

Detecção de Presença a Partir de Dados de Sensores Utilizando Rede Neural ARTMAP Fuzzy

Danieli Biagi Vilela * Anna Diva Plasencia Lotufo **

* Laboratório de Sistemas Inteligentes, Programa de Pós Graduação em Engenharia Elétrica, Universidade Estadual Paulista "Júlio de Mesquita Filho", SP (e-mail: biagidanieli@gmail.com)

** e-mail: anna.lotufo@unesp.br

Abstract: Presence detection in an environment has proved to be a task with great potential to increase the energy efficiency of buildings and aid in remote monitoring and assistance technologies in smart buildings. With the increasing availability of sensors and integrated technologies, smart buildings have evolved in the way they interact with users, with machine learning and artificial neural networks techniques stand out in recent literature. In order to test new algorithms for this task, we propose in this work the use of the Fuzzy ARTMAP artificial neural network as a classifier algorithm. Data obtained from temperature, CO₂, light and humidity sensors were used. The simulations were performed with training in sequential and random order and with two sample sizes. The results show a higher accuracy when compared to the literature average and by the network diagnosis time the algorithm can be added to a commercial real time presence detection system.

Resumo: A detecção de presença em um ambiente tem se mostrado uma tarefa com grande potencial para aumentar a eficiência energética de prédios e auxiliar em tecnologias remotas de monitoramento e assistência nos *smarts buildings*, prédios inteligentes. Com a disponibilidade cada vez maior de sensores e tecnologias integradas, os *smarts buildings* vêm evoluindo na maneira de interação com usuários, com destaque na literatura recente as técnicas de *machine learning* e redes neurais artificiais. Com o intuito de testar novos algoritmos para esta tarefa, foi proposto neste trabalho, o uso da rede neural artificial ARTMAP Fuzzy como algoritmo classificador. Foram utilizados dados obtidos de sensores de temperatura, CO₂, luz e umidade. As simulações foram realizadas com treinamento em ordem sequencial e aleatória e dois tamanhos de amostras. Foi possível observar uma acurácia na classificação maior que a média observada na literatura, e pelo tempo de diagnóstico da rede, o algoritmo pode ser agregado em um sistema comercial de detecção de presença em tempo real.

Keywords: Presence Detection; Smarts Buildings; Smart Environments; Artificial Neural Networks; Fuzzy ARTMAP.

Palavras-chaves: Detecção de Presença; Prédios Inteligentes; Ambientes Inteligentes; Redes Neurais Artificiais; ARTMAP Fuzzy;

1. INTRODUÇÃO

Ambientes inteligentes vêm se tornando populares nos últimos anos e assumindo importantes funções nas tarefas cotidianas. Para Cook and Das (2007) um ambiente inteligente adquire conhecimento sobre o ambiente e os aplica, de forma a melhorar a experiência dos usuários na interação com o ambiente. Um exemplo de ambientes inteligentes são os sistemas de gerenciamento de energia e conforto de edifícios, em inglês *Building Energy and Comfort Management* (BECM), usados em *Smart Buildings*. São sistemas de controle para edifícios que usam computadores e microprocessadores distribuídos para monitoramento, armazenamento de dados e comunicação.

São funções centrais em um sistema BECM o controle de aquecimento, ventilação e ar condicionado, em inglês

heating, ventilation, and air-conditioning (HVAC), controle de iluminação e controle de eletricidade (Levermore (2000)). Pelas características de fabricação e funcionamento, a maioria dos equipamentos de HVAC presumem uma ocupação máxima dos ambientes. Um sistema de ar condicionado, por exemplo, projetado para uma sala com capacidade de cem pessoas não adapta seu funcionamento se a sala estiver ocupada por dez pessoas, gerando assim um gasto adicional de energia.

Nesse sentido, estudos demonstraram o potencial da detecção de presença e/ou ocupação dos ambientes para um consumo mais consciente e eficiente de energia. Com a utilização de dados de sensores e algoritmos para detecção de presença é possível atingir uma economia anual de energia de até 42% nos sistemas de HVAC (Erickson et al. (2011)). Uma investigação recente em prédios comerciais,

mostrou uma grande variação no potencial de economia de energia, de 29% a 80% dependendo do perfil de utilização (Brooks et al. (2014)).

De maneira holística, pode-se enxergar o sistema de detecção de presença de um ambiente em quatro etapas principais: medição de parâmetros do ambiente, coleta de dados, algoritmos classificadores e perfil de ocupação (usado como base para avaliação e determinação de estratégias de gerenciamento de BECM e/ou HVAC). A Figura 1 apresenta um esquema representativo dessas etapas com alguns exemplos.

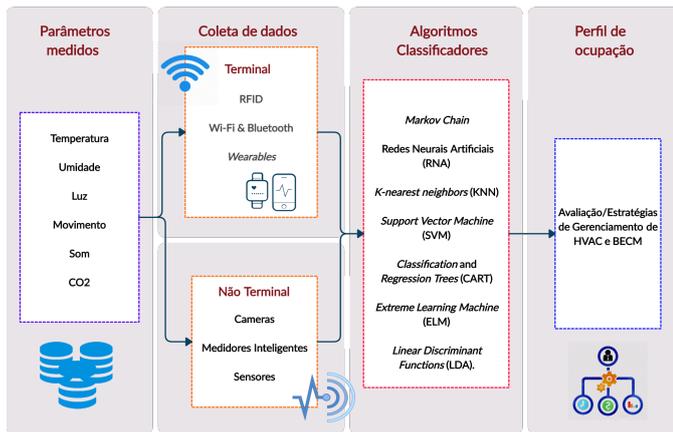


Figura 1. Visão geral das principais etapas de um sistema de detecção de presença.

