padrões. Capacidade essa adquirida através de experiências e, frente ao desconhecido, ele é capaz de fazer generalizações.

Segundo Haykin (2001), os neurônios presentes no córtex são responsáveis pelo processamento cognitivo humano. Dessa forma, um novo conhecimento adquirido ou uma nova experiência vivida pode efetuar alterações na estrutura do cérebro. Essas alterações de rearranjo da estrutura cerebral pode ser através reforço das conexões já existentes ou até mesmo a inibição delas.

Basicamente, pode-se resumir que Redes Neurais Artificiais são modelos matemáticos inspiradas no cérebro humano que tem a habilidade de aprender por exemplos utilizando-se de inúmeras aplicações para RNAs.

Segundo Haykin (1999, p.28)

“uma rede neural é um processador maciça e paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão

natural para armazenar conhecimento experimental e torná-lo disponível para o uso”.

Dessa forma, pode-se dizer que a menor unidade de processamento de informação de uma rede neural é o neurônio que é essencial para seu funcionamento. Na Figura 7 tem-se o modelo representativo de um neurônio em projetos de Redes Neurais Artificiais com seus três principais elementos:

- i. conjunto de n sinapses e suas conexões;
- ii. o somador para acumular os sinais de entrada;
- iii. e a função de ativação.




Figura 7. Modelo não-linear de um neurônio artificial (Haykin, 1999)

Os diferentes tipos de RNA se distinguem basicamente pela forma com que os neurônios são interligados (arquitetura da RNA) e o mecanismo de treinamento por elas utilizado. Sendo assim, a arquitetura de uma Rede Neural Artificial determinará o tipo de problema em que ela poderá ser utilizada. E essa arquitetura é definida pelo número de camadas, pelo tipo de conexões entre os nós e pela topologia. (Haykin, 2001).

3.2.1 Características das RNAs utilizadas

Neste trabalho, considera-se o uso daquelas que usam o aprendizado supervisionado (aprendizado com entradas/saídas) que são especialistas em interpolação e previsão.

De acordo com a Literatura, *Backpropagation Multilayer Perceptron* (MLP) e *General Regression Neural Networks*(GRNN) apresentam essas características.

É bem conhecida a habilidade das *Backpropagation Multilayer Perceptrons* para generalização e previsão, entretanto, o treinamento pode consumir um tempo elevado.

Por outro lado, as GRNNs são rápidas nos treinamentos e são apontadas na literatura (Timonin e Salevieva, 2005) como promissoras ferramentas para previsão espacial de radioatividade. Um preliminar trabalho comparativo (parte inicial desta dissertação) ratificou essa ideia (Pereira, 2016). Neste, a MLP de 5 camadas apresentou melhores resultado enquanto a GRNN obteve resultado um pouco menos preciso, mas com treinamento mais rápido. Já MLP de 3 camadas apresentou resultados notadamente inferiores. Sendo assim, nesse presente trabalho, foram enfatizados investigações para o uso de MLP de 5 camadas e de GRNN afim de aprimorá-las para serem usadas na aplicação móvel de previsão de doses.

3.2.2 Backpropagation Multilayer Perceptrons

Backpropagation Multilayer Perceptrons (MLP) são Redes Neurais Artificiais compostas de camadas de neurônios que em cada sinais de entrada sempre propaga adiante, da entrada para a saída. Elas apresentam:

- i. uma camada de entrada que recebe o dado de entrada;
- ii. uma camada de saída que providência a saída da RNA;

iii. uma ou mais camadas ocultas.

O número de neurônios na camada de entrada é igual ao número de entradas do problema. Assim como o número de neurônios da camada de saída é igual ao número de saídas da RNA.

A Figura 8 demonstra o grafo arquitetural de uma rede de múltiplas camadas totalmente conectada com duas camadas intermediárias (ocultas) e uma camada de saída. O sinal tem como sentido para frente, da esquerda para a direita e de camada em camada.




Figura 8: Grafo de uma Rede de Múltiplas Camadas (Adaptado de Haykin, 1999)

Já o número de camadas ocultas é flexível e é responsável por providenciar a habilidade de adaptação não-linear da Rede Neural Artificial. A função de ativação de neurônios pode ser não-linear (em geral, logística ou tangente hiperbólica) para adaptações complexas. O algoritmo de treinamento usado é o *Backpropagation* que é um algoritmo gradiente descendente capaz de minimizar a taxa de erro ajustando os pesos de sinapses de modo iterativo com o conjunto de dados para treinamento que são apresentados. O treinamento pode consumir um tempo considerável de acordo com o número de padrões, complexidade das correlações e número de neurônios.

3.2.3 General Regression Neural Network (GRNN)

De acordo com Specht (1991), GRNN é “uma rede baseada em memória que providencia estimativas de variáveis contínuas e converge para a superfície de regressão subjacente (linear e não-linear)”. Ela usa um algoritmo de aprendizado que providencia transições suaves mesmo entre os padrões de treinamento com dados esparsos em espaços multidimensionais.

