SISTEMA DE VENTILAÇÃO INTELIGENTE PARA MINAS SUBTERRÂNEAS UTILIZANDO REDES NEURAIS ARTIFICIAIS E UTILIZANDO LÓGICA FUZZY

Arina Bragança Moraes
Universidade Federal de Itajubá
Rua Irmã Ivone Drumond, n° 200, Distrito Industrial II – Itabira – MG – 35903-087
arina_bm@hotmail.com

Juliano de Almeida Monte-Mor
Universidade Federal de Itajubá
Rua Irmã Ivone Drumond, n° 200, Distrito Industrial II – Itabira – MG – 35903-087
jmontemor@unifei.edu.com

Vinícius Quintanilha Sano
Universidade Federal de Itajubá
Rua Irmã Ivone Drumond, n° 200, Distrito Industrial II – Itabira – MG – 35903-087
viniciussano31@gmail.com

RESUMO

Este artigo descreve uma abordagem de controle inteligente de ventilação para minas subterrâneas, buscando assegurar um ambiente higiênico e seguro para os trabalhadores. A abordagem proposta considerou o desenvolvimento de dois sistemas de ventilação, baseados nas técnicas de Redes Neurais Artificiais (RNA's) e Lógica Fuzzy, com o objetivo de manter as condições atmosféricas do interior da mina dentro dos limites de segurança determinados pelas normas regulamentadoras. Também se desenvolveu um sistema para simular as variações de gases e temperatura de uma mina subterrânea, considerando os parâmetros atmosféricos deste ambiente. Este simulador proporcionou a geração de conjuntos de dados para o treinamento da RNA proposta. Além disto, aplicou-se conhecimento empírico na construção de conjuntos de pertinência Fuzzy, buscando tratar a incerteza existente na determinação de uma vazão adequada para as diferentes variáveis atmosféricas representadas. Os resultados obtidos pelos dois sistemas propostos foram considerados satisfatórios para o modelo adotado para o problema.

PALAVRAS CHAVE. Ventilação, Lógica Fuzzy e Redes Neurais Artificiais

ADM – Apoio à Decisão Multicritério e OC – Otimização Combinatória

ABSTRACT

This article describes an approach to control the underground mine ventilation, in order to ensure a safe and sanitary environment for the mineworkers. The proposed approach considered two ventilation systems developments, based on Artificial Neural Network (ANN) and Fuzzy Logic, seeking to keep the mine atmospheric conditions within the safety limits, determined by regulatory norms. In addition, we developed a system to simulate the variation of gases concentration as well as temperature, considering the environment atmospheric parameters. That provided datasets to the ANN training, which offer the necessary flow rate to maintain the mine conditions acceptable. Besides, we applied empiric knowledge to create Fuzzy membership functions, seeking to deal with the uncertainty that appears during the flow rate determination. We have analyzed and discussed the obtained results for both systems and have considered them satisfactory to our problem modelling.

KEYWORDS. Ventilation, Fuzzy Logic and Artificial Neural Network

1. Introdução

Em uma mina subterrânea, o sistema de ventilação é responsável pela renovação do fluxo de ar e das concentrações de oxigênio, assegurando um ambiente higiênico e seguro para os trabalhadores, visto que as atividades mineradoras liberam diferentes quantidades de gases e partículas em suspensão. Tais gases são nocivos à saúde e a combinação entre eles pode gerar a formação de misturas explosivas. Outro fator agravante consiste na elevação de temperatura decorrente das atividades de máquinas e da explosão de rochas. Assim, um sistema de ventilação inadequado torna precárias as condições de trabalho no interior de uma mina. [Vutukuri e Lama 1986].

Por esta razão, uma empresa de mineração deve constantemente analisar as variáveis que interferem na qualidade do ambiente no interior de uma mina subterrânea, visando assegurar condições ambientais adequadas ao trabalho humano, bem como segurança local, de acordo com uma série de normas que buscam colocar em segurança a saúde e o bem-estar do trabalhador. Características atmosféricas, tais como estado físico, temperatura, pressão, umidade, partículas em suspensão e composição gasosa, devem ser constantemente monitoradas, a fim de que sejam renovadas periodicamente pelo sistema de ventilação, assegurando assim um ambiente higiênico e confortável para os mineradores e evitando possíveis explosões, originadas pelo acúmulo de determinados elementos inflamáveis [Gonçalves et al. 2009]. Porém, existe um determinado custo associado a realização desta tarefa, sendo a redução de custos um ponto chave para as empresas.

Qualquer sistema de ventilação deve possuir um circuito de controle que manipule variáveis como volume, pressão e vazão de ar. Tal circuito é responsável por medir e direcionar a saída do ventilador. Os primeiros ventiladores possuíam componentes mecânicos bem simples para realizar a tarefa de controle. Atualmente, com o avanço dos microprocessadores, existe maior precisão e flexibilidade no ajuste das variáveis, além de oferecer maiores opções de modos de controle [Chatburn 2004]. Apesar de existirem diferentes tipos de sistemas de controle de ventilação, este trabalho concentrou-se no controle por Redes Neurais Artificiais (RNA's) e por Lógica Fuzzy. Um sistema de ventilação controlado por estes mecanismos visa encontrar um equilíbrio entre a quantidade e a qualidade do ar e a eficiência energética fornecida.