Em relação à coleta de dados, os sistemas podem ser classificados de acordo com a necessidade de usar um terminal ou não (Lee et al. (2006)). No caso dos métodos que requerem um terminal, é necessário que os ocupantes se conectem a dispositivos sem fio que suportem tecnologias de comunicação, como Identificação por radiofrequência, do inglês (*Radio-frequency identification*) (RFID), Wi-Fi, Bluetooth ou GPS (*Global Positioning System*) no caso de dispositivos vestíveis (*wearables*). Nos métodos não terminais, a detecção é com base em uma abordagem passiva focada no monitoramento do ambiente, usando, por exemplo, câmeras para monitoramento visual ou infravermelho, sensores e medidores inteligentes para consumo de energia.

Para a fase de classificação, diversos algoritmos foram propostos para a tarefa de detecção de presença. Podem se destacar entre eles modelos estatísticos e estocásticos, como *Markov Chain* e suas variações, algoritmos de *Machine Learning*, como Redes Neurais Artificiais (RNA), *K-nearest neighbors* (kNN), *Support Vector Machine* (SVM), *Classification and Regression Trees* (CART), *Extreme Learning Machine* (ELM), e *Linear Discriminant Analysis* (LDA) (Nguyen and Aiello (2013)).

Em Elkhokhi et al. (2018), foram aplicados algoritmos de *Machine Learning* no mesmo banco de dados utilizado no presente estudo. Para aprendizado off-line, os autores utilizaram LDA para o treinamento e RF (*Random Forest*) e CART para teste. Para o aprendizado online foi agregado ao modelo o algoritmo *Vertical Hoeffding Tree*. A precisão máxima alcançada foi 95% de classificações corretas.

Além da detecção da ocupação, no trabalho de Lam et al. (2009) foi feita a detecção do número de ocupantes. Utili-

zaram a RNA *Feed-Forward* com duas camadas escondidas de 12 neurônios cada aliada com *Hidden Markov Models* (HMM) no treinamento. A precisão média da detecção foi de 80%.

Um sistema com múltiplos sensores foi utilizado para capturar os dados de utilização em Yang et al. (2012). Além das medidas usuais de temperatura, umidade, concentração de CO₂ e luminosidade, o modelo também usa som e movimento. O classificador utilizado foi uma RNA de Base Radial (RBF). Testes de campo foram realizados e a melhor taxa de detecção foi de 87,62% das amostras.

Foram testados sete algoritmos para treinamento de uma RNA *Feed-Forward* em Tutuncu et al. (2016) no mesmo banco de dados investigado no presente trabalho. O melhor resultado foi obtido pelo algoritmo *Limited Memory Quasi-Newton* (Phua and Ming (2003)), que obteve uma porcentagem de acerto média de de 98,803%.

Além de ser uma ferramenta que comprovadamente aumenta a eficiência energética de prédios, o sistema de detecção de ocupação a partir de dados de sensores em ambientes inteligentes tem outras aplicações atuais, muito importantes no contexto do isolamento social que o mundo está atravessando devido a pandemia causada pelo Covid-19, como determinação e mapeamento do comportamento dos ocupantes para reconhecimento de padrões, sistemas de monitoramento e segurança (Rashidi and Cook (2010)).

Apesar dos sistemas disponíveis e dos muitos protótipos em construção, a tarefa de detecção de presença em ambientes ainda é um processo sujeito a várias variáveis, propenso a erros e caro em muitos casos (Nguyen and Aiello (2013)). Por esse motivo, investigações são necessárias para aumentar a eficiência das ferramentas utilizadas e tornar os protótipos viáveis em escala real e comercial.

Este estudo propõe a utilização de um novo algoritmo classificador, ainda não testado na literatura para essa tarefa. Será investigado o desempenho da RNA ARTMAP *Fuzzy* (Carpenter and Grossberg (1992)) para a detecção de presença em um ambiente a partir de dados de sensores, com o objetivo de melhorar a eficiência reportada na literatura na detecção de presença com dados reais.

2. DESCRIÇÃO DO PROBLEMA E DOS DADOS

Utilizou-se, neste trabalho, o banco de dados proposto por Candanedo e Feldheim Candanedo and Feldheim (2016) para o problema de detecção da ocupação em um ambiente. No estudo, um escritório de dimensões 5.85m × 3.50m × 3.53m, ocupado por 2 pessoas, foi monitorado com sensores para medir as variáveis temperatura, umidade, luminosidade e níveis de CO₂. Os dados foram amostrados uma vez por minuto, o que corresponde, por exemplo, a 1440 amostras em 24 horas de medição.

