

Redes *bluetooth* associadas a redes neurais artificiais para monitoramento de suínos

Santos, D.S.¹; Arce, A.I.C.¹; Piza, L.V.¹; Sousa Silva, A.C.¹; Costa, E.J.X.^{1,2} e Tech, A.R.B.^{1,2}*

¹Faculdade de Zootecnia e Engenharia de Alimentos (FZEA), Universidade de São Paulo (USP). Departamento de Ciências Básicas (ZAB). Pirassununga, SP, Brasil.

²Bolsista Produtividade do CNPq.

PALAVRAS CHAVE ADICIONAIS

MultiLayer perceptron. Sistema de comunicação sem fio. Monitoramento de animais. Sistema de posicionamento.

ADDITIONAL KEYWORDS

MultiLayer perceptron. Wireless communication Systems. Animal tracking. Positioning System.

INFORMACIÓN

Cronología del artículo.

Recibido/Received: 21.08.2015

Aceptado/Accepted: 16.03.2016

On-line: 15.10.2016

Correspondencia a los autores/Contact e-mail:

adriano.tech@usp.br

INTRODUÇÃO

O crescimento da população humana e a capacidade de produção de alimentos são dois assuntos que tem despertado um grande interesse nos últimos séculos. Assim, a Teoria de Malthus (1982) já chamava a atenção sobre o grande impacto que o aumento populacional poderia trazer frente a grandes problemas de alimentação, fato

RESUMO

O artigo tem como objetivo apresentar uma metodologia para determinar o posicionamento de suínos em uma baía ou granja, utilizando o valor do *receiver signal strenght indicator* (RSSI) medido entre um dispositivo móvel carregado por um suíno e três dispositivos fixos. Os dados de RSSI foram processados por uma rede neural artificial do tipo *perceptron* multicamadas (PMC), responsável por interpretar os sinais RSSI e correlacioná-los com as coordenadas cartesianas X e Y de localização do suíno. Foi realizado um experimento para coleta dos dados na Faculdade de Zootecnia e Engenharia de Alimentos (FZEA/USP), em uma área de 16 m² que foi dividida em 289 pontos, sendo 286 pontos utilizados para coleta de dados de treinamento e teste da rede PMC. Após o treinamento da rede neural, foram escolhidos 8 pontos aleatoriamente, dentro da área experimental para os quais a rede neural treinada foi capaz de estimar as coordenadas de geolocalização. Após treinamentos e operações realizadas com diversas arquiteturas, concluiu-se que a arquitetura dotada de 10 neurônios na camada intermediária, consistiu-se na melhor alternativa, cujos resultados de monitoramento do suíno foram obtidas com valores aceitáveis de exatidão.

Bluetooth technology associated with artificial neural networks for monitoring swine

SUMMARY

The article aims to present a methodology to determine the positioning of pigs in a stall or barn, using the value of the *receiver signal strength indicator* (RSSI), measured between a mobile device carried by a pig and three fixed devices. The RSSI data were processed by a *neural network artificial multilayer perceptron* (PMC), responsible for interpreting the RSSI signals and correlate them with the Cartesian coordinates X and Y location of the pig. An experiment was conducted to collect data at the Faculty of Animal Science and Food Engineering (FZEA / USP) in an area of 16 m² which was divided into 289 points, with 286 points used to collect training data and test the PMC network. After training of the neural network were chosen randomly 8 points within the experimental area for which the trained neural network was able to estimate the geolocation coordinates and after training and operations carried out with different architectures, it was concluded that the architecture endowed with 10 neurons in the hidden layer, consisted in the best alternative, the results of which monitoring pig were obtained with acceptable accuracy values.

que não se concretizou graças ao avanço das técnicas agrícolas e do desenvolvimento de técnicas mais eficientes de produção de alimentos.

Para produzir alimentos para uma população que superou os 7 bilhões de indivíduos (ONU, 2013), é necessário a utilização de tecnologias que promovam o incremento da produção de gêneros alimentícios, de forma

rápida e com toda a segurança alimentar necessária para manter o bem-estar humano.

No entanto, o controle e monitoramento da produção animal não possui o mesmo desenvolvimento da produção industrial, embora já existam comercialmente sistemas de monitoramento integrados para suínos, aves e gado leiteiro (Sevegnani *et al.*, 2005).

Dentro deste cenário, os conceitos de monitoramento e rastreamento podem ser inseridos como alternativas para o estudo de comportamento de um rebanho suíno, podendo levar a importantes conclusões a respeito do impacto comportamental e sobre a qualidade e produtividade do mesmo.

