

Estimação de posição e velocidade de um alvo com base em TDOA e FDOA em sistemas de radar passivo usando redes neurais *feedforward*

Bruno Pompeo, Daniel Nicolalde-Rodríguez, Marcello Campos, José A. Apolinário Jr. e Wallace Martins

Resumo—Nesse trabalho, o uso de redes neurais do tipo *feedforward* para estimação de posição e velocidade de alvos não cooperativos em sistemas de radar passivo é investigado. Medidas consideradas como variáveis de entrada da rede são as diferenças de tempo de chegada (TDOA, do inglês *time-difference of arrival*) e as diferenças de frequência Doppler (FDOA, do inglês *frequency-difference of arrival*) entre o sinal direto proveniente de um iluminador de oportunidade e o sinal refletido no alvo que chegam nos receptores. Em relação às entradas, os experimentos simulados utilizam somente informações de TDOA, somente informações de FDOA ou, então, as duas medidas conjuntamente. Além disso, com o intuito de determinar os parâmetros mais eficientes utilizados na rede, variam-se o número de neurônios, a quantidade de receptores e os níveis de erros associados às medidas. Finalmente, após eleger as melhores redes, os resultados são comparados a outras técnicas de estimação.

Palavras-Chave—Radar passivo, redes neurais *feedforward*, TDOA, FDOA.

Abstract—In this paper, the authors investigate the use of *feedforward* neural networks to estimate the location and velocity of non-cooperative targets in passive radar systems. Time difference of arrival (TDOA) and frequency difference of arrival (FDOA) measurements between the direct-path signals originated by an illuminator of opportunity and the target's reflected signals acquired by sensors are the possible network inputs. Concerning network inputs, simulated experiments use only TDOAs, only FDOAs, or both measurements. Furthermore, to determine efficient network parameters, the experiments vary the number of neurons, amount of receivers, and error degrees. Finally, the best network results are compared with other estimation techniques.

Keywords—passive radar, *feedforward* neural network, time difference of arrival (TDOA), frequency difference of arrival (FDOA).

I. INTRODUÇÃO

Nos últimos anos, diversos trabalhos vêm sendo desenvolvidos utilizando o conceito de radares passivos e iluminadores de oportunidade [1]. Embora os primórdios do conceito de radar passivo datem do período da Segunda Guerra Mundial [2], só recentemente, ressurgiu o interesse dos pesquisadores nesses sistemas. Isso se deve, principalmente, aos avanços tanto em *hardware* quanto em *software*. Em um ambiente com espectro eletromagnético já extremamente ocupado e devido à necessidade de sensores mais eficientes em um cenário de guerra eletrônica, o uso de radares passivos se encaixam perfeitamente seja para fins de defesa, seja para aplicações

civis. Ultimamente, para esse último, encontram-se em evidência estudos no âmbito de comunicação e sensoriamento conjunto, aproveitando sistemas de comunicação específicos para estimar a localização de alvos [3].

Radares passivos, por construção, são radares biestáticos. Com o objetivo de garantir uma melhor acurácia e precisão nos resultados de estimação - tanto de posição quanto de velocidade - utilizam-se, geralmente, redes de sensores espalhadas pelo cenário. Essas redes são compostas por um ou mais iluminadores de oportunidade (transmissores) e múltiplos receptores. Em [4], são propostos dois métodos utilizando informações de TDOA para estimar a localização de um alvo: interpolação esférica (SI, do inglês *spherical interpolation*) e intersecção esférica (SX, do inglês *spherical intersection*). Esses métodos usam soluções fechadas que não consideram as relações não lineares inerentes ao problema. Por conseguinte, são bem sensíveis a erros existentes nas medidas de TDOA, comprometendo assim, a estimação da posição dos alvos. Em [12], o algoritmo lá denominado NLCLS (do inglês, *nonlinearly constrained least squares*) considera restrições não lineares. Dessa forma, incluem-se as não linearidades presentes nas equações originais de TDOA numa tentativa de compensar erros nas medidas.

Os métodos supracitados não fornecem informações acerca do vetor velocidade do alvo. Assim, no intuito de verificar a eficiência do método proposto nesse trabalho no que tange à estimação de velocidade, comparam-se os resultados obtidos com os resultados encontrados em [13]. Como a relação entre posição, velocidade, TDOA e FDOA não é linear, o uso de redes neurais torna-se um possível candidato na estimação tanto de posição quanto de velocidade [6].