No experimento, foram usados sensores DHT22 para temperatura (medida em °C) e umidade relativa (medida em %), sensor TSL2561 para luminosidade (Lux) e o Telaire 6613 para medir a quantidade de CO₂ no ambiente (em ppm). Também foi utilizado um microcontrolador Arduino para adquirir os dados, conectado a um rádio ZigBee que transferia os dados para uma estação de gravação. As informações de precisão e resolução e demais detalhes

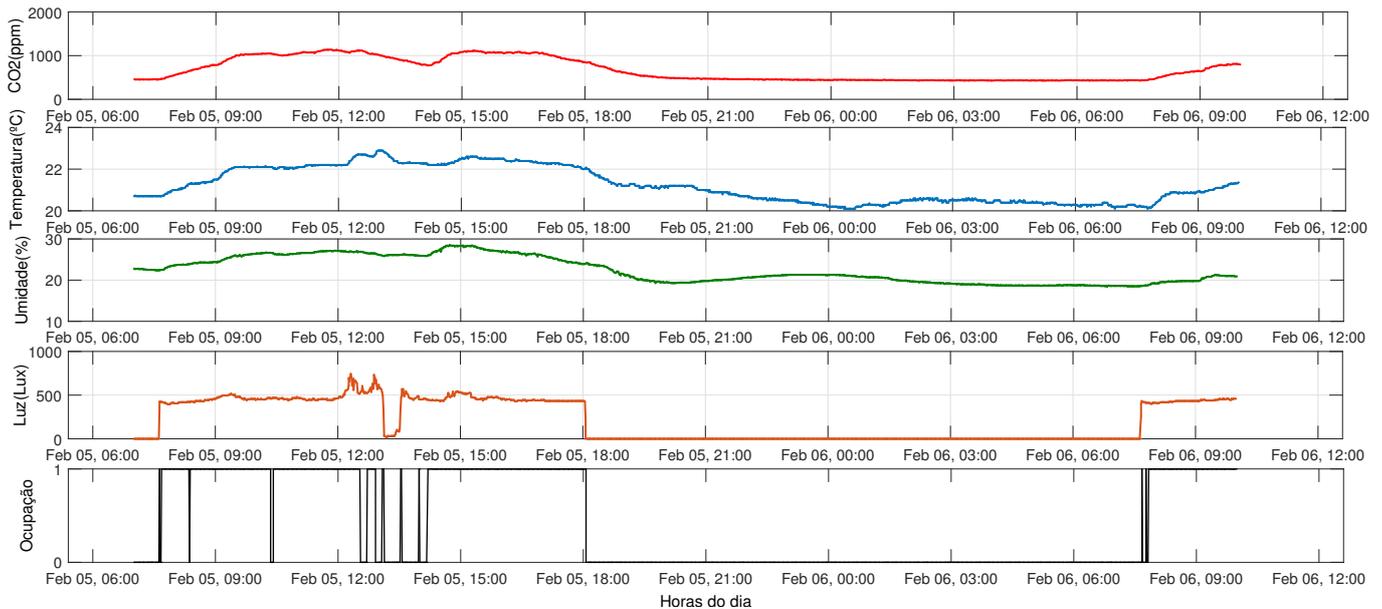


Figura 2. Comportamento das variáveis medidas em função das horas do dia.

do sistema de coleta e construção do banco de dados se encontram em Candanedo and Feldheim (2016).

Para compor o banco de dados de comparação, requerido por algoritmos supervisionados, foi utilizado uma câmera, que fotografou a cada minuto, com dados do timer. Em seguida, fez-se um trabalho manual de verificar as imagens para a construção da variável ocupação. Quando não houvesse nenhum ocupante nas imagens, a variável ocupação recebia 0 e quando houvesse, recebia 1.

O perfil de ocupação do escritório determina o comportamento das variáveis medidas. A Figura 2 mostra o comportamento das variáveis investigadas em relação ao tempo, iniciando as 07:00 horas de um dia e terminando as 10:00 horas do dia seguinte. As maiores variações nas medidas acontecem por volta das 08:00 horas quando o ambiente começa a ser ocupado e todos os sensores registram aumento e as 18:00 horas quando iniciam uma diminuição gradual que se estende até as 08:00 horas do dia seguinte. O sensor de luminosidade, porém, não apresenta o mesmo comportamento, a diminuição e aumento acentuado representam o momento em que as luzes são desligadas e ligadas, respectivamente.

É importante ressaltar que, as variáveis CO_2 , temperatura e umidade apresentam uma variação gradualmente mais lenta. De acordo com Lam et al. (2009) um aumento de 50 ppm no nível de CO_2 em 10 minutos tem alta correlação com a presença humana, dependendo da localização do sensor. Em relação à temperatura, (Dong and Andrews, 2009) constataram que em uma sala sem aberturas externas, as flutuações de temperatura causadas pela presença humana são mínimas ou variam lentamente com o tempo. Os sensores, dependendo da precisão, e do perfil da ocupação do ambiente, podem não ser capazes de captar bem essas pequenas variações.

2.1 Redes Neurais Artificiais e ARTMAP Fuzzy

Uma RNA é um processador massivamente distribuído em paralelo constituído de unidades de processamento mais simples (os neurônios), que armazenam conhecimento experimental e o tornam disponível para o uso. Se assemelha ao cérebro humano nos aspectos de adquirir conhecimento do ambiente por meio de um processo de aprendizagem, conhecido como treinamento, e em armazenar o conhecimento adquirido por meio das conexões entre os neurônios, chamadas de pesos sinápticos (Haykin (1999)).

A era moderna das RNA's teve seu início com a publicação de McCulloch and Pitts (1943), em que os autores apresentaram um cálculo lógico de redes neurais que unificava estudos de fisiologia e matemática. Propuseram que, com quantidade adequada de neurônios e conexões sinápticas sincronizadas e propriamente ajustadas, a rede proposta realizaria, a princípio, o cálculo de qualquer função computável.

As RNA's da família ART (*Adaptive Resonance Theory*) foram introduzidas por Carpenter and Grossberg (1987) como uma resposta ao problema de estabilidade-plasticidade: a rede deve ser flexível para aprender novos padrões enquanto se mantém estável. A ARTMAP, versão supervisionada da rede ART, é reconhecida pela sua eficiência na detecção e classificação de categorias em variadas aplicações (Lopes et al. (2005)). Por essas características, foi o algoritmo escolhido como classificador nesse trabalho.

