



Rede Neural e Processamento De Imagem Aplicados Em Um Sistema De Detecção e Alarme De Incêndio



Gilmar Alves de Aguiar Filho, Jim Jones da Silveira Marciano
Faculdade Presidente Antônio Carlos de Conselheiro Lafaiete
Engenharia de Controle e Automação

Resumo – Este trabalho apresenta uma abordagem alternativa para sistemas de detecção e alarme de incêndio em ambientes industriais. Esta estratégia inteligente (Rede Neural Artificial Cascade-Forward Backpropagation) apresentada no artigo possibilitou o sistema distinguir se o ambiente está com partículas de fumaça ou poeira e consequentemente evitando alarmes falsos nos testes realizados. Os resultados obtidos são promissores uma vez que o sistema de detecção e alarme de incêndio inteligente proposto tem uma resposta mais eficaz se comparado aos sistemas de detecção e alarme de incêndio convencionais.

Palavras Chave – Retropropagação em Cascata, Redes Neurais Artificiais, Sistema de Detecção de Incêndio.

I. SIGLAS

CFBP - Cascade-Forward Backpropagation;
CONIPC - Congresso Nacional de Inciciação a Pesquisa Científica;
FFBP- Feed-Forward Backpropagation;
IP- *Internet Protocol*;
LOG - Registro de Eventos;
PPM - Partículas por milhão;
PCA - Análise de Componentes Principais;
RGB - *Red Green Blue*;
RNA - Rede Neural Artificial;
SDAI - Sistema de Detecção e Alarme de Incêndio;
VCC - *Volt Corrente Contínua*.

II. INTRODUÇÃO

Em situações de incêndio, o abandono rápido e seguro dos ocupantes de um edifício é o principal objetivo dos Sistemas de Detecção e Alarme de Incêndio. Visando diminuir o tempo para detectar o incêndio e o número de alarmes falsos gerado por poeira, este artigo busca técnicas que permitam melhorar as respostas de sistemas convencionais de detecção e alarme de incêndio [1].

Um estudo feito nos Estados Unidos da América no ano de 2008, nos locais que não possuíam Sistema de detecção e alarme de incêndio, as estatísticas mostram que 3.667 pessoas perderam a vida em incêndios; 17.925 pessoas ficaram feridas; 115 bombeiros foram mortos; o incêndio mata mais americanos do que todos os desastres naturais juntos; as mortes em

incêndios residenciais representam 83%; em um ano foram registradas 1,6 milhões de ocorrências; o valor estimado das perdas resultantes de incêndios ultrapassam os US\$ 10,7 bilhões de dólares; a cada 31.500 incêndios ocorre a morte de 315 pessoas [2].

A estrutura do sistema de detecção e alarme incêndio é composta por centrais e repetidoras (controladores microprocessados) interligdos entre si. Os detectores (sensores) e acionadores manuais ou automáticos, estão conectados a esses controladores, quando os sensores detectam fumaça ou calor, a central de alarme de incêndio poderá localizar facilmente o setor afetado, e tomar as medidas cabíveis. A Calibração dos detectores pode ser feita na própria central. Entre os principais detectores automáticos de incêndio podem ser citados os; de fumaça (ópticos ou iônicos), que detectam a presença de particulado ou fuligem no ar; os termovelocimétricos, que detectam a variação de temperatura; e os de calor [3].

Denomina-se também como sistema de detecção e alarme de incêndios, por um painel eletromecânico que disponibiliza pelo menos um laço (circuito elétrico) em 24 VCC. Se neste laço convencional um dispositivo (como sensores de fumaça, sensor de calor, etc) qualquer for atuado, será possível identificar no painel convencional que o laço está em alarme. A forma de reconhecimento pelo painel é feita por comparativo de queda de tensão no circuito, ou seja, se um dispositivo qualquer for atuado, um resistor limitará a tensão no circuito elétrico. Este sistema apresenta como sua principal desvantagem, a não identificação de um segundo evento, ou seja, qualquer outro dispositivo que for acionado no laço não será identificado, pois o circuito já apresenta uma queda de tensão do primeiro dispositivo. Então para saber qual dispositivo foi acionado, terá que ser feita uma confirmação visual no local [4].

Intitula-se também como sistema endereçável de detecção e alarme de incêndios quando é utilizado um painel eletrônico que disponibiliza pelo menos um circuito elétrico, que possibilita a instalação de um número limitado por norma de dispositivos de detecção de alarmes de incêndios, a saber, 256 dispositivos como acionadores de manuais de alarmes, detectores de fumaça etc., onde cada um dos dispositivos ligados no laço endereçável tem um endereço lógico único. O reconhecimento pelo painel é feito através de um protocolo de comunicação (*software*), e não mais por queda de tensão como no sistema apresentado anteriormente, ou seja, se qualquer dispositivo for atuado, o protocolo de comunicação fará com que o painel endereçável reconheça exatamente qual foi o dispositivo atuado, qual foi o tipo de evento ocorrido (alarme

de fogo ou falha), data e hora do evento, armazenando essas ações em um *LOG* [4].