Para realizar tal renovação atmosférica, torna-se necessário um sistema de ventilação que, além de assegurar de forma eficiente um ar puro e refrigerado, também possa operar de forma a consumir uma menor quantidade de energia, sendo este o principal objetivo deste trabalho de pesquisa. Neste caso, o sistema de ventilação deve ser inteligente e autônomo o suficiente para identificar as diversas condições atmosféricas existentes e agir diretamente no sentido de melhorar estas condições. Assim, o sinal de controle determinará a velocidade dos motores dos ventiladores de acordo com as necessidades atuais, mantendo os parâmetros atmosféricos dentro dos limites de segurança e consumindo menores quantidades de energia.

2. Redes Neurais Artificiais

As Redes Neurais Artificiais surgiram no intuito de replicar ou, pelo menos, agregar características de topologia e poder de processamento do cérebro humano. O cérebro contém uma enormidade de neurônios que interligados formam uma estrutura com capacidade de processamento paralelo e distribuído. Hoje, elas se diferenciam bastante das redes biológicas, porém apresentam características em comum, como unidades de processamento paralelas e distribuídas, redundância e modularização das conexões [Braga et al. 2000].

A unidade base de todo o processamento das RNA's consiste no neurônio artificial, que foi proposto inicialmente por McCulloch e Pitts, em1943, como uma simplificação do que se tinha de conhecimento dos neurônios biológicos [Braga et al. 2000]. Tais autores propuseram a topologia de um neurônio artificial genérico, em que sua dinâmica de processamento ocorre da seguinte maneira: a partir dos sinais de entrada fornecidos, atribui-se pesos específicos para cada entrada; em seguida, realiza-se o somatório do produto dos sinais de entrada com seus respectivos

pesos mais o valor *bias* (responsável por aumentar ou diminuir o valor de entrada da função de ativação); e, finalmente, aplica-se a função de ativação, que permite, inibe ou restringe a ativação do sinal de saída.

Geralmente, a utilização de RNA relaciona-se com tarefas de associação e reconhecimento de padrões, aproximação de funções, controle e filtragem. Elas trazem uma gama de benefícios, principalmente por apresentarem uma arquitetura ajustável e métodos de treinamento para diversos tipos de situações. As RNA's podem ter origem linear ou não-linear, serem constituídas de diferentes quantidades de neurônios e camadas, e diferentes tipos de conexões entre os neurônios [Haykin 2001].

3. Lógica Fuzzy

Ao considerar o uso de Lógica Fuzzy (ou Lógica Nebulosa) para um dado problema, deve-se ponderar a necessidade de explorar a tolerância às imprecisões, i.e., deve-se equilibrar a precisão buscada e a incerteza existente no problema. Segundo [Ross 2010], quanto maior for a necessidade de precisão, maior será o custo e o tempo necessário para encontrar a solução. Assim, não se recomenda o uso de Lógica Fuzzy em problemas de alta precisão, e.g., atirar um raio laser em um alvo localizado a quilômetros de distância no espaço.

Geralmente a Lógica Fuzzy considera um grau de certeza, entre 0 e 1, segundo o qual propostas podem ser verdadeiras, sendo então possível classificar o grau de certeza de uma proposta a partir do valor que ela assume [Weber e Klein 2003]. Este tipo de lógica beneficia a representação de sistemas complexos e difíceis de modelar.

Fuzzy implementa preferências e experiências humanas por meio de funções de pertinência e regras. As funções de pertinência podem ter diferentes formatos dependendo da preferência e/ou nível de experiência do usuário. Já as regras, que descrevem relações em alto nível, i.e., utilizando termos linguísticos, são normalmente escritas em frases do tipo SE-ENTÃO. Com a adoção de conjuntos de pertinência e regras Fuzzy, o sistema torna-se capaz de retornar respostas para entradas não esperadas. Assim, a Lógica Fuzzy pode ser utilizada como uma metodologia geral para incorporar conhecimento, heurística ou teoria em controladores e em sistemas de tomada de decisão [Tomsovic e Chow 2000].

Segundo [Weber e Klein 2003], a Lógica Fuzzy tem sido aplicada na construção de sistemas de controle e de suporte à decisão, onde a descrição do problema não pode ser realizada de forma extremamente precisa. Esta metodologia tem sido aplicada com sucesso na análise de dados, construção de sistemas especialistas, controle e otimização, reconhecimento de padrões, dentre outras possibilidades.

Como a teoria de conjuntos fuzzy sugere que alguns elementos são mais membros de um conjunto do que outros, então o fator de pertinência pode assumir qualquer valor entre 0 e 1. O raciocínio fuzzy pode ser dividido em três etapas: fuzzificação, inferência e defuzzificação. O processo de fuzzificação envolve a análise do problema, a definição das variáveis, a definição das funções de pertinência (e.g, triangular, gaussiana, trapezoidal, etc.) e a criação dos conjuntos ou regiões de pertinência. Já na etapa inferência, realizam-se a definição e análise de regras e a criação da região resultante. Por fim, a defuzzificação consiste em converter as regiões resultantes em valores, representando a saída do sistema sob controle. Para esta conversão podem ser utilizadas diversas técnicas, sendo a técnica por cálculo de centróide a mais comum [Rabelo 2011].

4. Simulação do Ambiente da Mina Subterrânea

Devido à dificuldade de encontrar dados reais para os experimentos e treinamento da RNA, simulou-se as condições ambientais de uma mina subterrânea de carvão. Para isso, algumas considerações foram feitas a fim de simplificar o modelo de simulação.