A arquitetura ARTMAP *Fuzzy* (Carpenter and Grossberg (1992); Carpenter et al. (1992a,b)), utilizada neste trabalho, é uma versão da RNA ARTMAP que incorpora em sua estrutura operações de conjuntos *Fuzzy*. A ARTMAP *Fuzzy* pode reconhecer e aprender padrões de entrada binários e analógicos devido a substituição do operador de interseção (\cap) pelo operador *Fuzzy* AND (\wedge). Seu aprendizado é supervisionado, *i.e.*, necessita de uma resposta para comparação, e auto organizável.

2.2 Funcionamento da Rede Neural ARTMAP Fuzzy

A rede é composta por dois módulos ART Fuzzy (ARTa e ARTb). O conjunto dos dados de entrada é apresentado à ARTa Fuzzy e os dados de saída correspondentes à ARTb Fuzzy. O terceiro módulo, *inter-ART*, é um sistema de conexão entre os dois módulos ART que combina os parâmetros de entrada com os de saída através de um mecanismo regulador chamado *match tracking*. Esse mecanismo maximiza a generalização da rede e minimiza o erro (Carpenter and Grossberg (1992)). Para ajudar na compreensão da arquitetura e estrutura de fluxo, foi elaborado um esquema representativo da RNA ARTMAP Fuzzy baseada em Carpenter et al. (1992b), apresentado na Figura 3.

Cada sistema ART inclui um campo F_0 que representa o vetor de entrada atual, um campo F_1 que recebe entradas de F_0 (de baixo para cima) e de F_2 (cima para baixo). Os nós (índices) da camada F_2 são denotados por j em F_2^a , com $j = 1, \dots, N_a$ e por k em F_2^b com $k = 1, \dots, N_b$. Eles simbolizam categorias que competirão para representar as entradas nos dois módulos. N_a e N_b são as dimensões dos vetores de entrada dos módulos ARTa e ARTb, respectivamente.

O funcionamento da RNA ARTMAP Fuzzy será aqui apresentado com as principais etapas de seu algoritmo, de acordo com Carpenter et al. (1992b).

(1) Dados de entrada

Os vetores de entrada, módulo ARTa Fuzzy são representados pelo vetor $a = [a_1 \dots a_{M_a}]$, sendo M_a o número de vetores de entrada em ARTa e o vetor de entrada de ARTb Fuzzy (correspondente a saída desejada) é representado por $b = [b_1 \dots b_{M_b}]$, sendo M_b o número de vetores de entrada em ARTb. Para evitar a proliferação de categorias, esses vetores são normalizados de acordo com (1) e (2):

$$\bar{a} = \frac{a}{|a|} \quad (1)$$

$$\bar{b} = \frac{b}{|b|} \quad (2)$$

Em seguida é efetuada a codificação de complemento (I^a e I^b) (3) e (4), que preserva a amplitude dos dados de entrada:

$$I^a = [a \bar{a}] \quad (3)$$

$$I^b = [b \bar{b}] \quad (4)$$

Os vetores de atividade mostram se o nó está ativo (1) ou não (0) nas camadas da RNA. Na camada F_1 o vetor de atividade é denotado por X^a em ARTa e X^b em ARTb, na F_2 é Y^a em ARTa e Y^b em ARTb e no módulo *inter-ART* é X^{ab} .

(2) Parâmetros da rede

Os três principais parâmetros da rede ARTMAP Fuzzy (Carpenter et al. (1992b)) são:

- Parâmetro de escolha ($\alpha > 0$): atua na seleção de categorias;
- Parâmetro de vigilância ($\rho \in [0, 1]$): Controla a ressonância da rede, ou seja, verifica a combinação dos padrões de entrada e seus respectivos

pesos. É responsável pelo número de categorias criadas, que representam a capacidade de generalização da rede. Cada módulo tem um ρ próprio: ρ_a , ρ_b e ρ_{ab} ;

- Taxa de treinamento ($\beta \in [0, 1]$): controla a velocidade de adaptação da rede;

(3) Inicialização dos pesos

Inicialmente todos os pesos têm valor igual a 1, indicando que não existe nenhuma categoria ativa, *i.e.*, nenhum nó dos vetores de entrada foi ativo.

$$w_{j_1}^a(0) = w_{k_1}^b(0) = w_{j_1}^{ab}(0) = 1; \quad (5)$$

(4) Escolha de categoria

Esta etapa realiza um teste de similaridade entre os vetores de entrada e os possíveis candidatos a representá-los (nós j e k). Dado os vetores de entrada com codificação de complemento I^a e I^b , as funções de escolha T_j^a e T_k^b são determinadas por:

$$T_j^a(I^a) = \frac{|I^a \wedge w_j^a|}{\alpha + |w_j^a|} \quad (6)$$

$$T_k^b(I^b) = \frac{|I^b \wedge w_k^b|}{\alpha + |w_k^b|} \quad (7)$$

As categorias j e k são escolhidas como ativas (ju) e (kv), ou seja, adequadas e confirmadas para representar o padrão de entrada se estiverem de acordo com:

$$ju = \max \{T_j^a : j = 1 \dots, N_a\}; \quad (8)$$

$$kv = \max \{T_k^b : k = 1 \dots, N_b\}; \quad (9)$$

(5) Ressonância e Reset

Os critérios de vigilância dos módulos ARTb Fuzzy (10) e ARTb Fuzzy (11) devem ser satisfeitos para continuar o processo de combinação. Caso contrário ocorre o *reset*, o nó ju é excluído do processo de busca, T_j^a assume o valor zero e é escolhida uma nova categoria por (6).