Dentre os meses de Outubro de 2017 à Janeiro de 2018, foi realizado um levantamento na empresa *X*¹, a pesquisa revelou que o *SDAI* instalado em um ambiente industrial, alarmou 39 vezes devido ao elevado número de partículas de poeira no ambiente. Do número total de alarmes falsos gerados pela poeira, 13 aconteceram no mês de Outubro, 9 no mês de Novembro, 9 no mês de Dezembro e 8 no mês de Janeiro. O elevado número de alarmes falsos ocasionados por poeira no ambiente industrial, foi a motivação para tentar implementar um sistema de detecção e alarme de incêndio convencional.

Este trabalho visa aperfeiçoar a implementação de sistemas de detecção e alarme de incêndio já existentes, fazendo destes mais eficazes. Para possibilitar tal implementação foram utilizadas as técnicas subsequentes: *RNAs*, para realizar o reconhecimento e a classificação de padrões, tratamento de imagem para facilitar o processamento da *RNA*, e a *PCA* para melhorar a computação da rede neural. Ressalta-se que processamento de imagem é um trabalho complexo e requer *hardware* compatível. A proposta ostentada acima, apresenta resultados promissores e estes já receberam um aceite da comunidade científica, uma vez que a pesquisa foi publicada como resumo no VII *CONIPC* [5].

Este artigo está organizado da seguinte forma: a seção III apresenta a uma revisão bibliográfica sobre o que é Processamento de Imagem, sobre o que é *RNA*, sobre o que é *RNA CFBP*; a seção IV apresenta detalhadamente todo o desenvolvimento do projeto, bem como seus componentes e técnicas utilizadas; a seção V detalha os resultados do treinamento da rede, descreve também os resultados da validação e dos testes realizados, exemplificando onde a rede obteve mais acertos e também erros. A seção VI apresenta a conclusão.

III. REVISÃO BIBLIOGRÁFICA

A. Processamento de Imagens

Uma imagem digital é uma matriz de valores onde cada elemento é chamado de *pixel*. No caso de imagens em tons de cinza tem-se cada *pixel* correspondente a valores entre 0 e 255, onde *pixels* com valores próximos de zero são predominantes preto e *pixels* com valores próximos a 255 predominantes brancos. Em imagens coloridas, cada *pixel* possui 3 valores um para cada canal R (vermelho) G (Verde) B (Azul) [6].

Para tratar a imagem, alguns processos de pós-escaneamento podem ser realizados. O termo ‘processos de pós-escaneamento’ é utilizado para descrever várias técnicas de aprimoramento de imagem usando *hardware* ou *software* que podem ter singularmente ou independentemente um efeito na apresentação da saída de imagem e no tamanho do arquivo armazenado [7].

As técnicas mais comuns incluem [7] :

- Ajuste de tamanho;

- Remoção de pontos ou manchas de fundo;
- Remoção de bordas pretas;
- Transformação em tons de cinza.

O processamento de imagem tem como objetivo atuar sobre a informação digital das imagens, permitindo ao observador humano uma melhor análise e interpretação do seu conteúdo informativo ou a preparação para armazenamento e transmissão da imagem [8].

Um exemplo de tratamento da imagem pode ser visto na fig. 2 e na fig. 4, que são um produto da aplicação do fator de escalonamento e a transformação em tons de cinzas, nas figs. 1 e 4.

A fig. 1 representa o ambiente com poeira antes do tratamento da imagem e a fig. 2 representa o mesmo ambiente após o tratamento da imagem.



Fig. 1. Imagem do ambiente com poeira antes de passar pelo fator de escalonamento e transformação em tons de cinza.



Fig. 2. Imagem do ambiente com poeira pós-processamento.

¹ Por motivos de direitos autorais, tivemos que denominar como empresa *X*, a corporação onde foi realizado o estudo sobre o *SDAI*.

A fig. 3 representa o ambiente com fumaça antes do tratamento da imagem e a fig. 4 representa o mesmo ambiente após o tratamento da imagem.



Fig. 3. Imagem do ambiente com fumaça antes de passar pelo fator de escalonamento e transformação em tons de cinza.



Fig. 4. Imagem do ambiente com fumaça pós-processamento

B. Rede Neural Artificial

Uma *RNA* é um processador distribuído, constituído de unidades de processamento simples (conhecidas como neurônios), que tem a capacidade para armazenar conhecimento experimental e torná-lo disponível para uso. A *RNA* se assemelha ao cérebro humano em dois aspectos [9]:

1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.
2. Força de conexão entre os neurônios, conhecidos como pesos sinápticos, são utilizadas para armazenar conhecimento adquirido.

O Processo de treinamento é uma das partes mais importantes das redes neurais, cuja função é modificar os pesos sinápticos da *RNA* de forma ordenada para alcançar o objetivo de processo desejado. A modificação dos pesos pode ser do modo padrão ou do modo *batch*. No modo padrão a correção dos pesos é feita a cada apresentação de um exemplo do conjunto à rede, já no modo *batch* a apresentação é feita por ciclo, ou seja, a correção é feita quando todos os exemplos do conjunto são apresentados a rede [9]. Esta abordagem é bastante próxima a teoria dos filtros adaptativos lineares, que já está bem definida e foi aplicada em diversas áreas [10], [11]. Entretanto, é possível também para uma modificar sua própria topologia, o que é motivado pelo fato de os neurônios poderem morrer e que novas conexões sinápticas possam acontecer [9].