Analisaram-se as seguintes variáveis: as variações de concentração dos gases oxigênio (O_2), dióxido de carbono (CO_2) e metano (CH_4); a temperatura no interior da mina; a quantidade

de trabalhadores e a quantidade de máquinas a diesel com 150 HP, 300 HP e 770 HP. Dessa forma, foram feitas as seguintes considerações:

i. A mina subterrânea possui 100.000 m^3 de volume total, sendo 10.000 m^2 de área e 10 m de altura;
ii. Definiu-se uma mina subterrânea de extração de carvão, que libera metano a uma taxa de 5 m3/min;
iii. A quantidade total de veículos a diesel pode variar entre 0 e 5 veículos para cada potência adotada;
iv. A quantidade total de trabalhadores no interior da mina pode variar entre 100 e 1000 pessoas;
v. O sistema de ventilação adota a mesma quantidade de ar para as vazões de entrada e saída;
vi. A pressão atmosférica e a umidade no interior da mina mantêm-se constantes;
vii. Ignorou-se a existência de partículas em suspensão no ar, e.g., poeira.

Segundo [Hartman 2012], o sistema de ventilação de uma mina subterrânea, quando bem ajustado, deve reproduzir a composição do ar atmosférico presente na superfície. A composição média da atmosfera seca, abaixo de 25 km, possui em média 20,95% de O_2 e 0,037% de CO_2 [Barry e Chorley 2013].

A quantidade necessária de oxigênio para a respiração varia de acordo com a intensidade de trabalho. Em trabalho moderado, um trabalhador respira cerca de 30 vezes por minuto e inala cerca de 0,8 a 1,0 litros de ar por segundo, o que representa cerca de 0,03 litros de oxigênio consumidos e 0,027 litros de dióxido de carbono produzidos por segundo [McPherson, 2012].

Em condições ideais, o consumo médio de um motor a diesel é de 0,15 l/HP/h. Considerando que as máquinas não operam em potência máxima, adotou-se um rendimento médio igual a 55%. Pode-se calcular o consumo horário de diesel por meio da Equação 1.

$$C = P_n \times \eta \times C_m \tag{1}$$

onde C refere-se ao consumo horário, P_n a potência nominal, η trata-se do rendimento e C_m do consumo médio do veículo. Assim, o veículo consome cerca de 0,0825 litros de diesel por hora para cada HP de potência [JBS 2012].

Tomando como base as referências citadas e realizando os devidos cálculos, chegou-se à seguinte tabela:

Tabela 1 - Valores de consumo de O_2 e emissão de CO_2 dos veículos

Potência	Consumo de O_2	Liberação de CO_2	Referências
150 HP	24,12 m^3	17,18 m^3	[Petrobras 2012] [Garcia 2014] [Linde 2008] [De Carvalho 2011]
300 HP	48,24 m^3	34,35 m^3	
770 HP	123,82 m^3	88,17 m^3	

De acordo com a norma regulamentadora NR-22 [MTE 2015], a Equação 2 permite calcular a vazão de ar fresco necessária em função do número máximo de pessoas ou máquinas com motores a combustão a óleo diesel.

$$Q_T = Q_1 n_1 + Q_2 n_2 \tag{2}$$

Onde Q_T corresponde à vazão total de ar fresco em m^3/min; Q_1 à quantidade de ar por pessoa em m^3/min (para minas de carvão utiliza-se 6 m^3/min); n_1 refere-se ao número de pessoas no turno de trabalho; Q_2 trata-se da constante igual a 3,5 m^3/min/cv (cavalo-vapor) para motores a diesel e n_2 do número total de cavalo-vapor dos motores a diesel. Devido à proximidade das unidades, considerou-se 1 cv igual a 1 HP.

Por outro lado, de acordo com [McPherson 2012], tem-se 34.000 kJ/l como valor calorífico do diesel e, assumindo um consumo médio de um motor a diesel como 0,15 l/HP/h, ou seja, 0,20 l/kW/hr, obtém-se o total de calor produzido por kW de potência de uma máquina como:

$$Calor_{Total} = 0{,}2\times34000\times\frac{1}{3600}\times0{,}55\times1000\times[kW]$$
$$Calor_{Total} = 1038{,}9\ [J/s]\times[kW]$$

Já segundo a norma NBR 6401, uma pessoa libera um total de calor por volta de 83 (Kcal/h), considerando uma temperatura de 26°C. Assim, a Equação 3 permite calcular o calor total liberado para o ambiente por minuto, em função do número de pessoas.

$$Q_{Pessoas} = 96{,}51\times N^{o} de\ pessoas\ [J/s] \quad (3)$$

Desta forma, a Equação 4 permite determinar o calor total liberado para o ambiente.

$$Q_{Total} = Q_{Máq.} + Q_{Pessoas}\ [J/s] \quad (4)$$

De acordo com [Shapiro 2002], a Equação 5 relaciona a vazão necessária para remover o calor do ambiente.

$$\dot{Q} = \rho\dot{V}c(T_i\text{-}T_e)\ [J/s] \quad (5)$$

Onde T_i corresponde a temperatura interna do ambiente; T_e a temperatura externa; c refere-se ao calor específico do ar, equivalente a 1007 J/Kg.K; e ρ trata-se da densidade do ar, igual a 1,184 Kg/m^3, ambos considerados em uma temperatura de 25ºC [Çengel e Ghajar 2012].