$$\frac{|I^b \wedge w_{kv}^b|}{|I^b|} \geq \rho_b \quad (10)$$

$$\frac{|I^a \wedge w_{ju}^a|}{|I^a|} \geq \rho_a \quad (11)$$

Uma vez que as categorias dos dois módulos estão ativas, utiliza-se um mecanismo regulador denominado *match tracking* do módulo *inter-ART*, com parâmetro de vigilância ρ_{ab} , para verificar se a categoria ativa em ARTa Fuzzy corresponde à saída desejada apresentada em ARTb Fuzzy por meio da equação:

$$\frac{|Y^b \wedge w_{ju}^{ab}|}{|Y^b|} \geq \rho_{ab} \quad (12)$$

(6) Atualização dos pesos

O aprendizado da rede se dá pela atualização dos pesos. Após ocorrer a ressonância, os pesos de ARTa Fuzzy são atualizados por (12) e os de ARTb Fuzzy por (13):

$$w_{ju}^{anovo} = \beta(I^a \wedge w_{ju}^{avelho}) + (1 - \beta)w_{ju}^{avelho} \quad (13)$$

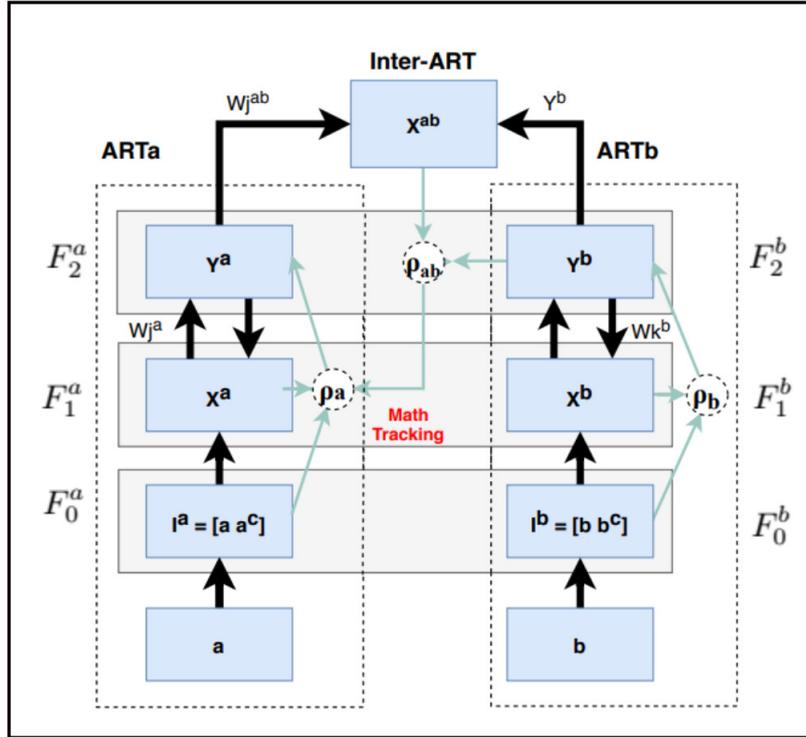


Figura 3. Arquitetura da RNA ARTMAP *Fuzzy*

$$w_{kv}^{novo} = \beta(I^b \wedge w_{kv}^{velho}) + (1 - \beta)w_{kv}^{velho} \quad (14)$$

A atualização dos pesos de *inter-ART* é feita por (14) e (15) para $j \neq jv$ e $k \neq kv$.

$$w_{jv,kv}^{ab} = 1 \quad (15)$$

$$w_{jv,k}^{ab} = 0 \quad (16)$$

3. RESULTADOS E DISCUSSÃO

A construção, treinamentos e testes da RNA ARTMAP *Fuzzy* foram feitos no software MATLAB R2015b. As variáveis temperatura, umidade, luminosidade e CO₂ compõem as entradas do módulo ART_a *Fuzzy* e a ocupação real medida é a entrada do módulo ART_b *Fuzzy*.

O número total de dados de treinamento é 8143 vetores (padrões de entrada), o que corresponde a, aproximadamente, 5,6 dias de utilização. Foram utilizados 70% do valor total para treinamento e 30% para teste, 5700 e 2443 amostras, respectivamente. Uma vez finalizado o treinamento, para o procedimento de teste, compara-se a saída real do problema (módulo ART_b *Fuzzy*) com a saída calculada pela rede ARTMAP *Fuzzy*. Como o ambiente é utilizado 8 horas por dia, os dados são compostos aproximadamente por $\frac{2}{3}$ de estados desocupados (0) $\frac{1}{3}$ de ocupados(1).

Os parâmetros da rede foram ajustados por tentativa e erro, executando diferentes treinamentos e comparando-se o desempenho entre eles. O vetor de parâmetros utilizado, está apresentado na Tabela 1.

Tabela 1. Vetor ótimo de parâmetros da rede ARTMAP *Fuzzy*.

Parâmetros	Valores
α	0,01
ρ_{a_0}	0,80
ρ_b	1,00
ρ_{ab}	1,00
β_a	0,70
β_b	1,00

Foi variada a forma de apresentação das entradas para a rede, executando testes com vetores em ordem sequencial e aleatória. Com os vetores em ordem aleatória, foram feitas 20 simulações de treinamento. Para o treinamento em ordem sequencial o acerto foi de 98,81%. O desempenho do treinamento em ordem aleatória, com média e coeficiente de variação (C.V.) para cada simulação está apresentado na Tabela 2. O tempo diagnóstico médio, etapa de teste da rede, foi de 0,00631 segundos por entrada.