C. Rede Neural Artificial Cascade-Forward Backpropagation

As *RNAs CFPB* são semelhantes as *RNAs FFBP*. A rede *FFBP* apresenta uma ou mais camadas ocultas (camadas de processamento), cujos nós computacionais são chamados de neurônios ocultos ou unidades ocultas. A função dos neurônios é atuar entre a camada de entrada e a camada de saída da rede, abstraindo e armazenando todo o conhecimento dos dados. Adicionando-se uma ou mais camadas de processamento, a rede torna-se capaz de extrair estatísticas de ordem elevada. Em um sentido bastante livre, a rede adquire uma perspectiva global apesar de sua conectividade local. A habilidade de os neurônios ocultos extrair estatísticas de ordem elevada é particularmente valiosa, pois esta competência influencia diretamente na capacidade de abstração da rede [9].

A *CFBP* e a *FFBP* utilizam o mesmo algoritmo de aprendizado, o *Backpropagation* (retropropagação), este algoritmo caracteriza-se por realizar a correção dos pesos, da camada de saída para a camada de entrada da rede, e apresenta dois parâmetros importantes com relação a correção dos pesos: o primeiro sendo denominado *Momentum*, que mede a resistência que os neurônios apresentam ao trocar o sentido de ajuste de um peso, durante o processo de treinamento da rede neural. O segundo sendo denominado *Learning Rate*, que controla a rapidez com que os pesos são alteráveis durante o processo de treinamento da *RNA* [12].

Embora ambas as redes utilizem o algoritmo de retropropagação, o que difere as duas como apresentado no esquemático da fig. 5 e da fig. 6, é que a *RNA CFPB* possui uma conexão de entrada adicional de todas as camadas anteriores às camadas seguintes. Por exemplo, uma rede *CFBP* de três camadas, tem conexões da camada 1 para a camada 2, da camada 2 para a camada 3, da camada 1 para a camada 3, e todas essas camadas recebem uma conexão da camada de entrada [13].

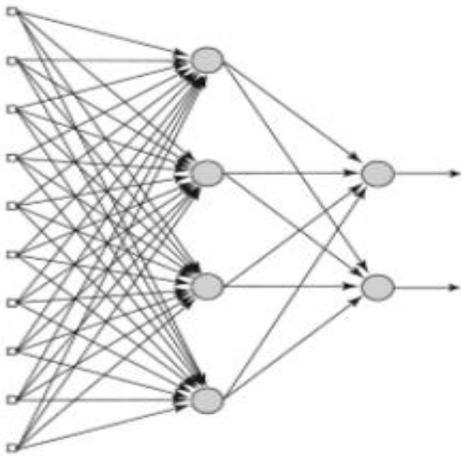


Fig. 5. Esquemático de uma RNA FFBP. [13]

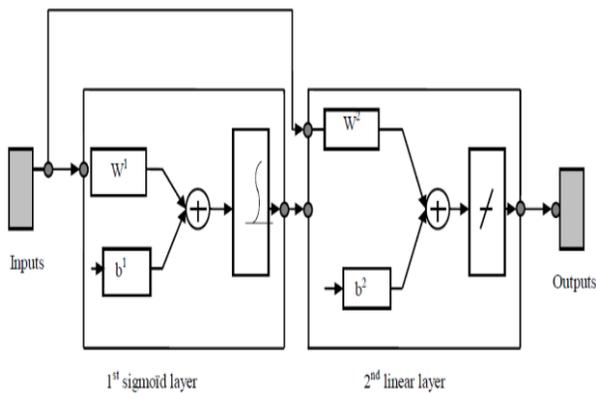


Fig. 6. Esquemático de uma RNA CFBP. [14]

Levando em consideração as diferentes análises, será apresentado de forma objetiva, a metodologia utilizada no processo de treinamento [14]:

- Processo de aprendizagem utilizando o método *Propagation Forward*.

$$\begin{aligned} a^0 &= p(q) \\ a^k &= f^k(W^k * a^{k-1} - b^k), \quad (1) \\ k &= 1, \dots, M \end{aligned}$$

- Processo de aprendizagem utilizando o método *Backpropagation*.

$$\begin{aligned} \delta^M &= (-2F'^M) * (n^M) * (d(q) - a^M) \\ \delta^K &= F'^K * (n^K) * (W^{K+1})^T * \delta^{K+1}, \\ k &= M - 1, \dots, 1 \end{aligned} \quad (2)$$

- Ajuste dos pesos e do *bias* (polarização).

$$\begin{aligned} \Delta W^k &= \eta \delta^K (a^{k-1})^T, K = 1, \dots, M \\ \Delta b^k &= \eta \delta^k, K = 1, \dots, M \end{aligned} \quad (3)$$

Vetor de saída do neurônio (a);

Bias (b);

Função de transferência (f);

Função de desempenho (F');
 Vetor de saída desejado ($d(q)$);
 Número de camadas da rede (M);
 Amostras de entrada da rede ($p(q)$);
 Pesos dos neurônios (W);
 Taxa de aprendizado (η);
 Sensibilidades (δ).