De acordo com a NR-15, a temperatura considerada ideal para o conforto térmico no ambiente de trabalho será de 26,8ºC a 28,0ºC [MTE, 2015]. Além disto, segundo as normas regulamentadoras NR-15, NR-22 e NR-33 [MTE, 2015], o limite de tolerância de CO_2 no ambiente de trabalho não deve ultrapassar 0,39%, de CH_4 deve ser inferior a 1% e de O_2 deve manter-se entre 19% e 23% do volume total.

Buscando manter o ambiente interno da mina com as concentrações normais de gases atmosféricos e a temperatura ideal para a manutenção do trabalho, realizou-se o controle de vazão de ar fresco da mina de forma a manter estes elementos em torno dos seguintes valores ideais: 21% de O_2, 0,03% de CO_2, 0,01% de CH_4 e 27,4 °C de temperatura. Além disto, adotou-se um comportamento linear para o cálculo da vazão necessária para manter cada elemento em seu valor ideal, i.e., a vazão cresceu linearmente com a variação destes elementos em relação aos seus valores ideais. Assim, calcularam-se vazões desejadas para cada um destes elementos, prevalecendo o maior valor encontrado durante as simulações.

Nas situações onde os gases ou a temperatura ficaram acima ou abaixo dos limites aceitáveis, adotou-se a vazão máxima de 27.500 m^3/min, que corresponde ao valor recomendado para a vazão na mina, obtido a partir da Equação 2, considerando a quantidade máxima de pessoas e máquinas no ambiente.

O sistema desenvolvido permitiu simular as variações de concentrações dos gases e temperatura no interior da mina durante intervalos de tempo. Para o treinamento da RNA foram gerados dados, por meio de um algoritmo no software *Matlab*, representando situações normais e anormais na mina. A Figura 1 apresenta as concentrações de oxigênio, gás carbônico e metano, em porcentagem do total de ar contido na mina, considerando um fluxo normal de pessoas e máquinas, enquanto a Figura 2 mostra a temperatura no interior da mina em condições normais de trabalho. O eixo horizontal representa o tempo percorrido em minutos da simulação. Definiram-se condições iniciais para cada gás próximas de suas concentrações na atmosfera: O_2 em 21%, CO_2 em 0,03%, CH_4 em 0,01% e temperatura em 27,4°C.

Na Figura 1*b*, pode-se observar que nos primeiros minutos de simulação ocorreu um aumento da concentração de CO_2 e CH_4, sendo justificável pela introdução de pessoas e máquinas, aumentando a emissão de tais gases. Por outro lado, a concentração de O_2, na Figura 1*a*, diminuiu por causa do aumento do seu consumo. Após os instantes inicias as concentrações já estabilizaram em torno dos valores adequados, por causa da troca de ar realizada pela ventilação.

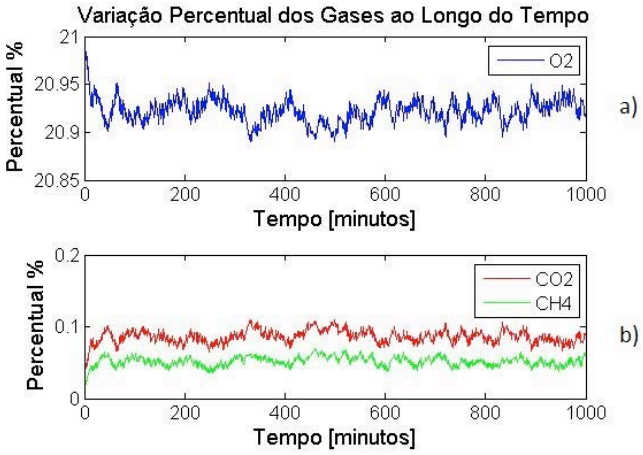

Figura 1 – (a) Concentração de O_2, (b) CO_2 e CH_4 com vazão ideal aplicada.
Fonte: (Autoria Própria)

Já quanto a variação da temperatura na Figura 2, ela ocorreu em função do fluxo de pessoas e máquinas em funcionamento, permanecendo dentro de um intervalo aceitável para o bom rendimento e segurança dos trabalhadores no interior da mina, respeitando os valores informados no Anexo Nº. 3 da norma NR-15.

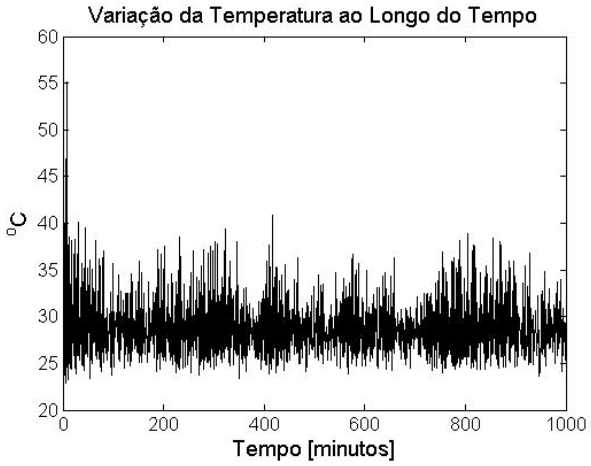

Figura 2 – Comportamento da temperatura com a vazão de controle aplicada.
Fonte: (Autoria Própria)

Para mostrar a consistência dos dados gerados pelo simulador de ambiente da mina, realizou-se outra simulação, agora considerando uma vazão de 100 m^3/min. A Figura 3 apresenta as variações das concentrações dos gases e da temperatura para esta vazão baixa.