A GRNN usa os conceitos de estimativas consistentes propostas por Parzen (1962). A estimativa de saída (Equação 1) é uma média ponderada de todos os padrões de treinamento.

$$\hat{Y}(X) = \frac{\sum_{i=1}^n Y^i \exp\left(-\frac{D_i^2}{2\sigma^2}\right)}{\sum_{i=1}^n \exp\left(-\frac{D_i^2}{2\sigma^2}\right)} \quad (1)$$

$$D_i^2 = (X - X^i)^T (X - X^i) \quad (2)$$

Onde $\hat{Y}(X)$ é uma saída estimada; X^i e Y^i são entradas e saídas de padrões de treinamento respectivamente; X é um valor observado para cada estimativa que é requisitada e é o fator de suavização (*smoothing factor*).

Altos valores de σ (*smoothing factor*) levam por mais funções de alisamento. Para encontrar um valor ótimo para σ , procedimentos de otimização podem ser utilizados a fim de minimizar ao menos os erros para o conjunto de testes. Neste trabalho, um Algoritmo Genético foi utilizado (AG) (Goldberg, 1989).

4 METODOLOGIA

4.1 VISÃO GERAL DO APLICATIVO MÓVEL DE PREVISÃO

O aplicativo móvel proposto para previsão de doses é primariamente desenvolvido para operação *stand-alone*, em outras palavras, ele deve funcionar sem qualquer tipo de conexão. O sistema deve aproximar uma distribuição espacial de dose considerando as seguintes informações:

- i. acidente atual (previamente identificado): variável de entrada;
- ii. algumas condições meteorológicas: variável de entrada;
- iii. tempo depois que o acidente se inicia: variável de entrada.

Para realizar isso, uma RNA é desenvolvida e treinada para cada acidente postulado considerando uma ampla variedade de condições meteorológicas. O conjunto de dados de treinamento é gerado por simulações usando o SCA de CNAAA. Para título de informação, os acidente postulados e utilizados para simulação junto ao SCA na CNAAA são: Ruptura da Linha de Instrumento, Ruptura da Linha VP com RTGV, Transiente de Alimentação Elétrica, Vazamento no KLP, Grande LOCA, Pequeno/Médio LOCA, Falha nos Sistemas KPF-KPK, Terremoto, Manuseio de Elemento Combustível, RTGV, Fusão Núcleo com Explosão de Vapor e Fusão Núcleo com Vazamento do UJA

4.1.1 A Arquitetura da Rede Neural Artificial

A fim de aprimorar o desempenho do processo de aprendizagem, 4 RNAs foram usadas para cada acidente postulado. Cada uma é aplicada para uma faixa específica de direções do vento, considerando-se 4 quadrantes (RNA-Norte, RNA-Sul, RNA-Leste e RNA-Oeste).

A Figura 9 mostra o escopo da previsão de cada uma das RNAs. Os limites do retângulo pontilhado é a área de dados de treinamento, enquanto o ângulo marcado em linhas em negrito define a faixa da direção do vento preferível para cada RNA. Por exemplo, a RNA-Norte é treinada com distribuição de dose na parte superior do mapa e seu escopo de aplicação são os ventos que vão dos ângulos de 315° a 45° (Observação importante: o eixo Norte é o de direção 0° e os ângulos aumentam na direção horária.).




Figura 9. Escopo de previsão de cada RNA. (a) RNA-Norte (b) RNA-Leste (c) RNA-Sul (d) RNA-Oeste (PEREIRA, 2017)

Cada RNA é treinada para estimar doses baseadas na posição espacial (X, Y) e nas condições meteorológicas vigentes.

Nesse trabalho, um conjunto reduzido é usado para ilustrar e validar nossa proposta. Assim como na investigação preliminar que será ainda descrita nesse

trabalho mais adiante, as variáveis da Tabela 1 foram usadas como entradas e saídas.

Tabela 1: Entradas e Saída da RNA

Entradas	Saída
Velocidade do Vento Direção do Vento Posição X Posição Y	Taxa de Dose

Muitas outras condições meteorológicas poderiam ser usadas como variáveis de entrada como tais como:

- i. estabilidade do vento;
- ii. temperatura;
- iii. temperatura gradiente;
- iv. índice pluviométrico;
- v. dentre muitos outros.

Similarmente, outras saídas possíveis poderiam ser usadas, como por exemplo:

- i. dose equivalente;
- ii. dose efetiva;

Na Figura 7 é mostrada a proposta da RNA. De acordo com a identificação do acidente e da direção do vento, o módulo de controle decide qual RNA será aplicada. Então, as variáveis de entradas são passadas para a Rede Neural Artificial escolhida e é executada, produzindo assim a dose prevista como saída.