Associado a isso é necessário o uso de tecnologias e sistemas de informação que permitam conhecer melhor o comportamento dos animais, a fim de garantir o bem-estar destes aumentando em consequência a qualidade e quantidade dos produtos de origem suína.

Desta forma, os sistemas de comunicação com ou sem fio, podem auxiliar aos gestores ou produtores na identificação e no estudo do comportamento dos animais e com isso, melhorar o sistema produtivo de maneira a aperfeiçoar e aumentar a produtividade do rebanho.

Um exemplo de sistema de comunicação de grande interesse para este trabalho é a tecnologia Bluetooth, que se trata de um método de comunicação sem fio que estabelece um *link* de rádio de curto alcance que surgiu com o propósito de substituir cabos para troca de dados entre dispositivos eletrônicos (Kansal, 2002).

O uso da tecnologia bluetooth é uma alternativa interessante, pelo baixo custo e pelo baixo consumo de energia (Billo, 2003), permitindo assim, fácil adaptação ao ambiente de produção suína. A implementação dessa tecnologia no sistema de produção animal, pode possibilitar a aquisição de dados zootécnicos, provenientes de sensores distribuídos no ambiente monitorado, de maneira a proporcionar dados úteis para melhorar o conforto e bem-estar dos animais, tais como: temperatura, umidade, ventilação, entre outros.

Além de possibilitar o monitoramento e controle climático do ambiente de produção, os transmissores bluetooth podem ser utilizados também para geolocalizar os animais dentro da área de criação.

Visto que a potência da onda eletromagnética utilizada para transmitir os dados no transmissor bluetooth é afetada pela distância, seu valor pode ser correlacionado com a distância do dispositivo transmissor. No entanto, além da distância existem outros fatores que podem afetar as características da onda eletromagnética no ambiente de produção suína, tais como a presença de obstáculos na infraestrutura de criação, obstáculos naturais, altura do equipamento com relação ao solo, etc. Dessa forma, estabelecer uma função matemática de correlação que permita inferir a distância entre dois dispositivos através da potência de sinal se torna bastante complexo.

A função que correlaciona o valor da potência do sinal recebido por um dispositivo bluetooth receptor com a posição do elemento transmissor, pode ser ex-

traída através do emprego das redes neurais artificiais (RNA). As RNA são modelos computacionais que buscam operar de modo análogo ao sistema nervoso dos seres vivos (Silva *et al.*, 2010) constituídas de unidades de processamento que se assemelham ao cérebro humano por adquirir conhecimento através de um processo de aprendizagem (treinamento) e armazenar as informações obtidas após o treinamento como pesos sinápticos entre as conexões neuronais artificiais. Com isso, as RNA adquirem a capacidade de generalização fornecendo saídas coerentes para valores de entrada que não estavam entre os dados apresentados durante o aprendizado da rede (Haykin, 2001). Dentre os tipos de rede existentes, podemos destacar as redes perceptron multicamadas (PMC), cujo algoritmo de treinamento é baseado na retropropagação do erro (Backpropagation). O algoritmo de treinamento dessa tecnologia é capaz de extrair características para aproximar qualquer função contínua (Braga *et al.* 2000). Dessa forma, as RNA podem geolocalizar os suínos dentro da área de produção a partir dos sinais emitidos por dispositivos bluetooth fixos distribuídos no ambiente e dispositivos moveis, acoplados aos suínos.

O emprego da inteligência artificial e as redes neurais artificiais na zootecnia de precisão tem chamado cada vez mais a atenção de pesquisadores por se tratar de um paradigma que tem trazido importantes inovações no gerenciamento agropecuário e destaca-se como ferramenta na tomada de decisão, como comprovado nas pesquisas realizadas por Pandorfi *et al.* (2011), Kominakis *et al.* (2002) of the number of hidden layers or of the number of neurons in the layers was required. The effect on the network's predictive ability of the number of records used in the training phase, the number of input variables (i.e. test-day records e Gutiérrez-Estrada *et al.* (2008).

Assim, o objetivo deste trabalho é propor uma metodologia que integre um sistema de comunicação sem fio e as redes neurais artificiais, para monitorar os suínos em um espaço de confinamento através da medição da potência do sinal (bluetooth), entre os nós fixos e os nós móveis (suínos).