Com a ventilação insuficiente apresentada na Figura 3*c*, conforme era esperado, as concentrações de CO_2 e CH_4 cresceram rapidamente, atingindo níveis prejudiciais para as condições de trabalho. O nível de O_2, na Figura 3*b*, também diminuiu abaixo do valor seguro. Já a temperatura, na Figura 3*a*, atingiu níveis extremamente altos, não sendo fornecido conforto térmico para os trabalhadores no ambiente da mina.

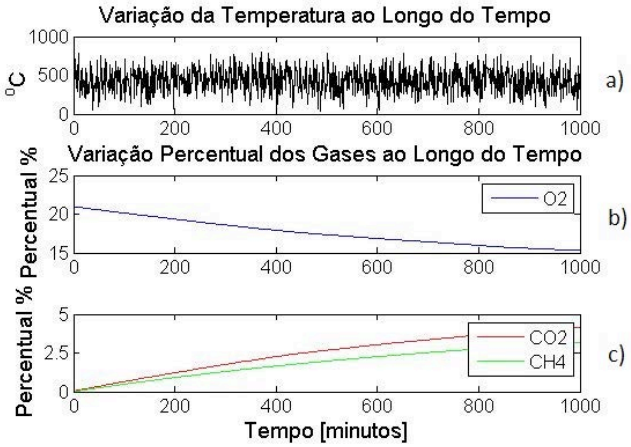

Figura 3 – (a) Comportamento da temperatura, (b) do O_2, (c) CO_2 e CH_4 com vazão baixa aplicada.
Fonte: (Autoria Própria)

5. Projeto da Rede Neural Artificial e Desenvolvimento do Controlador Fuzzy

Para a escolha da rede neural empregada para o controle da ventilação, considerou-se a característica dos dados simulados do ambiente da mina, abrangendo informações sobre a temperatura e as concentrações de gases inerentes ao ambiente de uma mina de carvão, além do fluxo de ar fresco adequado para cada situação simulada, fornecido por meio da troca de ar proporcionada pelo sistema de ventilação.

O projeto da rede neural considerou um modelo *MultiLayer Perceptron (MLP)*, treinado com um algoritmo de retropropagação de erro (*Backpropagation)*. Este tipo de rede apresenta aprendizado supervisionado baseado em regra de correção de erro [Haykin 2001].

Para a definição da arquitetura mais adequada a ser empregada para o controle de ventilação, realizaram-se testes considerando variações no número de neurônios e na quantidade de camadas da rede. De acordo com [Braga et al. 2000], define-se empiricamente o número de neurônios das camadas intermediárias. Além disto, [Haykin 2001] destaca que a adição de camadas ocultas torna a rede capaz de extrair estatísticas de ordem elevada. Esta habilidade dos neurônios ocultos extraírem estatísticas de ordem elevada torna-se particularmente valiosa para redes com grandes camadas de entrada.

Assim, considerando os quatro elementos de entrada (O_2, CO_2, CH_4 e temperatura), iniciaram-se testes com duas camadas ocultas e, posteriormente, acrescentaram-se mais camadas, quando as diversas configurações testadas para a quantidade e organização dos neurônios não apresentavam resultados satisfatórios. Como a saída da rede indica a vazão necessária para a mina, a camada de saída possui apenas um neurônio fixo. Em termos de pré-processamento e pós-processamento, normalizaram-se os valores da base de treinamento no intervalo [0,1], buscando facilitar a convergência do treinamento da rede. Em todos os testes, adotou-se o algoritmo *Backpropagation*, com a função de treinamento de *Levenberg-Marquardt*, que representa uma categoria de algoritmos com rápido processamento, baseado no Método de Newton [Hagan etc. al. 2014].

A Tabela 2 apresenta os parâmetros dos testes com diferentes arquiteturas, considerando dois tipos de algoritmos de treinamento: *Feed-forward backpropagation* e *Cascade-forward backpropagation*, sendo o último semelhante ao *Feed-forward*, incluindo, porém, uma ligação de peso a partir da entrada para cada camada, bem como a partir de cada camada para as camadas sucessivas. Estas ligações adicionais podem melhorar a velocidade na qual a rede aprende a relação desejada [Hagan etc. al. 2014]. Durante os testes, adotou-se uma função de ativação do tipo logaritmo sigmoide (*logsig*) nas camadas ocultas e linear (*purelim)* na camada de saída.

Tabela 2 - Algoritmos de treinamento testados com diferentes arquiteturas

RNA	1ª Camada	2ª Camada	3ª Camada
Feed-forward backpropagation	8	16	-
	8	16	32
	16	8	4
Cascade-forward backpropagation	8	16	-
	8	16	32
	16	8	4

Para selecionar o melhor algoritmo de treinamento para o controle de ventilação proposto, realizou-se a análise do erro encontrado entre a vazão desejada e a apresentada pela rede, fornecida como alvo. Apesar de ambos algoritmos terem desempenho satisfatório, com erros na escala de 10^{-1}, as redes usando *Cascade-forward backpropagation* apresentaram menor erro, sendo este algoritmo adotado para o treinamento dos demais experimentos.