Na fig. 7 é apresentado o diagrama que descreve as diferentes etapas do processo de treinamento da RNA CFBP.

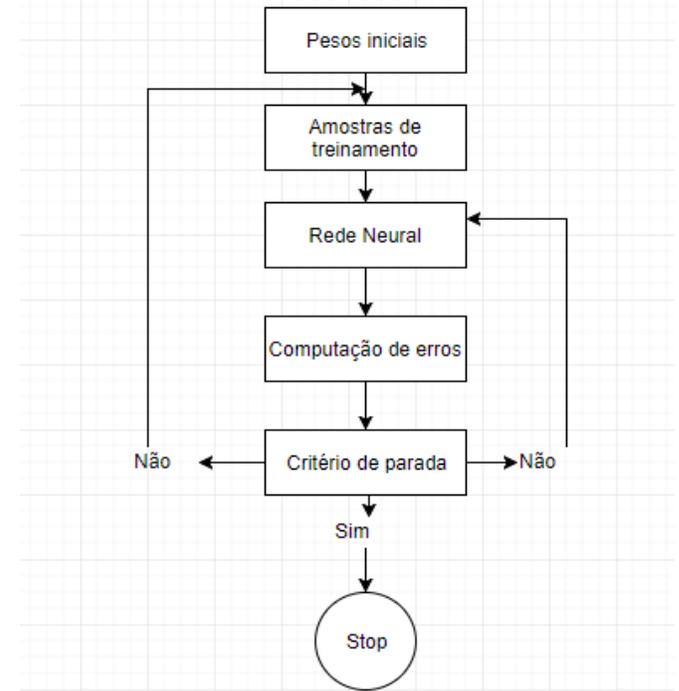


Fig. 7. Diagrama do processo de treinamento da rede neural artificial. [14]

Com os pesos iniciais aleatório da rede, as amostras para treinamento são apresentadas a RNA. Após o treinamento de cada amostra ocorre uma comparação entre a saída da rede neural e o vetor de saída desejado. Utilizando esta comparação é feito a computação dos erros. O treinamento é finalizado se os erros anteriormente mencionados atenderem aos critérios de parada. Caso os erros não atendam aos critérios de parada ocorre então um ajuste de pesos da camada de saída para a camada de entrada e a RNA recomeça o processo novamente. Esse ciclo ocorrerá até o critério de parada ser atingido [14].

Para justificar o uso de RNAs juntamente com processamento de imagens, será evidenciado o título de alguns trabalhos que usam soluções similares e obtiveram ótimos resultados. Reconhecimento da Variedade de Soja por meio do Processamento de Imagens Digitais Usando Redes Neurais Artificiais [15]. Reconhecimento de Imagens Digitais Utilizando Redes Neurais Artificiais [16]. Utilização de Redes Neurais na Classificação de Níveis de Degradação em Pastagens [17]. Uma Rede Neural Artificial para a Classificação de Imagens Multiespectrais de Sensoriamento Remoto [18]. Uso de Redes Neurais em Visão Computacional e Processamento de Imagens [19]. Diagnostico Auxiliado por Computador na Radiologia [20]. Classificação Automática e

Análise de Dados por Redes Neurais Auto Organizáveis [21]. Reconhecimento Automático de Placas de Veículos Automotores Através de Redes Neurais [22]. Sistemas de Segmentação de Imagens para Quantificação de Microestruturas em Metais Utilizando Redes Neurais Artificiais [23]. Uso de Redes Neurais Artificiais como uma Alternativa para Mapeamento de Biomassa e Carbono Orgânico no Componente Arbóreo de Florestas Naturais [24].

IV. DESENVOLVIMENTO

O projeto desenvolvido e descrito no presente artigo trata-se do aprimoramento de um sistema de detecção e alarme de incêndio que tem por finalidade detectar o princípio de um possível incêndio no ambiente industrial, conjunto a um detector de partículas sólidas. O primeiro passo do projeto foi construir o ambiente onde seriam criadas as simulações, em um segundo momento foram produzidas situações de poeira e fumaça no ambiente, para capturar as fotos contendo esses dados e realizar o treinamento da *RNA* e sua validação. Para esta fase foram capturadas 1000 fotos de cada ambiente. Estas fotos, do tipo *RGB* como mostrado na Seção III parte A, passaram pelo fator de escalonamento e foram transformadas em tons de cinza, para melhor processamento da *RNA*, todo esse processo de tratamento de imagem foi realizado via *software* Matlab. Após as fotos passarem pelo tratamento de imagem, o primeiro passo realizado para a obtenção dos resultados foi a aplicação da *Análise de Componentes Principais*, utilizando 5 componentes, afim de extrair as características principais das figuras e consequentemente poder reduzir a dimensionalidade dos dados [25].