Redes neurais artificiais (ANNs, do inglês *artificial neural networks*) são modelos computacionais inspirados no sistema nervoso de seres vivos e vêm sendo usadas há décadas na resolução de diversos problemas. A partir da década de 1990, houve um aumento significativo no seu uso (devido ao aumento na capacidade computacional) [7]. Uma vez que possuem alta capacidade de aprendizado são geralmente utilizadas na resolução de problemas não lineares e no reconhecimento de padrões. Dessa forma, propõem-se utilizá-las também em estimação de posição e velocidade de alvos.

Os autores em [8] propõem o uso de redes neurais para estimar a localização de um alvo usando medidas de TDOA. Este trabalho estende o uso de redes neurais para estimar tanto a posição de um alvo quanto seu vetor velocidade explorando medidas de TDOA e FDOA. Para tal, geram-se três tipos de implementação, com quatro redes neurais diferentes: uma única rede neural utilizando informações de TDOA e FDOA para estimar a posição; uma única rede neural utilizando informações de TDOA e FDOA para estimar posição e velocidade;

B. S. Pompeo, D. P. Nicolalde-Rodríguez e M. L. R. Campos PEE/COPPE, Universidade Federal de Rio de Janeiro, Rio de Janeiro, RJ, Brasil, E-mails: pompeo@coppe.ufrj.br, danielnicolalde@gmail.com e campos@coppe.ufrj.br, J. A. Apolinário Jr., Programa de Pós-graduação em Engenharia Elétrica, Instituto Militar de Engenharia, Rio de Janeiro, RJ, Brasil, E-mail: apolin@ime.eb.br e W. A. Martins, Interdisciplinary Centre for Security Reliability and Trust (SnT), University of Luxembourg (UniLu), Luxembourg, E-mail: wallace.alvesmartins@uni.lu

e duas redes separadas, uma utilizando informações de TDOA para estimar posição e outra para estimar velocidade a partir de informações de FDOA. Comparam-se os resultados obtidos entre si e com os encontrados em [8] e [13].

O trabalho está dividido em quatro seções acrescidas dessa Introdução. Na Seção II, a estrutura de sistemas de radar passivo do tipo MIMO (do inglês, *multiple-input and multiple-output*) é indicada, assim como as equações que relacionam FDOA e TDOA com posição e velocidade do alvo. Na Seção III, uma breve explicação sobre o funcionamento e o processamento de uma rede neural *feedforward* é dada, juntamente com o modelo das redes implementadas no trabalho. As simulações realizadas e os resultados encontrados são discutidos na Seção IV. Por fim, na Seção V são destacadas as conclusões.

II. SISTEMAS DE RADAR PASSIVO

Sistemas de radar passivo utilizam sinais provenientes de transmissores já existentes no cenário, esses também chamados de iluminadores de oportunidade. Dentre os parâmetros que mais influenciam a escolha do transmissor para servir a um sistema de radar passivo, destacam-se a densidade de potência no alvo, a natureza da forma de onda transmitida e a cobertura do sinal [5]. Em geral, sistemas de radar passivo são multiestáticos, ou seja, são compostos por Nt transmissores (TXs) e Nr receptores (RXs). A diversidade espacial, embora dificulte o processamento e a integração dos resultados obtidos, colabora para um melhor desempenho em termos de detecção, estimativa de parâmetros cinemáticos, rastreamento e identificação de alvos quando comparado a sistemas biestáticos com um único par TX-RX [9]. A Fig. 1 exemplifica como é a operação de sistemas dessa natureza com um único TX e Nr RXs no terreno. Na figura, as linhas mais grossas indicam o sinal recebido em visada direta, enquanto as linhas mais finas indicam o sinal proveniente da reflexão no alvo de interesse.

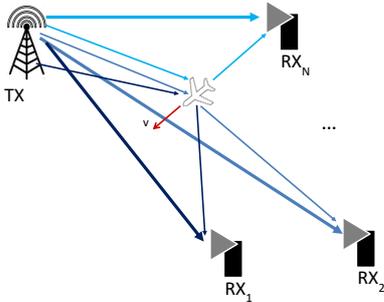


Fig. 1: Sistema de radar passivo com sensores distribuídos utilizando um único iluminador de oportunidade.