Figura 10.A RNA proposta. (PEREIRA, 2017)

Perceba que uma única taxa de dose é a variável de saída e sendo a finalidade principal do trabalho reconstruir a distribuição espacial de doses no mapa, a RNA deve ser executada para cada ponto no espaço. O domínio computacional da área de abrangência do Sistema de Controle Ambiental (SCA) é discretizado numa malha de 67 x 43 células (veja Figura 11). Cada célula representa no mundo real uma área de 250 x 250 metros. Sendo assim, serão feitas 2881 execuções da RNA treinada no *smartphone*.




Figura 11. Malha da área de abrangência do SCA

4.1.2 A Aplicação Móvel de Previsão de Doses

No presente estágio desse trabalho, foca-se na avaliação do quanto a previsão de doses é precisa, além do desempenho e limitação de execução do sistema em *smartphones* comerciais. A fim de se obter isso, um protótipo simples baseado na plataforma *Android* foi desenvolvido contendo uma única tela em que o usuário pode inserir o acidente em questão, informações meteorológicas e visualizar, como saída, o mapa com a distribuição espacial de doses. Na Figura 12 é mostrada a interface do usuário proposta.




Figura 12. Protótipo da aplicação de previsão de doses

Como entradas, o usuário deve escolher:

- i. acidente em curso;
- ii. tipo de dose/taxa de dose a ser prevista (em mRem/h);
- iii. tempo depois do início do acidente;
- iv. direção do vento;
- v. velocidade do vento.

Como pode-se observar na Figura 12, são necessárias quatro entradas para as Redes Neurais Artificiais: direção do vento, velocidade do vento e as posições

(x,y). Lembrando que as entradas de posição (x, y) não são imputadas pelo usuário a manusear o aplicativo e sim pelo controle do sistema desenvolvido.

Devido ao tamanho do conjunto dados necessários para treinamento e teste das RNAs (descritas na seção 4.2.3), neste trabalho, o tempo após o início do acidente não será considerado como entrada para a Rede Neural Artificial (o tamanho do conjunto de dados seria, pelo menos, 5 vezes maior). Por isso, a RNA foi treinada utilizando padrões com 60 minutos após o início do acidente.

Trabalhos futuros podem investigar a introdução dessa variável. A expectativa deste trabalho é de que sejam necessários aprendizados mais intensos e treinamentos com algoritmos paralelos.

Depois de inseridas as informações de entradas e clicando no botão “Predict” no aplicativo, a RNA adequada é escolhida e executada para cada célula do domínio computacional (são 2881 posições no mapa). A distribuição espacial de doses é então plotada no mapa a ser exibido logo abaixo.

Tentando criar uma maior interação com o usuário, a aplicação também tem outras funcionalidades do tipo:

- i. mostrar a posição real do usuário no mapa (desde que ele esteja dentro das coordenadas de abrangência);
- ii. a taxa de dose no local em que o usuário estiver presente (quando aplicável);
- iii. mostrar a dose ao clicar em qualquer parte do espaço no mapa.

4.2 DESENVOLVIMENTO E TESTE DAS REDES NEURAIS ARTIFICIAIS

4.2.1 Pré-processamento e pré-seleção de um conjunto de dados para treinamento, teste e produção

Investigações preliminares foram feitas a fim de selecionar uma adequada arquitetura de RNA e estratégias de treinamento. Diversas arquiteturas *Multilayer*

Perceptrons (MLP) com algoritmos de treinamento *Backpropagation* foram tentados, porém sem nenhum sucesso. Porém, a rede *General Regression Neural* (GRNN) otimizada por um Algoritmo Genético (AG) (Goldberg, 1989) produziu melhores resultados. E essa observação é confirmada pela literatura com alguns autores (Timonion e Savelieva, 2005; Mólet al., 2011 e Sarwat e Helal, 2013) que também usaram GRNN devido a sua capacidade de estimativa de variáveis contínuas.

Todos os padrões de treinamento, teste e produção foram gerados usando o Sistema de Dispersão Atmosférica da CNAAA que, (em modo de simulação) pode ser usado para simular cenários customizados para um conjunto de acidentes postulados e condições atmosféricas observadas.

A Tabela 2 mostra o intervalo e a distribuição de cada variável de entrada para treinamento, teste e produção do conjunto de dados utilizados no pré-processamento. Fazendo todas as combinações possíveis, 12.393 padrões (entrada e saída) foram gerados e, através de testes de otimização empíricos, uma boa distribuição desses padrões foram definidos de acordo com a Tabela 3.

Tabela 2. Faixas de valores e distribuição do conjunto de dados de treinamento e teste do pré-processamento

	Amplitude	Valores	Intervalo
Velocidade do vento (m/s)	1-5	9	0,5
Direção do vento (graus)	315-45	9	11,25
Posição X	1-65	17	4
Posição Y	10-42	9	4

Tabela 3. Uso dos padrões gerados no pré-processamento

Uso	Quantidade
Treinamento	3825
Teste	2448
Produção	6120

Devido a complexidade do problema, um número grande de padrões de treinamento são necessários. Porém, o aumento do número de padrões de treinamento implica em um tempo maior de treinamento. Essa relação de custo/benefício foi observada nesses testes iniciais do pré-processamento. Observe que o conjunto de padrões para teste também é grande afim de melhorar o critério de parada nas redes MLPs e também otimizar o *smoothing factor* na GRNN. Os padrões separados para produção não foram utilizados no treinamento da Rede Neural Artificial, eles foram apenas usados na simulação no uso real da RNA.