O processo de treinamento foi realizado pelo Matlab utilizando a *RNA CFBP*, configurada com 5 camadas de processamento, no qual a primeira camada é dotada de 15 neurônios e as demais camadas ocultas possuem 10 neurônios cada. A função de treinamento utilizada foi a Descida de Gradiente com Retro propagação de Impulso, esta função permite que a *RNA* responda não apenas ao gradiente local, mas também as tendências recorrentes da superfície de erro [26]. A função de ativação utilizada foi a Tangente Hiperbólica, que é uma função *Sigmoidal* que assume valores no intervalo de -1 a 1, por dispor dessas características a tangente hiperbólica aproxima-se mais da identidade, sendo uma alternativa mais eficaz para ativação das camadas ocultas da *RNA* [27].

Com a interação entre Matlab² e Arduino estabelecidas e prontas para receber os dados da medição do sensor, foi feita a captura das imagens via *software* Matlab, este estabelece comunicação com a câmera *IP*, que registra o evento em tempo real.

Na fase de testes, já com o ambiente montado e definido o valor para ativação do sensor (100 *ppm*), foram criadas situações de fumaça e poeira no ambiente afim de verificar a eficiência da ativação do conjunto. O sistema captura um frame para que a rede neural artificial possa fazer comparação da imagem atual e identificar se as partículas presentes são poeiras ou a fumaça.

Para elaboração do projeto foram utilizados os seguintes componentes:

- 01 Arduino Uno R3;
- 02 sensor de fumaça modelo MQ-02;
- 01 módulo relé 5V 02 canais;
- 01 *buzzer* 12V;
- 01 caixa de medidas 60cm x 40cm x 40cm para simulação do ambiente;
- 01 fonte de alimentação 5 volts;
- 01 fonte de alimentação 12 volts;
- 02 Latas de fumaça artificial;
- 01 câmera *IP*;
- Preço final do projeto R\$ 500.

O funcionamento deste sistema conforme apresentado na fig. 8, desempenha as seguintes atividades: o sensor medirá o número de partículas sólidas no ar, ao atingir certo percentual, este sensor enviará um sinal ao Arduino. Este que por sua vez trabalha em conjunto com o Matlab e uma câmera *IP*, que irá monitorar o local em tempo real, fará uma captura do frame de vídeo no instante em que o sensor de partículas mandar um sinal de alto número de partículas sólidas no ar. A foto capturada é então apresentada para a rede neural *CFBP* que foi previamente treinada. Após a comparação, a *RNA* classificará se a foto é provida de fumaça ou provida de poeira. Caso a foto capturada seja classificada como fumaça, é emitido um sinal para que o alarme possa ser disparado, por outro lado se a foto for classificada como poeira o alarme não será acionado.

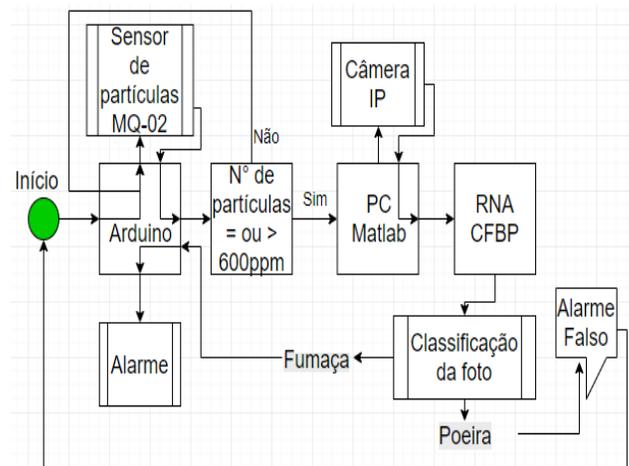


Fig. 8. Esquemático do sistema de detecção de incêndio.

V. RESULTADOS

Para a obtenção dos resultados deste trabalho foi realizado o treinamento da *RNA*, que durou aproximadamente 4 horas, com 650 fotos do ambiente com fumaça e 650 fotos do ambiente com poeira. Para facilitar o processo de treinamento da rede, foi utilizada a *PCA* como apresentado na seção IV, essa técnica

² A versão do *software* Matlab utilizada foi a 2016A, com a licença de estudante.

possibilitou gerar uma nova matriz com as componentes principais da matriz original, isso auxiliou na visualização dos dados, redução da dimensionalidade da matriz e também possibilitou uma melhoria nos resultados [25].

A fig. 9 apresenta a disposição os dados após a extração das componentes principais, neste caso, são apresentados 5 componentes.