Definem-se $\mathbf{p}_{\text{TX}}^{(i)} = [x_{\text{TX}}^{(i)} \ y_{\text{TX}}^{(i)} \ z_{\text{TX}}^{(i)}]^T$ o vetor posição do TX i , $i \in \{1, \dots, Nt\}$, $\mathbf{p}_{\text{RX}}^{(j)} = [x_{\text{RX}}^{(j)} \ y_{\text{RX}}^{(j)} \ z_{\text{RX}}^{(j)}]^T$ o vetor posição do RX j , $j \in \{1, \dots, Nr\}$, $\mathbf{p}_T = [x \ y \ z]^T$ o vetor posição do alvo de interesse e $\mathbf{v} = [v_x \ v_y \ v_z]^T$ o vetor velocidade do alvo. É fácil mostrar que a TDOA (τ_{ij}), referente ao sinal direto e ao sinal refletido no alvo é dada pela Eq (1), com c igual à velocidade da luz no meio.

$$\tau_{ij} = \frac{1}{c} \left(R_{\text{TX-alvo}}^{(i)} + R_{\text{alvo-RX}}^{(j)} - R_b^{(ij)} \right) \quad (1)$$

onde $R_{\text{TX-alvo}}^{(i)}$ é a distância entre o TX i e o alvo, $R_{\text{alvo-RX}}^{(j)}$ é a distância entre o alvo e o RX j e $R_b^{(ij)}$ é a distância entre o TX i e o RX j , chamada de *baseline*.

O deslocamento Doppler é dado pela razão entre a taxa de variação do caminho percorrido pelo sinal refletido no alvo e o comprimento de onda do sinal (λ), conforme a Eq (2). Note que a taxa de variação consiste da soma entre a taxa de variação da distância entre TX e alvo mais a taxa de variação da distância entre alvo e RX [4]. Como neste trabalho considera-se somente o alvo se movendo (TXs e RXs estacionários), o deslocamento Doppler é única e exclusivamente devido ao movimento do alvo e às posições dos pares TX-RX. A FDOA de cada par TX i -RX j (f_{ij}) é dada pela diferença entre a frequência recebida no sinal refletido e a frequência recebida na visada direta entre TX e RX:

$$\begin{aligned} f_{ij} &= -\frac{1}{\lambda} \left(\frac{\partial R_{\text{TX-alvo}}^{(i)}}{\partial t} + \frac{\partial R_{\text{alvo-RX}}^{(j)}}{\partial t} \right) \\ &= -\frac{1}{\lambda} \left(\frac{(x-x_{\text{TX}}^{(i)})v_x + (y-y_{\text{TX}}^{(i)})v_y + (z-z_{\text{TX}}^{(i)})v_z}{R_{\text{TX-alvo}}} \right. \\ &\quad \left. + \frac{(x-x_{\text{RX}}^{(j)})v_x + (y-y_{\text{RX}}^{(j)})v_y + (z-z_{\text{RX}}^{(j)})v_z}{R_{\text{alvo-RX}}} \right). \quad (2) \end{aligned}$$

Note que a relação entre (x, y, z) e (v_x, v_y, v_z) com os outros parâmetros não é linear.

III. MODELO DA REDE NEURAL

As redes neurais utilizadas nesse trabalho são do tipo *feedforward*, com duas camadas de neurônios, sendo a camada oculta com função de ativação tangente hiperbólica e a camada de saída com função de ativação linear. Para avaliar o desempenho da rede e escolher a de melhor custo-benefício, varia-se o número de neurônios na camada oculta $L \in \{5, \dots, 40\}$. A quantidade de saídas, $M \in \{2, 4\}$, pode ser somente vetor posição ou vetores posição e velocidade.