MATERIAL E MÉTODOS

A infraestrutura utilizada consiste de um conjunto de dispositivos bluetooth que foram instalados na área de produção (dispositivos fixos). Utilizando um dispositivo bluetooth móvel foram coletados os dados de potência do sinal (RSSI). Cada dado coletado foi relacionado com a posição do nó móvel dentro da área de produção. Com os dados coletados, foi criada uma base de dados que foi posteriormente utilizada para treinar uma rede neural PMC.

COMPOSIÇÃO DA BASE DE DADOS

Para a realização da etapa experimental de aquisição de dados foi utilizada uma área enquadrada nos padrões sugeridos pela Empresa Brasileira de Pesquisa Agropecuária (Embrapa, 2006). Segundo a EMBRAPA, uma granja deve possuir baias que forneçam um espaço de 2m² por leitoa, em número de seis a dez por área, independentemente do tamanho da baia, e 3m²

por porca, em número de cinco a dez animais por área. Dessa forma, foi utilizada uma área quadrada, de piso em concreto com 4 metros de lado, totalizando 16m².

A região utilizada foi dividida em pontos distantes 25 cm entre si, formando uma matriz ou malha de 17 linhas por 17 colunas, totalizando 289 pontos. As coordenadas dessas posições foram utilizadas posteriormente como saídas durante o treinamento da rede PMC. Posições diferentes das utilizadas para o treinamento, desde que dentro da área demarcada, podem ser estimadas pela rede neural por meio de sua característica de generalização (Silva *et al.*, 2010).

Por questão organizacional, escolheu-se um vértice para ser usado como referencial semelhante a um sistema de eixo cartesiano, que na base de dados foi identificado pelas coordenadas X e Y (0,0).

Nas posições ou coordenadas (100,100), (200,300) e (300,100), valores em centímetros em relação à posição de referência (0,0), foram instalados dispositivos bluetooth (versão 4.0). Estes dispositivos foram utilizados como referências fixas para a determinação da posição geográfica dos dispositivos móveis carregados pelos animais. Os dispositivos fixos foram denominados de 1, 2 e 3 (figura 1) e possuem instalado o software Bluetooth SPP PRO que é um software livre para a plataforma android V4.1, capaz de enviar um sinal de *inquiry packet*, para os dispositivos Bluetooth à sua volta e receber uma resposta de cada dispositivo através da qual o software consegue medir a potência do

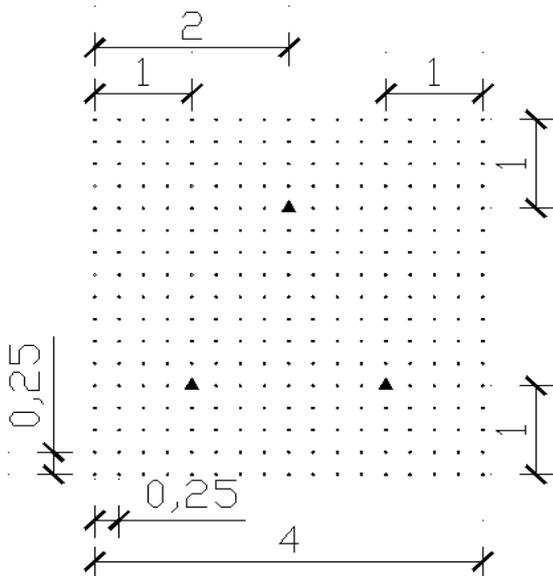


Figura 1. Área utilizada para a realização do experimento e coleta de dados (Area used for the experiment and collect data).

sinal conhecida como *Received Signal strenght indication* (RSSI) (Wang, 2010).

Um dispositivo móvel com tecnologia Bluetooth versão 2.1 foi deslocado através de cada ponto da matriz de pontos construída. Para cada local, identificado como posição (X,Y) foi medido o RSSI (Potencia do sinal) nos três dispositivos fixos.

Em cada uma das posições em que o dispositivo móvel foi posicionado, foram realizadas vinte coletas de RSSI, por cada um dos três equipamentos fixos. Na figura 2 pode-se visualizar o software do dispositivo 1, fazendo a busca e identificação do dispositivo móvel.