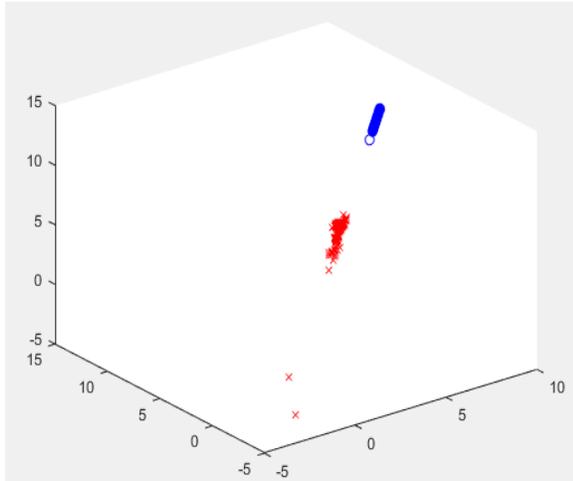


Fig. 9. Disposição dos dados utilizando 5 componentes principais. Os dados na cor azul em formato de círculo, correspondem as fotos do ambiente com fumaça e os dados na cor vermelha em forma de x, correspondem as fotos do ambiente com poeira.

Pela figura 9 é possível observar, que após a aplicação da PCA, os dados apresentam-se bem separados no espaço, esta característica contribuiu com a qualidade de classificação da RNA.

Na fig. 10 é possível observar o comportamento do erro quadrático médio, e o melhor resultado alcançado pela RNA CFBP ao decorrer de 10^3 épocas de treinamento.

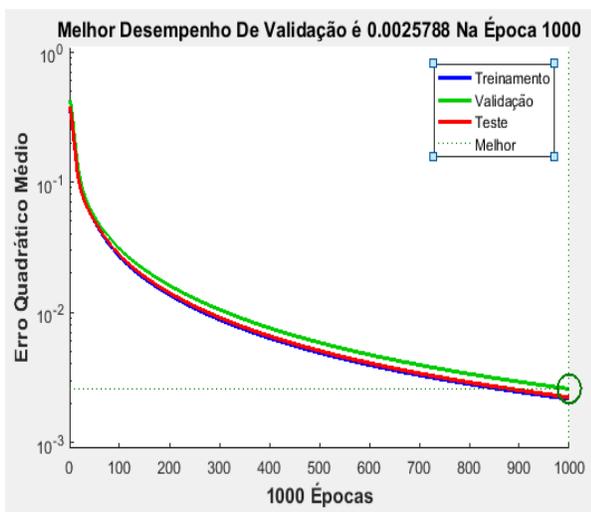


Fig. 10. Resultado do treinamento, erro quadrático médio.

A fig. 11 mostra o valor do gradiente no final de 10^3 épocas e o valor esperado que o gradiente alcançasse.

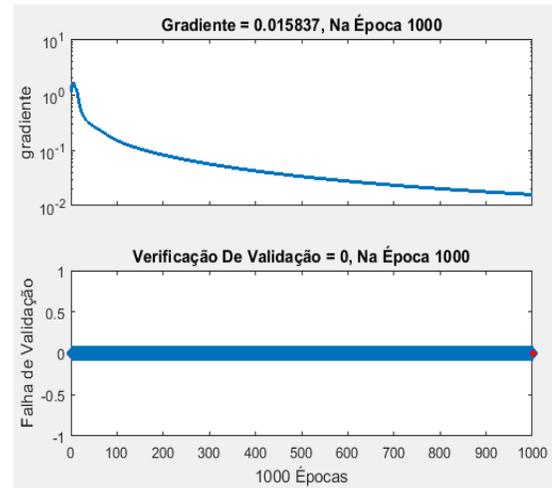


Fig. 11. Resultado do gradiente.

A tabela 1 apresenta a relação entre a taxa de acertos, a etapa utilizada para verificar a eficiência da CFBP e o número de fotos de cada ambiente utilizadas por etapa.

TABELA I
ACURÁCIA DAS ETAPAS DE APRENDIZADO DA SOLUÇÃO

Etapa	Taxa de acertos em %, em 1 treinamento	Nº de fotos do ambiente com fumaça	Nº de fotos do ambiente com poeira
Treinamento	100	650	650
Validação	100	350	350
Teste Fumaça	96,66	30	-
Teste Poeira	80	-	30
Teste Fumaça + Teste Poeira	88,33	30	30

Após o treinamento, iniciou-se a parte de validação da rede CFBP, onde foram separadas 350 fotos do ambiente com fumaça e 350 fotos do ambiente com poeira para comparação e foi obtido uma taxa de 100 % de acertos, como pode ser visto na tabela 1.

Como é exposto na tabela 1, nas 30 simulações do ambiente com fumaça, o aproveitamento obtido foi de 96,66% ou 29 simulações positivas. Já nas 30 simulações do ambiente com poeira, o aproveitamento foi de 80% ou 24 simulações positivas. A taxa média de acertos do ambiente com fumaça mais o ambiente com poeira foi 88,33% ou 53 simulações positivas.

É válido ressaltar que nas situações envolvendo o ambiente com poeira houveram certas dificuldades, passível de ser notada pela menor taxa de acertos da CFBP neste caso. Esta dificuldade pode ser explicada pelo fato da densidade da poeira utilizada e a proximidade do sensor com o particulado. A proximidade é o fator mais agravante, pois a poeira utilizada é derivada de minério de ferro e durante os testes, o particulado em contato com a eletrônica do sensor gerou um curto em seus circuitos.