A média da taxa de acerto na classificação foi de 98,50% e o valor máximo foi encontrado na simulação 6: 99,68%. O acerto da rede não apresentou grandes variações percentuais nas simulações, com C.V. de 0,65%, o que demonstra a adequação da metodologia e do uso da ARTMAP *Fuzzy* como algoritmo classificador para dados obtidos de sensores e a robustez do aprendizado da rede. Apesar de poucas variações percentuais no acerto, a ordem de apresentação das entradas na rede influencia no desempenho da classificação.

Como o desempenho da qualificação foi próximo de 100%, os perfis de ocupação durante um dia de utilização do ambiente se sobrepõem em quase todos os pontos, exceto

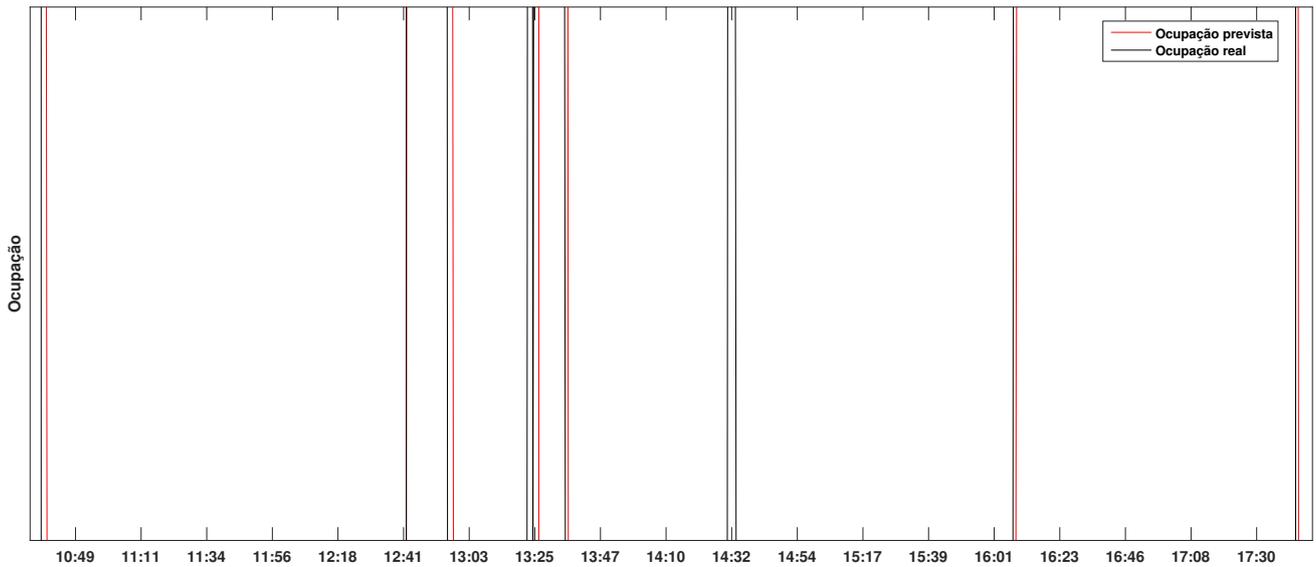


Figura 4. Comparação da ocupação real e calculada pela rede na Simulação 6.

Tabela 2. Desempenho da RNA ARTMAP Fuzzy com entradas em ordem aleatória.

Simulações	Acerto (%)	Categorias
1	98,32	17
2	98,96	18
3	99,30	22
4	98,08	16
5	98,44	18
6	99,68	17
7	97,36	17
8	98,60	12
9	97,36	14
10	98,39	17
11	98,56	16
12	97,84	16
13	99,51	19
14	98,12	13
15	98,96	18
16	97,92	18
17	99,19	16
18	98,52	14
19	98,44	12
20	98,39	18
Média(%)	98,50	16,8
C.V.(%)	0,65	14,99

nos erros de classificação da rede. Por esse motivo, os pontos de erro foram aproximados (*zoom*) na Figura 4 para melhor visualização. A Simulação 6 classificou de forma errada 8 em 2443 amostras (0,32% de taxa de erro). Os erros na classificação ao longo do dia se deram em períodos de maior instabilidade na ocupação, como o intervalo para almoço (entre 12:00 e 14:00 horas) e nos horários de entrada e saída de pessoas.

A criação de categorias representa a capacidade de generalização da rede, ou a capacidade de categorizar o espaço de entrada. Uma observação importante é que o número de categorias criadas não tem uma relação diretamente proporcional com o acerto da classificação (Figura 5). Uma rede com alta capacidade de generalização pode criar poucas categorias e não representar bem o conjunto de

dados a serem classificados, fazendo com que diminua o acerto. O contrário pode ocorrer com uma rede com baixa capacidade de generalização, criar muitas categorias e se tornar excessivamente seletiva.

Os erros aconteceram especificamente nos períodos de instabilidade de ocupação e consequentemente instabilidade nas medidas dos sensores. Esse resultado corrobora com a hipótese levantada na seção 2, na qual a variação gradualmente lenta das variáveis temperatura, nível de CO₂ e umidade poderia não ser medida com a precisão necessária pelos sensores utilizados.

A matriz de confusão é uma ferramenta muito utilizada na análise de desempenho de classificadores, mostrando as frequências de classificação para cada classe do modelo: TP (true positives), FP (*false positives*), TN (*true negatives*) e FN (*false negatives*) (Powers and Ailab (2007)). A Tabela 3 apresenta a matriz de confusão para o melhor resultado obtido na classificação. Os erros foram 5 do tipo FP e 3 do tipo FN.