Para um melhor desempenho e eficiência no aprendizado dos padrões de treinamento, todos os dados foram normalizados de acordo com a Equação (3). Essa normalização foi realizada antes de os dados serem submetidos ao treinamento da rede numa ferramenta independente.

$$X_N = \frac{(X - \bar{X})}{S} \quad (3)$$

onde X_N é o valor normalizado; X é o valor original, $\bar{X}$ é a média e S é desvio padrão.

Para esse pré-processamento, foram investigados o uso de duas arquiteturas de *Backpropagation Multilayer Perceptrons* e uma GRNN.

A mais simples MLP (MLP-3Camadas) foi a com 3 camadas com uma função logística de ativação na camada oculta e na camada de saída. A camada de entrada apenas dimensiona e distribui as entradas. De acordo com os dados de treinamento, a camada de entrada tem 4 neurônios e a camada de saída tem 1 neurônio. Já a camada oculta é composta por 60 neurônios.

Já a segunda MLP (MLP-5Camadas) foi com 5 camadas e também com uma função logística de ativação de suas camadas ocultas e de saída. Em conformidade com os padrões de treinamento, ela tem 4 neurônios na camada de entrada e 1 na camada de saída. Nas 3 camadas ocultas são compostas por 20 neurônios cada.

A GRNN usa em seu treinamento uma passagem apenas e sua arquitetura é moldada de acordo com o conjunto de dados de treinamento, ou seja, a camada oculta tem 1 neurônio para cada padrão de treinamento. Entretanto, o *smoothing factor* é um parâmetro crítico para uma boa generalização. Consequentemente, a GRNN utilizada aqui foi otimizada com um Algoritmo Genético destinado a encontrar o melhor *smoothing factor* para o conjunto de dados de teste selecionado.

4.2.2 Resultados, análises e conclusões do pré-processamento

Sendo assim, nessa seção são apresentados resultados numéricos obtidos a partir do desenvolvimento, do treinamento e da aplicação da RNA proposta. Esses resultados são avaliados, comparados e discutidos. Na Tabela 4 é exibida a comparação dos resultados obtidos por cada arquitetura de RNA quando aplicados os padrões de produção.

Tabela 4. Estatísticas do pré-processamento com padrões de produção

Arquitetura	Correlação	Erro Máximo	Média Erro	Tempo
MLP-3Camadas	0,978	132,859	2,869	4:59 h
MLP-5Camadas	0,990	125,594	1,045	2:37 h
GRNN	0,986	137,551	1,477	0:23 h

Os tempos de treinamento na Tabela 4 (última coluna) são exclusivamente para comparação. Como cada treinamento desse pré-processamento foi feito numa Máquina Virtual com o Sistema Operacional Windows XP 32 bits, os tempos não refletem o desempenho absoluto do treinamento.

Sendo assim, pode-se observar que as melhores estatísticas foram obtidas pela MLP-5Camadas. Os erros e a correlação para o conjunto de padrões de produção demonstram uma ótima generalização (habilidade de prever padrões não-treinados). Por outro lado, a GRNN que apresenta uma correlação e média de erro

não tão boas quanto a MLP-5Camadas, porém, foi a rede treinada mais rapidamente (aproximadamente 6,8 vezes mais rápida do que a MLP-5Camadas).

A MLP-3Camadas foi a pior com um coeficiente de correlação de 0,978 (o que não é todo ruim), com uma média de erro de quase 3 vezes e um tempo de treinamento de aproximadamente 2 vezes maior do que a MLP-5Camadas.

Da Figura 13 a Figura 18 pode-se observar graficamente a influência dos números mostrados na Tabela 4 na previsão das doses usando os padrões de produção.

Nota-se que nas Figura 13, Figura 14 e Figura 15, para altos valores de saída (dose), o ajuste entre o valor simulado e o valor previsto pela RNA é bom para todas as arquiteturas, porém, com certa vantagem para a MLP-5Camadas.




Figura 13. Plotagem do maior valor de saída (dose). Valor simulado *versus* previsto pela RNA MLP-3Camadas




Figura 14. Plotagem do maior valor de saída (dose). Valor simulado *versus* previsto pela RNA MLP-5Camadas




Figura 15. Plotagem do maior valor de saída (dose). Valor simulado *versus* previsto pela RNA GRNN

Entretanto, para valores pequenos de saída (dose), significantes discrepâncias podem aparecer. A Figura 16, Figura 17 e Figura 18 mostram o conjunto de dados de produção que a saída deveria ser zero. É necessário observar que todas as arquiteturas apresentam valores não nulos. A saída da MLP-3Camadas obtém valores próximos de 11, enquanto a MLP-5Camadas apresentam valores perto de 1,1 e a GRNN tem valores encontrados na vizinhança de 0,8.