O software SPP PRO retorna um número adimensional, que representa a potência do sinal de Bluetooth. Os dados coletados foram organizados em forma de planilha, onde cada linha representa uma posição na área experimental. Para cada linha, existiam 3 grupos de 20 colunas, um grupo para cada dispositivo Bluetooth fixo (estações fixas). No total foram coletados 286 pontos, uma vez que nos pontos (100,100), (200,300) e

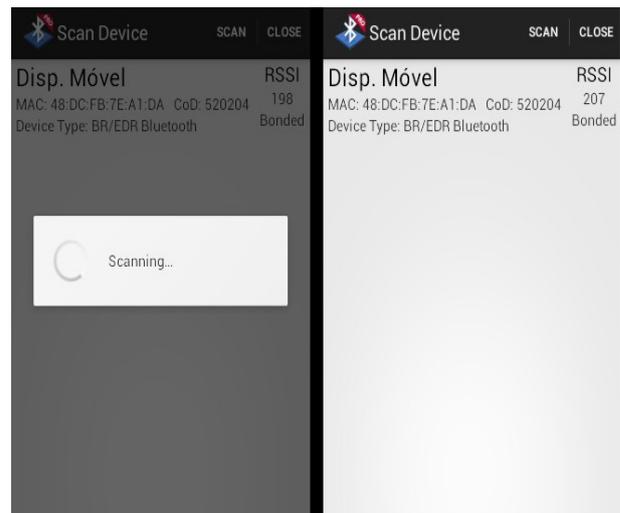


Figura 2. Screenshot da tela do sistema coletor de dados (Screenshot of the collector data system).

(300,100) o dispositivo móvel não foi instalado, visto que nestes pontos estavam os dispositivos fixos 1, 2 e 3, respectivamente.

O sistema de posicionamento proposto, opera de forma semelhante ao conhecido método da triangulação que permite estimar a posição de um dispositivo móvel através da distância do objeto a pelo menos três pontos fixos conhecidos. Para este trabalho, a medição da dis-

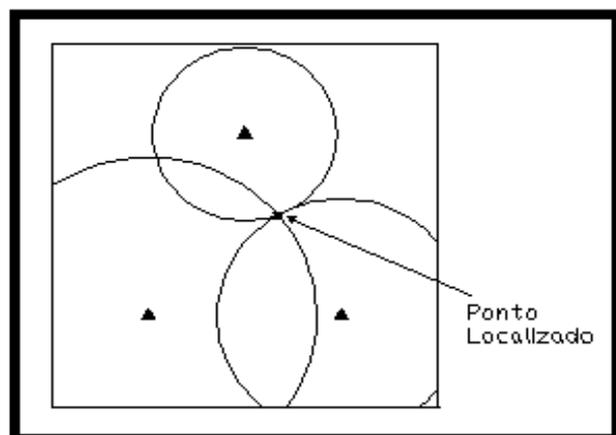


Figura 3. Método da triangulação (Triangulation method).

tância foi substituída pela potência do sinal Bluetooth e a interpretação dessa potência para determinar a localização do objeto é realizada pela rede neural artificial. A **figura 3** ilustra a proposta implementada.

Para a etapa de teste e validação da rede neural artificial, foram escolhidos 8 pontos arbitrários dentro do espaço de 16m² para os quais também foram feitas 20 medidas do RSSI, entre o dispositivo móvel e os três dispositivos fixos.

De modo análogo, esses dados foram dispostos em uma planilha, onde cada linha representa um ponto de teste e para cada uma das linhas existem 3 grupos de 20 colunas. Esses 8 pontos foram utilizados somente no algoritmo de operação da Rede PMC proposta com o intuito de verificar se após a etapa de treinamento a rede foi capaz de inferir a posição do dispositivo móvel a partir do RSSI apresentado.

PROCESSAMENTO DE DADOS

O problema abordado pode ser entendido como um problema de aproximação funcional, uma vez que o valor do RSSI decai de modo não linear, conforme o aumento da distância entre o dispositivo móvel e um dispositivo fixo.

Por outro lado, como a tecnologia Bluetooth opera com um sinal de rádio, é importante lembrar que ondas eletromagnéticas ao se propagarem na atmosfera sofrem absorção de energia por parte de vapor d'água e moléculas de oxigênio (Miguens, 2001). Desta forma, a simples dinâmica atmosférica, como ventos ou mudanças na umidade relativa do ar são capazes de provocarem medidas de RSSI diferentes, para a mesma distância.

Por isso, o valor de RSSI que caracteriza a distância do dispositivo móvel ao dispositivo fixo foi definido pela média aritmética dos vinte valores RSSI lidos. No entanto, nos pontos próximos aos vértices, o valor RSSI por muitas vezes não foi encontrado por um ou mais dispositivos fixos.