Após a definição do algoritmo de treinamento, realizaram-se testes buscando uma arquitetura que reduzisse o erro quadrático. A Tabela 3 descreve as configurações que apresentaram melhor desempenho.

Tabela 3 - Arquiteturas testadas com variação de neurônios e camadas ocultas

RNA	1a Camada	2a Camada	3a Camada	4a Camada
Cascade-forward backpropagation	8	16	-	-
	8	16	4	2
	32	16	8	4

Dentre as configurações da Tabela 3, obteve-se o melhor desempenho com a arquitetura com 4 camadas ocultas, contendo 8 neurônios na primeira camada, 16 na segunda, 4 na terceira e 2 neurônios na última camada. Durante os experimentos, dividiram-se os dados gerados nas simulações em três conjuntos: treinamento, validação e teste. Esta configuração apresentou um erro quadrático médio equivalente a 7,383 x 10^{-6} para o conjunto de validação. A função adotada para avaliação de desempenho calcula o Erro Quadrático Médio (MSE) como definido pela Equação 6.

$$MSE = \frac{1}{N}\sum_{i=1}^{N}(Y_d\text{-}Y_r)^2 \qquad (6)$$

Onde N refere-se ao número de amostras; Y_d trata-se da saída desejada; e Y_r da saída fornecida pela rede neural.

Foi necessária a realização de duzentas e oitenta e nove épocas para encontrar o menor valor para o MSE. Tanto o conjunto de validação quanto o de teste convergiram para uma escala próxima, evidenciando a boa capacidade da rede de aprendizado e generalização.

No desenvolvimento do controlador de ventilação proposto, baseado em Lógica *Fuzzy*, utilizou-se uma análise *fuzzy* do tipo *Mamdani*, pois trata-se do tipo mais comumente utilizado [Rabelo 2011]. Para a *defuzzificação* dos valores de vazão, criou-se uma função que atendesse às características do projeto, que calcula o valor centroide apenas do conjunto de pertinência representando o maior nível de vazão, diferentemente da função centro da área normal [Simões e Shaw 2007], que considera a união de todas os conjuntos de pertinência resultantes das regras.

Como variáveis de entrada do controlador *fuzzy* consideraram-se o percentual de oxigênio, o percentual de gás carbônico, o percentual de metano presentes na atmosfera e a temperatura no interior da mina. Já a variável de saída representou a vazão correspondente em metros cúbicos por minuto.

No projeto do controlador proposto, adotou-se funções de pertinência triangulares e trapezoidais. Conforme recomendado por [Simões e Shaw 2007], escolheram-se a quantidade de funções e seus formatos com base na experiência e na natureza do processo a ser controlado.

Desta forma, de acordo com as considerações feitas na Seção 4, escolheram-se as funções de pertinência triangular e trapezoidal. Além disto, como o grau de superposição entre as

funções de pertinência afeta a precisão da lógica *fuzzy*. Utilizou-se, para as variáveis de entrada, uma superposição em torno de 25% entre suas funções de pertinência, pois considera-se tal valor como razoável [Simões e Shaw 2007], tendo apresentado bons resultados experimentalmente se comparado a outros valores testados. Para a variável de saída, não foi considerado nenhuma superposição, uma vez que se espera que prevaleça a maior vazão de saída.

Quanto à base de regras, originadas a partir do conhecimento prévio do sistema e da lógica de controle implementada no algoritmo de simulação, que proporcionou a inferência do valor desejado de vazão, criaram-se 12 regras para representar as diversas situações do ambiente da mina. Nos antecedentes destas regras, relacionaram-se as entradas consideradas por meio de operadores lógicos *AND/OR*. Além disto, adotou-se uma inferência do tipo *máx-mín* [Simões e Shaw 2007], para a determinação da vazão do sistema de ventilação.

5. Resultados e Discussões

Consideraram-se dois conjuntos de testes para a comparação dos controladores desenvolvidos. Sendo o primeiro conjunto utilizando entradas retiradas da base de dados da simulação e o segundo utilizando dados aleatórios. A Tabela 4 apresenta uma parcela dos resultados dos testes do primeiro conjunto, comparando as saídas de vazão obtidas do simulador, do controlador neural, do controlador *fuzzy* e a partir da Equação 2, da norma NR-22, discutida na Seção 4. Por outro lado, os registros da Tabela 5 buscam avaliar a capacidade de generalização da rede, uma vez que não estão contidos no conjunto de treinamento da rede.

Tabela 4 - Resultado obtido dos testes com entradas retiradas da base de dados da simulação

Teste	Pessoas	TotalCV	O_2(%)	CO_2(%)	CH_4(%)	T(^oC)	Vazão de Controle (m^3/min)	Vazão da Saída RNA (m^3/min)	Vazão da Saída Fuzzy (m^3/min)	Vazão Norma (m^3/min)
1	329	3360	20,93	0,074	0,047	30,75	12466,84	12496,26	13800	13734
2	833	2440	19,73	0,059	0,033	24,72	17636,67	17575,32	20700	15702
3	973	450	20,93	0,083	0,350	28,47	9851,06	9807,08	8600	8848
4	816	4300	20,91	0,062	0,054	31,30	14399,13	14386,41	16600	19946
16	570	2890	20,93	0,084	0,055	30,08	10095,10	10076,72	13800	13535