Figura 16. Plotagem dos menores valores de saída (dose). Valores previstos pela RNA MLP-3Camadas




Figura 17. Plotagem dos menores valores de saída (dose). Valores previstos pela RNA MLP-5Camadas




Figura 18. Plotagem dos menores valores de saída (dose). Valores previstos pela RNA GRNN

Olhando por esse aspecto, a GRNN parece ser a melhor opção, porém, analisando mais profundamente nos ajustes gerais para altos valores de saída, a MLP-5Camadas é levemente melhor.

Sendo assim, os resultados para esse pré-processamento concluíram que a *Backpropagation Multilayer Perceptron* com 5 camadas (MLP-5Camadas) é a melhor opção em termos de generalização com o melhor coeficiente de correlação (0,990) e a menor média de erros. Já a GRNN é eficiente para mapear funções contínuas, embora ela apresente coeficiente de correlação e média de erros não tão bons. E ela possui duas vantagens a serem consideradas até aqui: rápido treinamento (otimização do *smoothing factor*) e um melhor ajuste para a previsão de taxa de doses que são muito próximas de zero, por exemplo.

4.2.3 Preparação do conjunto de dados para treinamento, teste e produção

Todos os padrões de treinamento, teste e produção foram, também, gerados usando o Sistema de Dispersão Atmosférica da CNAAA que, (em modo de simulação) pode ser usado para simular cenários customizados para um conjunto de acidentes postulados e condições atmosféricas observadas.

Nessa seção, será apresentada a preparação do conjunto de dados para treinamento, teste e produção do processamento da proposta inicial de trabalho.

A Tabela 5 e Tabela 6 mostram os intervalos e a distribuição de cada variável dos conjuntos de padrões de treinamento e teste, respectivamente.

Tabela 5: Faixas de valores e distribuição do conjunto de dados de treinamento

	Amplitude	Valores	Intervalo
Velocidade do vento (m/s)	1-5	5	1
Direção do vento (graus)	135-225	5	22,5
Posição X	1-65	17	4
Posição Y	10-42	9	4

Tabela 6: Faixas de valores e distribuição do conjunto de dados de teste

	Amplitude	Valores	Intervalo
Velocidade do vento (m/s)	1.5-4.5	4	1
Direção do vento (graus)	146-214	5	22,5
Posição X	1-65	17	4
Posição Y	10-42	9	4

Observe que os intervalos de velocidade do vento (em m.s^{-1}) do conjunto de dados para treinamento e para teste são diferentes. Nessa etapa de trabalho, com o objetivo de melhorar o desempenho de treinamento das RNAs, não foi utilizada a mesma esquematização do pré-processamento descrito na seção 4.2.1. As velocidades utilizadas para treinamento foram: 1 m.s^{-1} , 2 m.s^{-1} , 3 m.s^{-1} , 4 m.s^{-1} e 5 m.s^{-1} . E para o conjunto de testes, foram utilizados as velocidades intermediárias às de treinamento sendo elas: $1,5 \text{ m/s}$, $2,5 \text{ m/s}$, $3,5 \text{ m/s}$ e $4,5 \text{ m/s}$, totalizando 4 velocidades diferentes. Da mesma forma, foram utilizados ângulos diferentes (direção do vento) para treinamento e teste. A Figura 19 faz uma melhor representação da disposição dos ângulos utilizados para teste e treinamento.




Figura 19. RN-Norte com os ângulos para treinamento (em branco) e teste (em vermelho).

A Figura 20 demonstra os pontos X e Y escolhidos para comporem os conjuntos para treinamento e teste para a RNA-Norte.

4.3 APLICAÇÃO DA REDE NEURAL ARTIFICIAL E SUA AVALIAÇÃO

Como mencionado, nesse trabalho enfatizamos as investigações para encontrar arquiteturas de RNAs mais adequadas para a aplicação proposta começando dos resultados obtidos em investigações preliminares descritos na seção 4.2.1. Confirmando resultados anteriores, depois de dezenas de experimentos com diferentes números de camadas (de 3 a 5), neurônios por camada e funções de ativação, uma MLP de 5 camadas obteve a melhor previsão enquanto a GRNN apresentou o treinamento mais rápido. As características dessas RNAs utilizadas foram sumarizadas na Tabela 8.

Tabela 8: Características das RNAs

Arquitetura	Características
MLP de 5 Camadas	- Camadas: 5 - Camada de entrada: 4 neurônios (linear) - Camada oculta 1: 40 neurônios (logístico) - Camada oculta 2: 40 neurônios (logístico) - Camada oculta 3: 40 neurônios (logístico) - Treinamento: backpropagation
GRNN	- Camadas: 4 - Camada de entrada: 4 neurônios (distribuição) - Camada intermediária (oculta): 3825 neurônios (Gaussiano) - Camada de Soma (oculta): 2 neurônios (soma) - Camada de Saída: 1 neurônio - Otimização do <i>smoothingfactor</i>: Algoritmo Genético

4.3.1 Estatísticas de Treinamento das RNAs

Nas Tabela 9 e Tabela 10 são mostradas algumas estatísticas obtidas aplicando a GRNN e a MLP de 5 Camadas, respectivamente, para cada conjunto de dados.