Desta maneira, quando qualquer um dos três dispositivos fixos não pode fazer a leitura do valor de RSSI, foi atribuído o valor zero ao RSSI. Em muitos dos pontos em que frequentemente o dispositivo móvel não foi identificado, a média dos vinte valores foi inferior a 150 dBm, que é o valor mínimo de RSSI que o *software*

entrega. Dessa forma, o valor da média também recebeu o valor zero. Isso significa que não foi possível a determinado dispositivo fixo encontrar o dispositivo móvel. Assim, a localização do dispositivo móvel pela rede neural usará o valor zero de um dos dispositivos fixos e os valores obtidos dos outros dois dispositivos fixos.

Para processar os dados foi escolhido o modelo de rede neural perceptron multicamadas (PMC) ou multilayer perceptron (MLP), pois uma rede PMC treinada com o método de retropropagação do erro (backpropagation) constitui uma ferramenta de grande aplicabilidade para mapeamento de sistemas não lineares do tipo entradas e saídas (Haykin, 2001).

A arquitetura da rede utilizada possui uma camada de entrada com três neurônios, que recebem o valor de RSSI fornecido pelos dispositivos fixos 1, 2 e 3, respectivamente, e a camada de saída dotada de dois neurônios referentes às coordenadas X e Y da localização do dispositivo móvel.

Quanto ao número de camadas intermediárias, segundo Silva *et al.* (2010), o teorema da aproximação funcional estabelece que uma camada neural intermediária é suficiente para extrair as características de qualquer função. No entanto, a quantidade de neurônios na camada intermediária que melhor poderá extrair as características da função em questão é obtida de modo empírico.

Assim foi confeccionado um algoritmo de treinamento para rede neural artificial do tipo perceptron multicamadas (PMC), com método de aprendizagem de retropropagação (backpropagation). Como o número de neurônios da camada intermediária não era conhecido, ambos os algoritmos permitem que se escolha o número de neurônios na referida camada, para que se faça o treinamento e operação, permitindo, assim, a comparação dos seus desempenhos.

No entanto, a função logística, utilizada como função de ativação dos neurônios, é totalmente diferenciável, variando no intervalo de 0 a 1. Por isso, a fim de evitar que a função logística fique em saturação devido aos valores elevados das médias em dBm e das coordenadas X e Y, os dados foram normalizados no intervalo de 0 a 1 tanto para os valores de entrada (RSSI) quanto para os valores de saída (coordenadas X e Y).

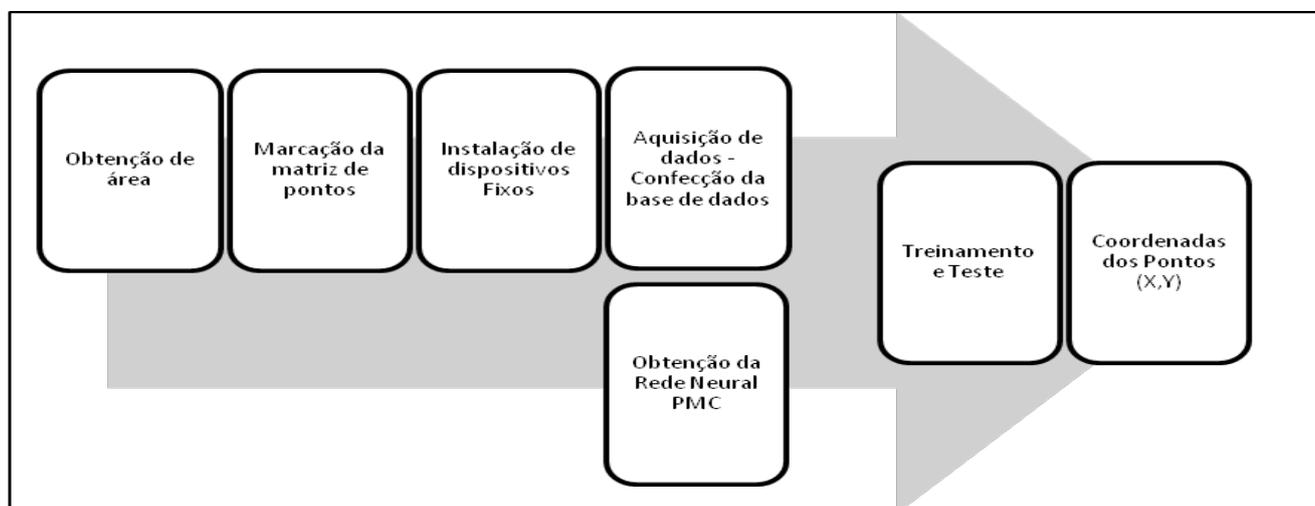


Figura 4. Descrição e preparo da área para o desenvolvimento do experimento (Description and preparation area for the development of the experiment).