O vetor de entrada do sistema, $\mathbf{r}_{\text{in}} = [r_1 \dots r_K]^T$, é dado pelas TDOAs e/ou FDOAs referentes ao cenário considerado. Para entrada na rede neural, utiliza-se o vetor $\mathbf{r}'_{\text{in}} = [r'_1 \dots r'_K]^T$, dado pelos componentes de \mathbf{r}_{in} normalizados entre $[-1, 1]$. Já o vetor de saída do sistema, $\mathbf{s}_{\text{out}} = [s_1 \dots s_M]^T$, é dado pelas posições e/ou velocidades dos alvos considerados. A saída da rede neural fornece o vetor $\mathbf{s}'_{\text{out}} = [s'_1 \dots s'_M]^T$, que contém os componentes do vetor \mathbf{s}_{out} normalizados entre $[-1, 1]$. O processo de escalonamento se faz necessário para que as operações da rede neural atuem de maneira correta e limitada ao intervalo $[-1, 1]$. A Fig. 2 mostra os vetores de entrada e de saída da rede neural e as duas camadas da rede.

No treinamento da rede neural comumente utiliza-se o erro quadrático médio da saída estimada da rede como critério de desempenho, tendo como referência os valores cinemáticos teóricos do alvo: $F_0 = \frac{1}{Q} \sum_{q=1}^Q \epsilon_q^2$, onde $\epsilon_q^2 = \|\mathbf{s}'_{\text{out}}{}^{(q)} - \hat{\mathbf{s}}'_{\text{out}}{}^{(q)}\|^2$ representa a norma quadrática da diferença entre $\mathbf{s}'_{\text{out}}{}^{(q)}$ (teórico) e $\hat{\mathbf{s}}'_{\text{out}}{}^{(q)}$ (estimado) para o q -ésimo par de vetores (entrada-saída); Q representa o número total de vetores de saída considerados no treinamento da rede. Existem algoritmos de otimização pré-definidos para treinamento da rede [11]. Um algoritmo comumente utilizado é o de Levenberg-Marquadt e foi o algoritmo escolhido para ser usado neste trabalho. Os pares de vetores entrada-saída foram divididos em três grupos não igualmente divididos: treinamento, validação e teste.

IV. SIMULAÇÕES E RESULTADOS ENCONTRADOS

A. Definição do cenário

O cenário utilizado nas simulações consiste, a princípio e sem perda de generalidade, em um ambiente 2-D, composto

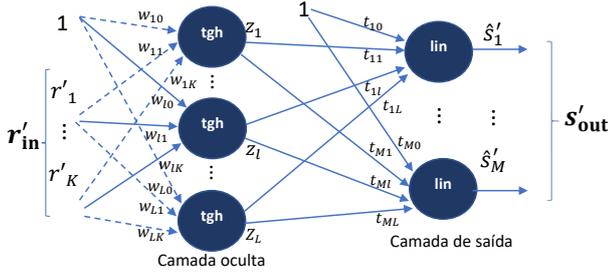


Fig. 2: Modelo da rede neural para estimar a localização e/ou velocidade de um alvo.

por um TX fixo em (7,0) km e $Nr \in \{4, 6, 10, 15\}$ RXs localizados em uma área de 10 km \times 10 km, centrada em (0,0), sendo seus posicionamentos escolhidos de forma aleatória, dentro de regiões angulares separadas por $\Delta\theta = \frac{2\pi}{Nr+1}$ radianos, começando em $\theta = \frac{\pi}{Nr+1}$ radianos, conforme criado em [8]. Os alvos foram escolhidos com posição e velocidade aleatórias, também em 2-D, distribuídas de maneira uniforme entre (-10,-10) km a (10,10) km e (-200,-200) m/s a (200,200) m/s respectivamente.

Conforme implementado em [13], para uma comparação justa, em seguida, houve a necessidade de se criar um cenário com um TX e oito RXs, em um ambiente 3-D.

B. Dimensionamento das redes neurais

Com base nos resultados já encontrados em [8], utilizam-se 5000 pares entrada-saída - com posições e velocidades aleatórias do alvo - nas simulações citadas na Subseção IV-A. Esses dados são divididos em: 2500 pares usados para treinamento, 1250 pares usados para validação e 1250 pares usados para teste. A fim de otimizar a quantidade de neurônios utilizados nas redes, ou seja, otimizar o custo computacional e tempo de execução, foram feitos experimentos exaustivos considerando diferentes números de RXs e diferentes números de neurônios na camada oculta. Para testar a robustez das redes, já que nas técnicas indicadas em [4] o resultado é sensível a erros de medidas de TDOAs, adicionam-se ao valor nominal de TDOA erros gaussianos com desvio padrão de $\sigma \in \{0, 1, 2, 3, 4, 5\}\%$ da TDOA. Este mesmo procedimento é utilizado nas medidas de FDOA.