Os coeficientes de correlação e as métricas estatísticas de erros (média de erro absoluto e máximo erro absoluto) nas Tabela 8 e Tabela 9 são bons, especialmente para o conjunto de produção demonstrando uma generalização muito boa (habilidade de prever padrões não treinados) de ambas as RNAs.

Tabela 9: Estatísticas de treinamento da GRNN

	Conjunto de Treinamento	Conjunto de Teste	Conjunto de Produção
Número de Padrões	3825	2448	6120
Média de erro absoluto	0.011	1.810	1.217
Máximo erro absoluto	1.088	74.060	98.538
Coeficiente de Correlação	1.000	0.9822	0.9882
Gerações (população=20)	31		
Tempo de treinamento	00:19 h		

Tabela 10: Estatísticas de treinamento da MLP de 5 Camadas

	Conjunto de Treinamento	Conjunto de Teste	Conjunto de Produção
Número de Padrões	3825	2448	6120
Média de erro absoluto	0.691	1.113	1.050
Máximo erro absoluto	28.772	82.884	98.065
Coeficiente de Correlação	0.9980	0.9906	0.9909
Épocas	40,000		
Tempo de treinamento	04:30 h		

Perceba que MLP de 5 Camadas foi um pouco melhor nos conjuntos para teste, treinamento e também de produção. Por outro lado, a GRNN tem uma ótima aproximação no conjunto de treinamento. Essa é uma característica esperada de

RNAs devido ao fato de que as funções de ativação da camada intermediária (Gaussianas) são centradas em cada padrão de treinamento (um neurônio é designado na camada oculta para cada padrão de treinamento). Além de que o *smoothing factor* é então otimizado para caber nos padrões de teste. Notavelmente, a GRNN apresenta uma grande vantagem em termos de tempo de treinamento.

4.3.2 Previsão da distribuição espacial de dose

Com o objetivo de obter o resultado final que é obter o mapa de distribuição de dose sendo executadas numa plataforma móvel, as RNAs foram adaptadas a plataforma Android (Linguagem Java) e assim, implementadas junto ao aplicativo proposto que foi mostrado na Figura 12.

Uma vez a RNA adaptada e implementada ao aplicativo para *smartphone*, para a plotagem do mapa de acordo com as condições climáticas além da identificação do acidente em ocorrência, a RNA foi executada para cada ponto no espaço geográfico do mapa em que o SCA tem sua abrangência.

A Figura 21 mostra o mapa gerado pelo simulador de dispersão atmosférica (usado como referência) para um vento a $2,5 \text{ m.s}^{-1}$ e a 326° para um hipotético acidente (termo fonte). Deve ser enfatizado que para a execução da RNA no aplicativo, foram utilizados dados não treinados (produção). As Figura 22 e Figura 23 mostram, respectivamente, previsões obtidas pelas MLP de 5 Camadas e GRNN. Valores abaixo de $10^{-2} \text{ mRem.h}^{-1}$ foram considerados nulos.




Figura 21. Mapa gerado pelo simulador




Figura 22. Mapa Gerado pela MLP de 5 Camadas




Figura 23. Mapa gerado pela GRNN




Figura 24. Escala de doses

Nota-se que, embora as estatísticas de treinamento das RNAs sejam muito boas e muito similares para ambas as RNAs, diversas discrepâncias são visíveis numa primeira análise ocular.

No mapa de distribuição espacial de dose da MLP de 5 Camadas (Figura 22), inúmeros pontos no mapa, que deveriam ter valores de taxa de dose nulas, apresentam pequenos valores (regiões em verde claro) inclusive em regiões impróprias. Por outro lado, regiões com altas doses (outras cores) apresentam previsão satisfatória. No caso da GRNN, as discrepâncias aparecem onde há taxas de doses altas (as regiões onde há valores altos, a GRNN expande indo muito além do que se é esperado no limite da pluma). Porém, a GRNN é mais coerente na previsão dos limites da pluma. Ela não espalha valores pequenos para regiões impróprias naquelas taxas de dose que são supostamente nulas.

Considerando cada limitação da previsão das RNAs, alguns ajustes são propostos. Visando eliminar a indicação de falsas doses em regiões que supostamente tem taxas de doses nulas, um limiar foi definido para considerar as taxas de dose iguais a zero. Empiricamente, experimentos demonstraram que 0,5 mRem/h (menos que 0.1% do máximo valor de saída do conjunto de dados de treinamento) foram adequados. O resultado da aplicação deste corte é mostrado na Figura 26 e Figura 27.