VI. CONCLUSÃO

Um fator muito importante, quando falamos sobre Inteligência Artificial e Redes Neurais Artificiais é a fase de coleta e processamento de dados, esse fator influenciou muito no projeto proposto, pois considerando que a fumaça e a poeira são partículas em movimento, podem assumir inúmeras formas, quanto maior o número de fotos na fase de treinamento, melhor será resultado obtido, na comparação com a foto do evento registrado pela câmera. Conforme os resultados obtidos e apresentados na seção V, o trabalho ostenta que é possível dar inteligência a um sistema de detecção e alarme de incêndio convencional, e este por sua vez tornar-se capaz de distinguir o que é ou não fumaça, conseqüentemente, detectar o princípio de um possível incêndio, não disparando alarmes falsos em casos de poeira no ambiente.

A proposta principal do trabalho como exposta acima, foi alcançada, mas o projeto demanda uma continuidade, com o objetivo de se obter um sistema com uma taxa de 100% de acertos, componentes de captação de dados com boas configurações, desta forma apresentando respostas cada vez mais precisas. O baixo custo do projeto foi um ponto significativo e iniciou-se abertura de uma proposta para futuros estudos, com a implantação do sistema em um ambiente industrial.

Ressalta-se que instalação do projeto em um ambiente industrial como salas elétricas, resultaria na diminuição do número de alarmes falsos gerados por poeira. Com a diminuição do número de alarmes falsos, certas situações poderiam ser evitadas, situações estas que acarretam no deslocamento de equipe especializada para verificação do possível incêndio, e no alto número de funcionários em salas de controle, cuja função é verificar o mal funcionamento do sistema. Podemos evidenciar, que a diminuição dos alarmes falsos ocasionaria ganho de tempo para equipe de manutenção em salas elétricas, já que estes não teriam que parar as atividades de manutenção devido a um alarme falso.

VII. REFERÊNCIAS

- [1] M. da S. Virginio, *Avaliação Dos Sistemas De Combate A Incêndio De Uma Instituição Pública De Ensino Superior Localizada No Município De Mossoró-RN*, Mossoró: Departamento de Ciências Ambientais e Tecnológicas da Universidade Federal do Semiárido, 2013, pp. 24-30.
- [2] A. I. Seito, A. A. Gil, F. D. Pannoni, R. Ono, S. B. Da Silva, U. Del Carlo and V. Pignatta e Silva, *A Segurança Contra Incêndio No Brasil*, São Paulo: Projeto Editora, 2008, pp. 1-3.
- [3] S. J. Montebeller, *Sensores Sem Fio Avaliação E Emprego Na Automação De Sistemas Prediais*, São Paulo: Biblioteca24horas, 2011, pp. 37-42.
- [4] J. Ross, *Alarmes*, São Paulo: Editora Antena Edições Técnicas Hemu, 2008. [EBook] Disponível em: <https://books.google.com.br/books?id=Xc11BI45rK4C&pg=PA8&dq=como+funciona+sistema+de+alarme+de+incendio&hl=pt-BR&sa=X&ved=0ahUKEwjL8Ieko7nYAhVikZAKHZ6aBj8Q6AEIJZA#v=onepage&q=como%20funciona%20sistema%20de%20alarme%20de%20incendio&f=false>.