A **figura 4** sintetiza os passos realizados nesse trabalho, desde a escolha do local, até a obtenção de respostas da provável posição (X,Y) do dispositivo móvel (suíno).

Com isso, diversos treinamentos da rede PMC foram realizados com 6, 9, 10, 15 e 20 neurônios na camada intermediária, com uma taxa de aprendizagem de 0.01 e precisão 1×10^{-6} . Após a operação das redes treinadas observou-se qual arquitetura apresentaria melhores resultados.

RESULTADOS E DISCUSSÃO

A **tabela I** permite comparar os desempenhos das 5 arquiteturas de rede PMC testadas. É possível observar os erros nas medidas dos oito pontos, denominados de P1 a P8. Para cada topologia de rede testada, com 6, 9, 10, 15 e 20 neurônios na camada intermediária, são apresentados os erros absolutos e relativos aos eixos X e Y. Quando são apresentados ao algoritmo de operação os oito pontos de teste, em cada um deles ocorre um erro de medida, ou seja, o ponto apontado pelo algoritmo de operação fica ligeiramente deslocado no eixo X e Y. Assim, para efeito de comparação e ajustes das topologias da rede neural foi calculada a média das distâncias X e Y de deslocamento do valor de resposta frente ao valor real, os quais são somados, formando o seu correspondente erro médio em X e Y, respectivamente. Já as colunas referentes aos erros relativos, estas foram obtidas de modo semelhante, sendo a média dos erros em relação à posição correta. Em outras palavras, a diferença entre o valor real e o obtido, foi dividida pelo valor real e, em seguida calculada a média do erro relativo em X e Y de cada ponto.

Também são apresentados os resultados do desempenho do treinamento de cada uma das topologias. É possível observar que a topologia dotada de 6 neurônios na camada intermediária realiza um treinamento mais rápido, de apenas 561 épocas. Cada época equivale a uma operação de aprendizado com os 286 dados de treinamento aplicados. Um treinamento tão rápido não permite extrair de maneira coerente as relações entre a potência do RSSI e da posição real. Isso explica o seu desempenho em localização inferior às demais topologias. Empiricamente é possível observar o melhor desempenho em operações da topologia com 10 neurônios na camada intermediária. Esse erro poderia ser ainda menor se fossem apresentados mais dados de treinamento a rede, seja através de uma distância menor que 25cm entre os pontos de treinamento, o que automaticamente geraria mais que 286 pontos, seja aplicando

mais estações físicas, o que nesse caso alteraria a camada de entrada da rede neural. São alternativas que podem gerar resultados satisfatórios, mas que fogem do escopo deste trabalho, de mostrar que é possível inferir as posições de um animal dentro do seu espaço e mapear suas diferentes localizações com eficiência.

Para ilustrar melhor o processo de rastreamento, ou seja, das diferentes posições do dispositivo móvel no seu espaço, é apresentada na **tabela II** uma comparação entre as distâncias calculadas pelo modelo neural e as suas correspondentes distâncias reais. Os dados foram organizados com o propósito de mostrar a distância entre cada ponto, partindo do ponto P1 até o P8, bem como a distância total a ser percorrida ao realizar esse itinerário. Cada linha mostra o comportamento de cada topologia de rede neural, bem como os valores reais dessas distâncias.

É possível observar que as arquiteturas com 9 e 20 neurônios na camada intermediária são as que apresentaram valores mais discrepantes nos cálculos das distâncias percorridas, quando comparadas aos valores reais de cada deslocamento. Considerando, que essas implementações são as que apresentaram maiores erros de localização no algoritmo de operação, torna-se natural entender porque os cálculos de distância realizados pelas mesmas tiveram desempenho inferior.

Além disso, a **tabela II** mostra que a arquitetura dotada de 9 neurônios foi a que chegou mais próxima das distâncias reais percorridas. No entanto, é importante lembrar de que essa implementação teve desempenho inferior às arquiteturas com 10 e 15 neurônios na camada intermediária para encontrar a posição do dispositivo móvel em cada um dos 8 pontos, como já apresentado na **tabela I**.