Perceba que embora algumas discrepâncias ainda possam ser observadas entre o mapa simulado e o mapa gerado pelas RNAs, a informação é qualitativamente importante ao suporte nas decisões de campo se o Sistema de uma Central Nuclear não estiver disponível. A previsão da MLP de 5 Camadas parece ser mais próxima ao mapa simulado.




Figura 25. Mapa gerado pelo simulador




Figura 26. Mapa gerado pela MLP de 5 Camadas com corte




Figura 27. Mapa gerado pela GRNN com corte




Figura 28. Escala de doses

4.4 EXECUÇÃO DAS RNA NA PLATAFORMA ANDROID

Nessa seção, é mostrado os resultados do desempenho da RNA executada num smartphone com a plataforma *Android*. Nesse caso, utilizou um smartphone comercial Samsung J5 com processador *Quad Core* (Qualcomm Snapdragon) com 1.2 GHz e 2 Gb de RAM.

A Tabela 11 mostra o tempo de execução de cada RNA no sistema especificado para reconstruir o mapa e plotar a distribuição de dose. Lembrando que a RNA precisa ser executada 2881 vezes (uma vez para cada posição no mapa que tem 43 x 67 células).

O tempo de execução da RNA MLP de 5 camadas treinada com a plotagem do mapa foi de 5 segundos. Já para a GRNN, foram consumidos 25 segundos.

Tabela 11: Tempo de execução na geração do mapa de doses

	Tempo de execução (segundos)
MLP de 5 camadas	5
GRNN	25

Note também que a execução da GRNN consome um tempo bem maior quando é comparada a MLP de 5 Camadas utilizada. Este fato é esperado devido ao grande número de neurônios necessários na camada intermediária (oculta). A GRNN é composta de 3832 neurônios ao total enquanto a MLP de 5 camadas tem apenas 125.

Embora a MLP de 5 Camadas necessite de mais tempo para treinamento (4 h e 30 minutos), considerando o mapa gerado com as previsões de doses e o tempo de execução associado para gerá-lo, a MLP de 5 Camadas parece ser bem melhor que a GRNN.

5 CONCLUSÕES FINAIS

Neste trabalho, um sistema móvel para previsão de doses baseado em RNAs foi proposto, desenvolvido e avaliado. Investigações preliminares apontaram que a MLP de 5 Camadas e a GRNN são ótimas opções. Essas duas arquiteturas foram, então, utilizadas no desenvolvimento de um sistema móvel de celular destinado a gerar um mapa de distribuição de dose para suporte à decisão por parte de equipes de emergências quando os dados da central nuclear e seus sistemas estiverem indisponíveis.

Como foi verificado neste trabalho, as estatísticas de ambas, MLP de 5 camadas e a GRNN, são bem similares em termos de magnitude de erros e coeficientes de correlação. Embora, como mostrado aqui, os mapas gerados por cada RNA são um pouco diferentes. A MLP de 5 camadas apresenta mais erros quando a taxa de dose deve ser nula enquanto a GRNN apresenta mais erros em altos valores de dose. Com o objetivo de aprimorar o mapa, um limite de 0,5 mRem/h foi imposto para definir os pontos de doses nulas.

Comparando os mapas gerados pelo conjunto de dados para produção (dados não treinados) com o mapa simulado (referência), uma melhor representação gráfica foi obtida pela MLP de 5 camadas enquanto a GRNN não interpolou o conjunto de dados de treinamento com transições suáveis conduzindo assim a uma não tão satisfatória resolução espacial.

Depois de avaliar a precisão das RNAs em suas previsões, a diversas execuções em *smartphones* comerciais usando a plataforma *Android* foi aferida. Ressaltando, novamente, que para cada mapa de distribuição de doses gerado, é necessária a execução da RNA 2881 vezes. Para realizar isso, a MLP de 5 camadas leva 5 segundos enquanto a GRNN leva 25 segundos, em média. Uma grande diferença na execução, mas que se é esperado devido à quantidade de neurônios necessários para cada tipo de RNA (MLP de 5 camadas: 125 neurônios apenas; GRNN: 3832 neurônios).

Em resumo, pode-se concluir que um sistema móvel de previsão de doses usando uma MLP de 5 Camadas atinge uma boa precisão na previsão do mapa de doses com num tempo curto de execução.

6 TRABALHOS FUTUROS

Este trabalho é o primeiro passo nas investigações da viabilidade de desenvolvimento de sistemas móveis de previsão de doses para *smartphones* baseados em RNA ainda tão defasado em sua utilização.

O sistema seria completo se outras variáveis como, por exemplo, o tempo depois que o acidente se inicia fosse considerado. Porém, para incluir mais variáveis como entradas da RNA, o tamanho do conjunto de padrões para treinamento e testes dessas RNAs cresceria de uma maneira em que as RNAs não seriam capazes de lidar. Para superar essas limitações, o uso de modelos de Aprendizagem Profunda, como *Deep Nets* em conjunto com o uso de técnicas de processamento paralelos podem ser o caminho a ser seguido.