C. Simulações

Para avaliar os desempenhos fornecidos pelas redes neurais para o problema descrito, foram feitas simulações em quatro construções de redes diferentes, conforme apresentado na Tabela I, além de compará-las com os resultados obtidos em [8]. Para tal, avaliamos cada rede particular com erro médio total da posição, em que $\bar{E}_p = \frac{1}{P_r} \sum_{q=1}^{P_r} \gamma^{(q)}$, sendo $\gamma^{(q)} = \|\mathbf{p}_T^{(q)} - \hat{\mathbf{p}}_T^{(q)}\|$ a norma da distância entre a posição teórica do alvo $\mathbf{p}_T^{(q)}$ e a estimada $\hat{\mathbf{p}}_T^{(q)}$, em metros, para o q -ésimo par, $q \in \{1, \dots, P_r\}$. Também faz-se a avaliação com erro médio total da velocidade, em que $\bar{E}_v = \frac{1}{P_r} \sum_{q=1}^{P_r} \beta^{(q)}$, sendo $\beta^{(q)} = \|\mathbf{v}_T^{(q)} - \hat{\mathbf{v}}_T^{(q)}\|$ a norma da distância entre a velocidade do alvo teórica $\mathbf{v}_T^{(q)}$ e a estimada $\hat{\mathbf{v}}_T^{(q)}$, em metros por segundos, para o q -ésimo par.

- 1) Simulação 1 - Rede NET : Uma rede com as entradas sendo informações de TDOAs e FDOAs e saídas os vetores posição e velocidade $\hat{\mathbf{s}}_{out} = [\hat{\mathbf{p}}_T \ \hat{\mathbf{v}}_T]^T$;

TABELA I: Entradas e saídas das redes neurais

Redes	Entradas da Rede		Saídas da Rede	
	TDOAs	FDOAs	Posição do alvo	Velocidade do alvo
NET	X	X	X	X
NET _p	X		X	
NET _{p1}	X	X	X	
NET _v		X		X
NET _{v1}	X	X		X

TABELA II: Desempenho das redes neurais para posição

Redes	Nr RXs	K neurônios	σ
NET _p	4	≥ 20	$\leq 2\%$
NET	4	≥ 25	$\leq 1\%$
NET _{p1}	4	≥ 25	$\leq 2\%$
NET _p	6	≥ 15	$\leq 3\%$
NET	6	≥ 25	$\leq 2\%$
NET _{p1}	6	≥ 15	$\leq 3\%$
NET _p	10	≥ 15	$\leq 5\%$
NET	10	≥ 35	$\leq 4\%$
NET _{p1}	10	≥ 25	$\leq 5\%$
NET _p	15	≥ 10	$\leq 5\%$
NET	15	≥ 25	$\leq 4\%$
NET _{p1}	15	≥ 10	$\leq 5\%$

- 2) Simulação 2 - Rede NET_p* e Rede NET_v: Duas redes separadas, sendo a rede NET_p com as informações de TDOA na entrada e vetor posição na saída e a rede NET_v com as informações de FDOA na entrada e vetor velocidade na saída;
- 3) Simulação 3 - Rede NET_{p1}: Uma rede com as entradas sendo informações de TDOAs e FDOAs e saída somente o vetor posição;
- 4) Simulação 4 - Rede NET_{v1}: Uma rede com as entradas sendo informações de TDOAs e FDOAs e saída somente o vetor velocidade;

Nesses experimentos, as posições dos RXs e do TX, considerando que são fixas e conhecidas, não formam parte da entrada da rede neural para não aumentar a complexidade da rede.

D. Resultados

A Fig. 3 apresenta as curvas de \bar{E}_p considerando σ variando entre 0% e 5%, o número de neurônios na camada oculta variando de 5 a 40 e cenários com $Nr = 4, 6, 10$ ou 15 RXs, referentes às simulações 1, 2 (para posição) e 3. Note que a inclusão das informações de FDOAs como parâmetro de entrada não favorecem o resultado quando o interesse é somente a posição dos alvos. Desta forma, a rede NET_p possui o melhor desempenho quando comparada às redes NET e NET_{p1}. De fato, a rede NET_{p1} tenta minimizar a influência das entradas FDOAs, visto que somente as informações de TDOAs são suficientes para estimar as posições dos alvos.