Esse desempenho superior ocorreu por conta de sua característica de rastreamento ter fornecido pontos que, embora com maior erro em relação ao ponto real, coincidentemente estavam à mesma distância entre si, tal qual a distância real. Em outras palavras, a arquitetura com 9 neurônios encontrou pontos com maiores erros médio e relativo, mas cuja distância em relação ao ponto anterior era numericamente próximo à distância real. Por isso, o destaque de desempenho aqui observado, não constitui fator para uma classificação superior em desempenho de monitoramento ou localização, em relação às duas últimas implementações citadas.

Diante dessas análises, tornou-se evidente que a rede neural que melhor extraiu as características dos dados de treinamento apresentado e que conseguiu realizar

Tabela I. Comparação de desempenho de treinamentos e operação para as 5 arquiteturas de rede PMC utilizadas (Training performance comparison and operation for five PMC network architectures used).

	Épocas	EQM	Precisão	Erro absoluto X	Erro absoluto Y	Erro relativo X	Erro relativo Y
6 neurônios na camada intermediária	561	0,0492	9,93E ⁻⁷	36,10	24,23	17,81%	14,07%
9 neurônios na camada intermediária	2588	0,0435	9,99E ⁻⁷	33,86	20,62	16,70%	9,93%
10 neurônios na camada intermediária	2170	0,0449	9,99E ⁻⁷	31,98	18,42	16,21%	9,14%
15 neurônios na camada intermediária	2436	0,0440	9,99E ⁻⁷	33,11	20,35	16,36%	10,07%
20 neurônios na camada intermediária	1597	0,0461	9,98E ⁻⁷	33,24	21,37	16,31%	12,13%

Tabela II. Comparação da distância real com as estimadas em cada arquitetura de rede treinada (Comparison of the actual distance with the estimated in each trained network architecture).

	P1-P2	P2-P3	P3-P4	P4-P5	P5-P6	P6-P7	P7-P8	Distância total
Deslocamento real	44,56	65,00	33,60	27,00	43,72	42,12	53,72	309,76
Deslocamento experimental 6 neurônios na camada intermediária	6,00	18,08	23,16	6,52	8,56	5,96	13,40	81,76
Deslocamento experimental 9 neurônios na camada intermediária	43,60	53,28	93,20	29,88	45,28	21,60	32,88	319,68
Deslocamento experimental 10 neurônios na camada intermediária	37,32	49,36	82,72	25,72	39,48	19,08	30,72	284,36
Deslocamento experimental 15 neurônios na camada intermediária	38,36	49,64	86,44	28,16	41,28	21,76	30,12	295,80
Deslocamento experimental 20 neurônios na camada intermediária	25,80	36,32	61,28	19,32	28,24	16,08	20,96	208,04

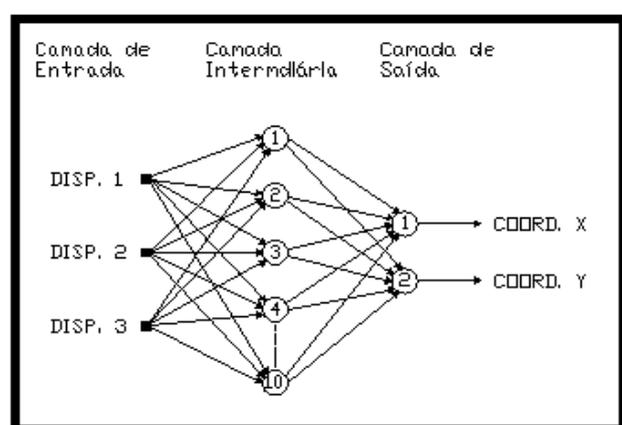


Figura 5. Topologia de Rede com 10 neurônios na camada intermediária (Network Topology with 10 neurons in the hidden layer).

a generalização com maior fidelidade foi a Perceptron Multicamadas, com 10 neurônios na camada neural intermediária, que pode ser vista na **figura 5**.