Além disso, seria de grande utilidade que o aplicativo desenvolvido não só esteja disponível para equipes de emergências ligadas a CNAAA, mas também para a população em geral, principalmente, aquela que se encontra no raio de abrangência do SCA e dos Planos de Emergências. Dessa forma, a obtenção de dados meteorológicos de fontes externas (*sites* de informações meteorológicas) faria com que o aplicativo fosse muito mais realístico e possível ao uso de pessoas não-técnicas.

7 REFERÊNCIAS

CALIFORNIA AIR RESOURCES BOARD AND THE CALIFORNIA ENERGY RESOURCES CONSERVATION AND DEVELOPMENT COMMISSION. Point Source Model Evaluation and Development Study – The Grid Model IMPACT (Integrated Model for Plumes and Atmospherics in Complex Terrain). FABRICK, A.; SKLAREW, R.; WILSON, J. **Technical Report (Contract A5-058-87)**. [S.l.]: [s.n.], 1987.

CAO, X., ROY, G., HURLEY, W.J. AND ANDREWS, W. S. Modeling the Concentration Distributions of Aerosol Puffs Using Artificial Neural Networks. **Boundary-Layer Meteorology**, 136(1):83-103, 2010 (DOI: 10.1007/s10546-010-9501-)

COPPE/UFRJ - NUCLEAR, LABORATÓRIO DE ANÁLISE E SEGURANÇA. **SCA-MOD Sistema de Controle Ambiental - Modelagem**. Rio de Janeiro: [s.n.], v. 4, 1987.

ELETRONUCLEAR. **Informações sobre o plano de emergência das usinas nucleares de Angra dos Reis. 2011.** Disponível em: <<http://www.eletronuclear.gov.br/Not%C3%ADcias/NoticiaDetalhes/tabid/191/NoticiaID/322/D>>. Acessado em: 10/04/2018.

FURNAS CENTRAIS ELÉTRICAS S.A. **Especificação Funcional do Sistema de Controle Ambiental (SCA)**. Rio de Janeiro: [s.n.], 1987.

GOLDBERG, D. E., Genetic Algorithms in Search, Optimization and Machine Learning, New York, **Addison-Wesley**, 1989.

HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. Second Edition. Prentice Hall, 1999.

HOSSAIN, K. M. A. Predictive Ability of Improved Neural Network Models to Simulate Pollutant Dispersion **International Journal of Atmospheric Sciences**, 2014 (<http://dx.doi.org/10.1155/2014/141923>)

LAURET, P., HEYMESA, F., APRINA, L., JOHANNETB, A., DUSSERREA, G., MUNIERC, L., LAPÉBIEC, E. Near Field Atmospheric Dispersion Modeling on an Industrial Site Using Neural Networks. **Chemical Engineering Transactions**, vol.31, 2013

MÓL, A. C. A., PEREIRA, C. M. N. A. FREITAS, V. G. G. AND JORGE, C. A. F. Radiation dose rate map interpolation in nuclear plants using neural networks and virtual reality techniques, **Annals of Nuclear Energy**, 38, pp.705–712, 2011.

PARZEN E. On estimation of a probability density function and mode. Ann. **Math Statist.**, vol.33, pp.1065-1076, 1962.

PEREIRA, C.M.N.A., SCHIRRU, R., GOMES, K.J., CUNHA, J.L., Artificial Neural Networks for Radiation Dose Prediction in Nuclear Emergencies: Preliminary Investigations. *Advances in Computer Science Research* (ISSN 2352–538X), **Atlantis Press**, 2016

PEREIRA, C.M.N.A., SCHIRRU, R., GOMES, K.J., CUNHA, J.L., Development of a mobile dose prediction system based on artificial neural networks for NPP emergencies with radioactive material releases. **Annals of Nuclear Energy**, 105, pp.219–225, 2017.

SARWAT, E. AND HELAL, N. General Regression Neural Networks for Estimating Radiation Workers Internal Dose. **Arab Journal of Nuclear Science and Applications**, 46(1), (374-380), 2013.

SILVA, A. J. D., SANTOS, J. R. , PEREIRA, C. M. N. A. AND CARVALHO, P. V. R. A Mobile Computer System to Support First Responders to a Radiological Emergency. **International Nuclear Atlantic Conference - INAC 2013**, Brazil, pp.24-29, 2013 (ISBN: 978-85-99141-05-2)

SPECHT, D. F. A General Regression Neural Network. **IEEE Transactions on Neural Networks**.vol.2, n.6, 1991

TIMONIN, V. AND SAVELIEVA, E. Spatial Prediction of Radioactivity using General Regression Neural Networks. **Applied GIS**, vol.1, n.2, Monash University EPress, 2005.

WORLD NUCLEAR ASSOCIATION. **World Nuclear Performance Report 2017**.Inglaterra [s.n], 2017.