Tabela 3. Matriz de confusão para o melhor resultado obtido.

Presença	Ocupado (1)	Desocupado (0)	Soma
	TP	FP	
Ocupado (1)	729	5	734
Desocupado (0)	FN	TN	
	3	1706	1709

Em sistemas de detecção de presença, a maior quantidade de aplicações são relacionadas a conforto térmico dos usuários e utilização mais eficiente de energia. Os erros FP são mais prejudiciais a utilização de energia elétrica, pois se um sinal falso positivo é gerado na resposta, o sistema se manterá em funcionamento e o ambiente estará desocupado. Já os erros FN são mais nocivos aos ocupantes, pois um sinal de FN levaria a um desligamento dos aparelhos de conforto térmico, podendo causar imprevistos e diminuindo o conforto térmico e confiabilidade do sistema.

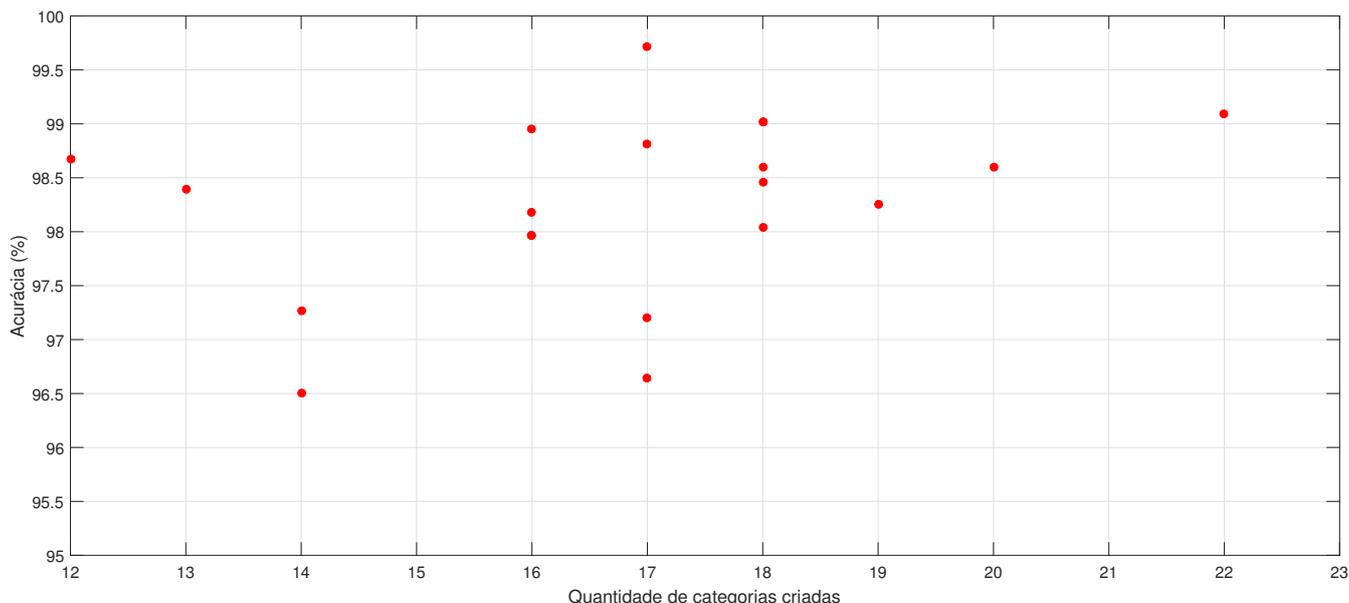


Figura 5. Comparação da acurácia da classificação com a quantidade de categorias criadas para 1440 entradas.

O F-score (17) é uma medida de desempenho de um modelo em um conjunto de dados, usado para avaliar sistemas de classificação binários. É definido como a média harmônica entre a precisão ($\frac{TP}{TP+FP}$) e o recall ($\frac{TP}{TP+FN}$) (Powers and Ailab (2007)).

$$F - score = \frac{TP}{TP + \frac{1}{2}(FP + FN)} \quad (17)$$

Para o melhor resultado, o F-score obtido na classificação feita pela RNA ARTMAP *Fuzzy* foi de 0,9945, mostrando que rede tem um ótimo desempenho em identificar corretamente as classes.

4. CONCLUSÃO E SUGESTÕES PARA TRABALHOS FUTUROS

A RNA ARTMAP *Fuzzy* mostrou um bom desempenho para classificação de dados de sensores, com porcentagem de erros mínima de 0,32%, média de 1,27% e 1,5% e máxima de 2,64%. Pelo tempo de diagnóstico, média de 0,00631 segundos por entrada, porcentagem de acerto da classificação (máxima de 99,68%) e baixa variação com diferentes entradas, o algoritmo tem potencial para ser agregado em um sistema inteligente de detecção de presença em tempo real viável comercialmente.

A ordem de apresentação das entradas no treinamento da RNA ARTMAP *Fuzzy* tem influência no acerto da classificação, porém com um pequeno coeficiente de variação para as simulações realizadas.