CONCLUSÃO

Quanto aos objetivos pretendidos, os resultados mostraram que a rede neural do tipo Perceptron Multicamadas apresentou-se como um algoritmo eficiente na interpretação dos dados obtidos, por meio do RSSI dos sinais de rádio utilizados na transmissão Bluetooth. A característica das redes neurais em encontrar uma relação entre dados de entrada e saída semelhante a uma função matemática, graças à sua capacidade de generalização constituiu uma ferramenta eficaz para aprender a relação entre o sinal RSSI entre o dispositivo móvel e os três dispositivos fixos e transformá-la na informação de qual a posição no eixo X e Y que possui tais características. Dessa forma, a rede neural torna-se uma alternativa a aplicação de métodos estatísticos na interpretação de dados. Além disso, os resultados obtidos abrem novas frentes de pesquisa ao permitir novos estudos que permitam melhorar o desempenho do aprendizado e operação da rede neural.

Através da tecnologia descrita, foi possível estimar a localização dos nós móveis embarcados nos suínos. A capacidade de generalização das redes neurais possibilitou a identificação da localização dos nós móveis, inclusive em posições intermediárias aos pontos escolhidos para o treinamento da rede.

Conclui-se, portanto, que a utilização da tecnologia bluetooth, associadas às redes neurais artificiais, consistem um sistema eficiente para monitoramento e rastreamento suíno em seu espaço de manejo (baía), que permitirá futuramente o estudo da movimentação animal, correlacionada ao seu comportamento, ao seu ambiente e à qualidade e produtividade animal, bem como a coleta de dados referentes à temperatura, umidade, iluminação e etc.

AGRADECIMENTOS

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio e concessão de Bolsa de Pesquisa.

BIBLIOGRAFIA

- Billo, E.A. 2003. Uma pilha de protocolos bluetooth adaptável à aplicação. 82 f. Monografia (Bacharelado em Ciência da Computação) – Universidade Federal de Santa Catarina. Florianópolis.
- Braga, A.P.; Carvalho, A. P. L.F. e Ludermin, T. B. 2000. Redes neurais artificiais: teoria e aplicações. 1º ed. Editora LTC. Rio de Janeiro. RJ.
- Empresa brasileira de pesquisa agropecuária - EMBRAPA. 2006. Boas práticas de produção de suínos. Concórdia. MG.
- Gutiérrez-Estrada, J.C.; Vasconcelos, R. e Costa, M.J. 2008. Estimating fish community diversity from environmental features in the Tagus estuary (Portugal): multiple linear regression and artificial neural network approaches. *J Appl Ichthyol*, 24:150–162.
- Haykin, S. 2001. Redes neurais: princípios e prática. 2. ed. Editora Bookman. Porto Alegre. RS.
- Kansal, A. 2002. Bluetooth Primer. Editora Red-M. Los Angeles. EUA.
- Kominakis, A.P.; Abas, Z.; Maltaris, I. e Rogdakis, E. 2002. A preliminary study of the application of artificial neural networks to prediction of milk yield in dairy sheep. *Comput Electron Agr*, 35: 35–48.
- Malthus, T.R. 1982. Ensaio sobre a população. 1º ed. Editora Abril Cultural. São Paulo.
- Miguens, A.P. 2001. Navegação: a ciência e a arte. Vol. 3. Capítulo 34. Noções sobre geração, transmissão, propagação e recepção das ondas eletromagnéticas e acústicas. https://www.mar.mil.br/dhn/dhn/quadros/livro_tres.html (05/12/2013).
- Pandorf, H.; Silva, I.J.O.; Sarnighausen, V.C.R.; Vieira, F.M.C.; Nascimento, S.T. e Guiselini, C. 2011. Use of artificial neural networks on the prediction of zootechnical indexes on gestation and farrowing stages of swines. *Rev Bras Zootecn*, 40: 676–681.
- Silva, I.N.; Spatti, D.H. e Flauzino, R.A. 2010. Redes neurais artificiais: para engenharia e ciências aplicadas. 1º ed. Editora Artliber. São Paulo. SP.
- Sevegnani, K. B.; Caror, I.W.; Pandorf, H.; Silva, I.J.O. e Moura, D.J. 2005. Zootecnia de precisão: análise de imagens no estudo do comportamento

- de frangos de corte em estresse térmico. *Revista Brasileira de Engenharia Agrícola e Ambiental*, 9: 115-119.
- ONU. 2013. Relativa à proteção dos suínos em sistema de criação intensiva, tendo em conta particularmente o bem-estar das porcas criadas em vários graus de confinamento e em grupo. http://ec.europa.eu/food/fs/aw/aw_legislation/pigs/comm_pt.pdf (28/09/2013).
- Wang, Y.; Shi, S.; Yang, Xu e Ma, A. 2010. Bluetooth indoor positioning using RSSI and least square estimation. *IEEE ICFC*. Shanghai. China.