Tabela 5 - Resultado obtido dos testes com entradas aleatórias

Teste	O_2(%)	CO_2(%)	CH_4(%)	T(^oC)	Vazão de Controle (m^3/min)	Vazão da Saída RNA (m^3/min)	Erro da Saída RNA (%)	Vazão Saída Fuzzy (m^3/min)	Erro da Saída Fuzzy (%)
1	21	0,2	0,5	27	13914	14489,82	4,137	13800	-0,819
2	21	0,22	0,3	27,4	14797	14306,07	-3,319	12200	-17,551
3	23	0,2	0,5	27,4	27500	24418,98	-11,204	27200	-1,091
4	24	0,4	2	40	27500	40241,96	46,334	27200	-1,091
5	23	0,3	0,9	28	27500	23718,6	-13,751	23400	-14,909

Quanto aos resultados da Tabela 4, como os dados utilizados para o treinamento da RNA foram gerados pelo simulador, os valores de vazão encontrados nos testes com o controlador neural apresentaram uma pequena porcentagem de erro, comprovando provável treinamento adequado da rede. Além disto, ressalta-se que os valores de vazões tanto do controlador neural quanto do controlador *fuzzy* ficaram abaixo da vazão calculada a partir da Equação 2, definida na norma NR-22. Isto confirma empiricamente nossa hipótese de que um controle adequado de vazão pode resultar em economia de energia na mina. Como a Equação 2 considera apenas informações sobre a quantidade de pessoas e máquinas na mina, os valores calculados para a vazão foram aparentemente superestimados, sendo capazes de tratar indiretamente tanto as possíveis concentrações anormais de gases quanto as possíveis temperaturas elevadas da mina. Por outro lado, os controladores propostos levaram em consideração estes elementos de forma independente, resultando em vazões que permitem mantê-los dentro dos limites aceitáveis para os trabalhadores.

Para o conjunto de dados representado pela Tabela 5, encontraram-se erros abaixo de 10% para cerca de 66% dos registros em ambos os controladores propostos. Eles obtiveram um erro superior a 20% no máximo em 16% dos registros de teste.

Para reduzir ainda mais o erro encontrado, torna-se necessário melhorar a construção da base de dados disponível e a arquitetura empregada no treinamento da RNA, além de melhorar a precisão das funções de pertinência representadas. Desta forma, encontrar uma arquitetura para a rede neural que satisfaça o problema em questão trata-se de uma tarefa trabalhosa e que demanda bastante tempo. Além da escolha correta da arquitetura da rede, torna-se necessária a construção de uma base de dados adequada, que proporcione um treinamento da rede capaz de generalizar com sucesso situações não previstas no conjunto de dados, de forma tal que reduza comportamentos imprevisíveis na saída da rede diante destas situações.

Por outro lado, para melhor a precisão da vazão obtida pelo controlado *fuzzy*, pode-se aumentar a quantidade de funções de pertinência, acrescentado novos níveis intermediários para as variáveis de entrada e saída. Outra forma de melhorar os resultados seria a aplicação de algoritmos genéticos ou outras técnicas semelhantes para encontrar as superposições ideais entre as funções de pertinências.

6. Conclusão

Este trabalho teve por objetivo o desenvolvimento de controladores inteligentes, baseados em Redes Neurais Artificias (RNA) e Lógica *Fuzzy*, capazes de propiciarem um controle adequado da vazão necessária para que um sistema de ventilação mantenha as condições de trabalho em minas subterrâneas dentro dos limites toleráveis, além de proporcionarem redução da energia dispendida nesta tarefa.

Para cumprir este objetivo, tornou-se necessário o desenvolvimento de um simulador do ambiente da mina, considerando as concentrações dos gases O_2, CO_2 e CH_4, além da temperatura interna da mina, de forma a simular situações que proporcionassem um treinamento adequado para a RNA. Considerou-se a elaboração de um modelo simplificado e aproximado para a simulação da atmosfera da mina, uma vez que este não corresponde ao foco principal deste trabalho de pesquisa.

Observou-se no projeto da rede neural artificial, a importância de obter-se uma base de dados adequada para seus processos de treinamento e validação. Buscando mitigar esta dificuldade, a simulação do ambiente da mina considerou tanto situações normais quanto anormais das concentrações dos gases e da temperatura interna da mina. Deve-se ressaltar que o ambiente de uma mina subterrânea possui diversas variáveis e alta complexidade, tornando-o difícil uma modelagem precisa do controle de ventilação.

De maneira geral, consideraram-se satisfatórios os resultados obtidos pelos controladores neural e *fuzzy*, levando em consideração tanto as imprecisões inerentes das técnicas adotadas quanto, respectivamente, as simplificações e aproximações do modelo de simulação utilizado para a geração dos dados de treinamento da RNA, e a imprecisão existente no processo de criação de regras de inferência, segundo a experiência e observação do projetista. A maioria dos resultados dos controladores se aproximou do esperado.

Ambas as técnicas apresentaram vantagens e desvantagens no controle de ventilação e, dependendo da aplicação, aconselha-se a adoção de uma técnica em detrimento da outra. A lógica *fuzzy* apresentou maior flexibilidade, apesar de não ter como característica uma grande precisão da resposta. Assim, nas situações envolvendo problemas bem conhecidos, onde a modelagem matemática se torna tão complexa que prejudica a precisão e a confiabilidade do modelo, e naquelas onde não existe disponível um banco de dados descrevendo as situações previstas, recomenda-se a aplicação de Lógica *Fuzzy*. A principal desvantagem na adoção de RNA para controle de ventilação consiste na imprevisibilidade da saída durante a ocorrência de situações não previstas durante o treinamento, o que poderia indicar um superajuste da rede.