O ganho da proposta apresentada em relação à literatura se deve as características da RNA ARTMAP *Fuzzy*, cujo aprendizado é feito baseando-se nas relações entre os dados de entrada associados com as saídas desejadas, sem interferência de funções de modelagem ou aproximações. Os pesos da rede, que armazenam o conhecimento adquirido, somente diminuem a medida que as adaptações são feitas, até a estabilização. Dessa forma, todos os elementos tem

garantia de agrupamento nas classes criadas pelo sistema. Outra característica importante é que, pela atuação do teste de vigilância, a RNA tem a garantia de plasticidade, é capaz de aprender um novo padrão, em qualquer tempo de sua operação, sem perder ou corromper o aprendizado previamente adquirido.

4.1 Sugestões para trabalhos futuros

Para trabalhos futuros, recomenda-se investigar o efeito isolado e combinado das variáveis temperatura, CO₂, luz e umidade na eficiência da classificação e analisar o efeito dos parâmetros da rede ARTMAP *Fuzzy* nas respostas.

AGRADECIMENTOS

O presente trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de financiamento 001 e ao CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico).

REFERÊNCIAS

- Brooks, J., Goyal, S., Subramany, R., Lin, Y., Middelkoop, T., Arpan, L., Carloni, L., and Barooah, P. (2014). An experimental investigation of occupancy-based energy-efficient control of commercial building indoor climate. In *Proceedings of the IEEE Conference on Decision and Control*, 5680–5685. IEEE.
- Candanedo, L.M. and Feldheim, V. (2016). Accurate occupancy detection of an office room from light, temperature, humidity and CO₂ measurements using statistical learning models. *Energy and Buildings*, 112, 28–39.
- Carpenter, G., Grossberg, S., and Iizuka, K. (1992a). Comparative performance measures of fuzzy ARTMAP, learned vector quantization, and back propagation for handwritten character recognition. In *In: IJCNN International Joint Conference on Neural Networks*, 794–799.

- Carpenter, G. and Grossberg, S. (1992). A self-organizing neural network for supervised learning, recognition, and prediction. *IEEE Communications Magazine*, 30(9), 38–49.
- Carpenter, G.A. and Grossberg, S. (1987). A Massively Parallel Architecture for a Self-Organizing Neural Pattern Recognition Machine. *Pattern Recognition*, 115, 54–115.
- Carpenter, G.A., Grossberg, S., Markuzon, N., Reynolds, J.H., and Rosen, D.B. (1992b). Fuzzy ARTMAP: A Neural Network Architecture for Incremental Supervised Learning of Analog Multidimensional Maps. *IEEE Transactions on Neural Networks*, 3(5), 698–713.
- Cook, D.J. and Das, S.K. (2007). How smart are our environments? An updated look at the state of the art. *Pervasive and Mobile Computing*, 3, 53–73.
- Dong, B. and Andrews, B. (2009). Sensor-based occupancy behavioral pattern recognition for energy and comfort management in intelligent buildings. *IBPSA 2009 - International Building Performance Simulation Association 2009*, 1444–1451.
- Elkhoukhi, H., Naitmalek, Y., Berouine, A., Bakhouya, M., Elouadghiri, D., and Essaaidi, M. (2018). Towards a Real-time Occupancy Detection Approach for Smart Buildings. *Procedia Computer Science*, 134, 114–120.
- Erickson, V.L., Carreira-Perpiñán, M.Á., and Cerpa, A.E. (2011). OBSERVE: Occupancy-based system for efficient reduction of HVAC energy. In *Proceedings of the 10th ACM/IEEE International Conference on Information Processing in Sensor Networks, IPSN'11*, 258–269.
- Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation. 2nd Edition*. Prentice-Hall.
- Lam, K.P., Höynck, M., Dong, B., Andrews, B., Chiou, Y.S., Zhang, R., Benitez, D., and Choi, J. (2009). Occupancy detection through an extensive environmental sensor network in an open-plan office building. In *IBPSA 2009 - International Building Performance Simulation Association 2009*, 1452–1459.
- Lee, S., Ha, K.N., and Lee, K.C. (2006). A pyroelectric infrared sensor-based indoor location-aware system for the smart home. *IEEE Transactions on Consumer Electronics*, 52(4), 1311–1317.
- Levermore, G. (2000). *Building Energy Management Systems: Applications to Low-energy HVAC and Natural Ventilation Control*. E & FN Spon, London.
- Lopes, M.L.M., Minussi, C.R., and Lotufo, A.D.P. (2005). Electric load forecasting using a fuzzy ART&ARTMAP neural network. *Applied Soft Computing Journal*, 5(2), 235–244.
- McCulloch, W.S. and Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115–133.
- Nguyen, T.A. and Aiello, M. (2013). Energy intelligent buildings based on user activity: A survey. *Energy and Buildings*, 56, 244–257.
- Phua, P.K. and Ming, D. (2003). Parallel nonlinear optimization techniques for training neural networks. *IEEE Transactions on Neural Networks*, 14(6), 1460–1468.
- Powers, D.M.W. and Ailab (2007). Evaluation : From Precision , Recall and F-Factor to ROC , Informedness , Markedness & Correlation. *Journal of Machine Learning Technologies*, 2(December), 37–63.
- Rashidi, P. and Cook, D.J. (2010). Mining and monitoring patterns of daily routines for assisted living in real world settings. *IHI'10 - Proceedings of the 1st ACM International Health Informatics Symposium*, 336–345.
- Tutuncu, K., Cataltas, O., and Koklu, M. (2016). Occupancy Detection Through Light, Temperature, Humidity, and CO2 Sensors Using ANN. In *Proceedings of ISER 45th International Conference*, 16–20.
- Yang, Z., Li, N., Becerik-Gerber, B., and Orosz, M. (2012). A multi-sensor based occupancy estimation model for supporting demand driven HVAC operations. *Simulation Series*, 44, 100–107.