A Tabela II indica o número de RXs, neurônios na camada oculta e valores de σ que garantem um erro de estimação de até 1% na posição, ou seja, $\bar{E}_p \leq 200$ m, conforme estabelecido em [8]. Note que, em geral, a rede com melhor resultado para estimação de posição é a rede NET_p. Essa mesma rede foi proposta em [8] e de igual maneira mostrou ser resistente aos diferentes graus de erros nas medidas, superando os resultados encontrados utilizando os algoritmos SI, SX e NLCLS. Vale ressaltar, que a rede NET_{p1} fornece resultados similares, porém como usa mais dados de entrada necessita de maior custo computacional e maior tempo de execução.

*Essa rede já foi analisada em [8].

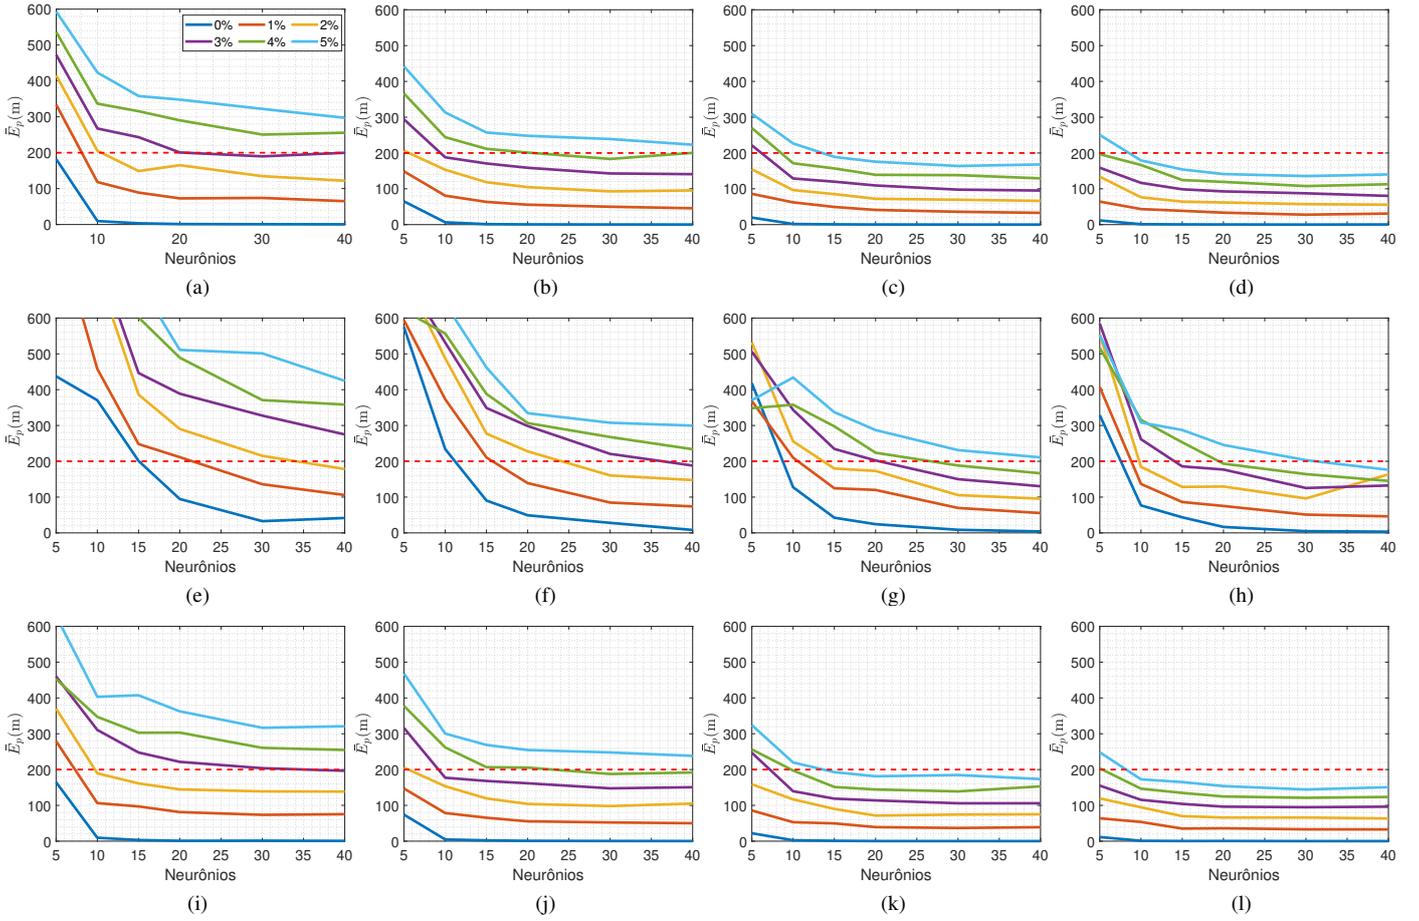


Fig. 3: Erro médio total da posição do alvo. Cada curva está associada a um nível de ruído. Rede NET_p com (a) $N_r = 4$ RXs, (b) $N_r = 6$ RXs, (c) $N_r = 10$ RXs, e (d) $N_r = 15$ RXs. Rede NET com (e) $N_r = 4$ RXs, (f) $N_r = 6$ RXs, (g) $N_r = 10$ RXs, e (h) $N_r = 15$ RXs. Rede NET_{p1} com (i) $N_r = 4$ RXs, (j) $N_r = 6$ RXs, (k) $N_r = 10$ RXs e (l) $N_r = 15$ RXs.

TABELA III: Desempenho das redes neurais para velocidade

Redes	N_r RXs	K neurônios	σ
NET_v	4	-	-
NET	4	≥ 40	$\leq 1\%$
NET_{v1}	4	≥ 40	$\leq 1\%$
NET_v	6	-	-
NET	6	≥ 25	$\leq 1\%$
NET_{v1}	6	≥ 25	$\leq 1\%$
NET_v	10	-	-
NET	10	≥ 25	$\leq 2\%$
NET_{v1}	10	≥ 40	$\leq 3\%$
NET_v	15	-	-
NET	15	≥ 30	$\leq 3\%$
NET_{v1}	15	≥ 25	$\leq 3\%$