- [5] G. Aguiar and J. Marciano, “Inteligência Artificial Aplicada em um Sistema de Detecção de Incêndio”, *Centro de Ensino Superior de Conselheiro Lafaiete*, 05 de Novembro de 2018. [Online] Disponível em: <https://www.ces-cl.edu.br/index.php/conicp>.
- [6] A. C. G. Martins, “Comandos Básicos de Matlab aplicados ao Processamento de Imagens”, *Unesp Sorocaba*, 20 de Julho de 2018. [Online] Disponível em: <http://www.sorocaba.unesp.br/Home/Graduacao/EngenhariaAmbienta/antonio/comandos-basicos-de-matlab-aplicados-ao-processamento-digital-de-imagens---revisado-em-31-de-10-de-2016.pdf>.
- [7] M. F. de Paiva, *Boas Práticas Para o Projeto de Homologação, Implantação, Utilização e Manutenção de Sistemas De Gestão Da Informação Que Armazenam Imagens Digitais De Documentos Com Fidedignidade e Confiabilidade*, São Paulo: Editora Target, 2008, pp. 69-73.
- [8] J. J. P. de Lima, *Técnicas de Diagnóstico com Raios X: Aspectos Físicos e Biofísicos*, 2ª ed., Universidade de Coimbra, 2009, pp. 354-356.
- [9] S. Haykin, *Redes Neurais Princípios e Práticas*, 2ª ed., Porto Alegre: Editora Bookman, 2007, pp. 28-37 46-48.
- [10] B. Widrow and S. D. Stearns, *Adaptive Signal Processing*, Englewood Cliffs: Prentice Hall, 1985.
- [11] S. Haykin, *Adaptive Filter Theory*, 3ª ed., Englewood Cliffs: Prentice Hall, 1996.
- [12] N. L. Barth, *Inadimplência Construção de Modelos de Previsão*, São Paulo: Editora Nobel, 2004, pp. 41-42.
- [13] D. P. Mohapatra and S. Patnaik, *Intelligent Computing, NetWorking, and Informatics*, Índia: Editora Springer, 2013, pp. 195-196.
- [14] S. Tengeleng and N. Armand, “Performance of Using Cascade-Forward Backpropagation Neural Networks for Estimating Rain Parameters with Rain Drop Size Distribution”, *Atmosphere*, 27 de Julho de 2018. [Online] Disponível em: <http://www.mdpi.com/2073-4433/5/2/454>.
- [15] O. Khatchatourian and F. R. R. Padilha, “Reconhecimento de Variedades de Soja por Meio do Processamento de Imagens Digitais Usando Redes Neurais Artificiais”, *SciELO*, 22 de Setembro de 2018. [Online] Disponível em: http://www.scielo.br/scielo.php?pid=S0100-69162008000400016&script=sci_abstract&tlang=pt.
- [16] R. R. da Silva, “Reconhecimento de Imagens Digitais Utilizando Redes Neurais”, *Repositório UFPA*, 22 de Setembro de 2018. [Online] Disponível em: http://repositorio.ufpa.br/bitstream/1/9444/1/MONOGRRAFIA_Reconhecimento_de_imagens_digitais_utilizando_redes_neurais_artificiais.pdf.
- [17] C. S. Chagas, C. A. O. Vieira, E. I. Fernandes Filho and W. de C. Júnior, “Utilização de Redes Neurais Artificiais na Classificação de Níveis de Degradação em Pastagens”, *SciELO*, 22 de Setembro de 2018. [Online] Disponível em: <http://www.scielo.br/pdf/rbeaa/v13n3/v13n03a14.pdf>.
- [18] W. Nishida, “Uma Rede Neural Artificial Para Classificação de Imagens Multiespectrais de Sensoriamento Remoto”, *Repositório UFSC*, 22 de Setembro de 2018, [Online] Disponível em: <https://repositorio.ufsc.br/bitstream/handle/123456789/77542/138042.pdf?sequence=1>.
- [19] J. D. S. da Silva, “Uso de Redes Neurais em Visão Computacional e Processamento de Imagens”, *Instituto Nacional de Pesquisas Espaciais*, 20 de Setembro de 2018. [Online] Disponível em: <http://mtc-m16.sid.inpe.br/col/sid.inpe.br/marciana/2004/09.17.13.47/doc/publicacao.pdf>.

- [20] P. M. de A. Marques, “Diagnóstico Auxiliado por Computador na Radiologia”, *Scielo*, 12 de Outubro de 2018. [Online] Disponível em: <http://www.scielo.br/pdf/%0D/rb/v34n5/7682.pdf>.
- [21] J. A. F. Costa, “Classificação Automática e Análise de Dados por Redes Neurais Auto Organizáveis”, *Repositório da Produção Científica e Intelectual da Unicamp*, 12 de Outubro de 2018. [Online] Disponível em: <http://repositorio.unicamp.br/handle/REPOSIP/260981>.
- [22] A. C. G. Thomé, B. C. Guingo and R. J. Rodrigues, “Reconhecimento Automático de Placas de Veículos Automotores Através de Redes Neurais Artificiais”, *NCE Universidade Federal Do Rio De Janeiro*, 12 de Outubro de 2018. [Online] Disponível em: http://www.nce.ufrj.br/labic/downloads/2CBCComp_2002.pdf.
- [23] V. H. C. de Albuquerque, P. C. Cotez, A. R. de Alexandria, W. M. Aguiar and E. de M. Silva, “Sistema de Segmentação de Imagens para Quantificação de Microestruturas em Metais Utilizando Redes Neurais Artificiais”, *Scielo*, 12 de Outubro de 2018. [Online] Disponível em: <http://www.scielo.br/pdf/rmat/v12n2/v12n2a17>.
- [24] E. R. Schoeninger, H. S. Koehler, L. F. Watzlawick and P. C. de O. Filho, “Uso de Redes Neurais Artificiais como uma Alternativa para Mapeamento de Biomassa e Carbono Orgânico no Componente Arbóreo de Florestas Naturais”, *Ambiência ISSN*, 12 de outubro de 2018. [Online] Disponível em: <https://revistas.unicentro.br/index.php/ambiencia/article/view/152>.
- [25] S. Wold, K. Esbensen and P. Geladi, “Principal Component Analysis”, *Elsevier*, 11 de Agosto de 2018. [Online] Disponível em: https://imedea.uibcsic.es/master/cambioglobal/Modulo_V_cod101615/Theory/lit_support/pca_wold.pdf.
- [26] “MathWorks TRAINGDM”, *MathWorks*, 2006. [Online] Disponível em: https://www.mathworks.com/help/nnet/ref/traingdm.html#f8-671774_seealso.
- [27] “MathWorks TANSIG”, *MathWorks*, 2006. [Online] Disponível em: <https://www.mathworks.com/help/nnet/ref/tansig.html>.