Referências

Barry, R. G. e Chorley, R. J. (2013). Atmosfera, tempo e clima. Bookman, Porto Alegre.

Braga, A. P., Carvalho, A. C. P. L. F. e Ludemir, T. B. (2000). Redes Neurais Artificiais: Teoria e Aplicações. LTC, Rio de Janeiro.

Brasil (2015). Ministério do Trabalho e Emprego. NR 15 – Atividades e Operações Insalubres. Web page. http://www.mte.gov.br/index.php/seguranca-e-saude-no-trabalho/2015-09-14-19-18-40/2015-09-14-19-23-50/2015-09-29-20-46-53. Acessado: 2015-07-25.

Brasil (2015). Ministério do Trabalho e Emprego. NR 22 – Saúde e Segurança Ocupacional na Mineração. Web page. http://www.mte.gov.br/index.php/seguranca-e-saude-no-trabalho/2015-09-14-19-18-40/2015-09-14-19-23-50/2015-09-29-20-46-60. Acessado: 2015-07-22.

Brasil (2015). Ministério do Trabalho e Emprego. NR 33 – Segurança e Saúde no Trabalho em Espaços Confinados. Web page. http://www.mte.gov.br/index.php/seguranca-e-saude-no-trabalho/2015-09-14-19-18-40/2015-09-14-19-23-50. Acessado: 2015-07-25.

Çengel, Y. A. e Ghajar, A. J. (2012). Transferência de calor e massa: uma abordagem prática. AMGH, Porto Alegre.

Chatburn, R. L. (2004). Computer control of mechanical ventilation. Respiratory care, v.49, n. 5, p. 507-508.

De Carvalho, C. H. R. (2011). Emissões relativas de poluentes do transporte motorizado de passageiros nos grandes centros urbanos brasileiros. Texto para Discussão, Instituto de Pesquisa Econômica Aplicada (IPEA).

Garcia, R. F. (2014). Combustíveis. Web page. http://garcia.xpg.uol.com.br/aula11_combustiveis.pdf. Acessado: 2015-08-02.

Gonçalves, B. M. G.; Portes, D. de S. P.; Fernandes, D. G.; Souza, D. F de.; Andrade, L. R. (2009). Ventilação em Mina Subterrânea. UEMG, João Monlevade.

Hagan, M. T., Demuth, H. B., Beale, M.H. e De Jesús, O. (2014). Neural Network Design. Martin Hagan, Oklahoma.

Hagan, M. T., Demuth, H. B. e Beale, M.H. (2015). Neural Network Toolbox^{TM}: user's guide. MathWorks, Natick.

Haykin, S. (2001). Redes Neurais: Princípios e prática. Bookman, Porto Alegre.

Hartman, H. L., Mutmansky, J. M., Ramani, R. V. e Wang, Y. J. (2012). Mine ventilation and air conditioning. John Wiley & Son, New York.

JBS Construtora e Serviços (2012). Como calcular combustível máquinas. Web page. http://www.construplena.com.br/noticia.php?id=13. Acessado: 2015-08-02.

Linde Gases Ltda (2008). Gás-Massa-Líquido. Web page. http://hiq.linde-gas.com.br/international/web/lg/br/like35lgspgbr.nsf/docbyalias/down_gas_mass_liq. Acessado: 2015-08-03.

McPherson, M. J. (2012). Subsurface ventilation and environmental engineering. MVS Engineering, Clovis.

Moran, M. J. e Shapiro, H. N. (2002). Princípios de termodinâmica para engenharia. LTC, Rio de Janeiro.

Petrobrás Distribuidora S.A. (2012). Web page. http://www.br.com.br/wps/portal/portalconteudo/produtos/automotivos/gasolina/!ut/p/c4/04_SB8K8xLLM9MSSzPy8xBz9CP0os3hLf0N_P293QwP3YE9nAyNTD5egIEcnQ4MgQ_2CbEdFAGTlInk!/?PC_7_9O1ONKG10GSIC025HDRRAB10F4000000_WCM_CONTEXT=/wps/wcm/connect/portal+de+conteudo/produtos/automotivos/gasolina/duvidas+frequentes+gasolinas+petrobras#top . Acessado: 2015-08-02.

Rabelo, R. A. L., Carneiro, A. A. F. M., Fernandes, R. A. S. e Braga, R. T. V. (2011). Uma abordagem baseada em sistemas de inferência Fuzzy Takagi-Sugeno aplicada ao planejamento da operação de sistemas hidrotérmicos de geração. In SBA Controle & Automação, p. 49-64, Campinas.

Ross, T. J. (2010). Fuzzy logic with engineering applications. John Wiley & Son, Chichester.

Simões, M. G. e Shaw I. S. (2007). Controle e Modelagem Fuzzy. Blucher: Fapesp, São Paulo.

Tomsovic, K. e Chow, M. Y. (2000). Tutorial on Fuzzy Logic Applications in Power Systems. IEEE PES Winter Meeting, Singapore.

Vutukuri, V. S. e Lama, R. D. (1986). Environmental engineering in mines. Cambridge University Press, Nova Iorque.

Weber, L., Klein, P. A. T. (2003). Aplicação da lógica fuzzy em software e hardware. Ulbra, Canoas.