A Fig. 4 apresenta as curvas de \bar{E}_v considerando σ variando entre 0% e 5%, o número de neurônios na camada oculta variando de 5 a 40 e cenários com $N_r = 4, 6, 10$ ou 15 RXs, referentes às simulações 1, 2 (para velocidade) e 4. A Tabela III indica o número de RXs, neurônios na camada oculta e valores de σ que garantem $\bar{E}_v \leq 4$ m/s, considerando 1% de erro máximo na estimação das velocidades.

Note que, em geral, a rede com melhor resultado, neste caso, é a rede NET_{v1} . Verifica-se também que a rede NET fornece resultados similares. Isso se dá ao fato de ambas as redes utilizarem, além das informações de FDOA, também, as informações de TDOA para computar a velocidade. No entanto, pelo fato das saídas da rede NET serem velocidade e posição, há uma maior sobrecarga no processamento da

rede neural, causando um resultado ligeiramente abaixo do fornecido pela rede NET_{v1} .

Utilizando a rede NET_{v1} , a Fig. 5 indica os resultados encontrados referentes ao erro quadrático médio (RMSE) da velocidade de um alvo na posição (1000, 1500, 3000) m, com velocidade (120, 150, 100) m/s, sendo (3000, 1000, 0) a posição do TX e (0, 5000, 0), (5000, 0, 1000), (-5000, 0, 1500), (0, -5000, 1000), (0, 0, 1000), (0, 1000, 1000), (0, -2000, 0) e (-5000, 2000, 0) as posições dos RXs, em metros. Esses pontos são os mesmos utilizados em [13]. O RMSE foi obtido após 5000 execuções da rede, com erro gaussiano de média nula e variâncias diversas (σ^2), conforme mostrado na Fig. 5, associado tanto à TDOA ($\frac{\sigma^2}{c^2}$) quanto à FDOA ($10^{-5}\sigma^2$). Esses 5000 pares foram gerados a partir de posições e velocidades com distribuições uniformes limitadas em (-5000, -5000, 0) m a (5000, 5000, 3000) m e (-200, -200, -200) m/s a (200, 200, 200) m/s, respectivamente. Os valores encontrados com 60 neurônios são similares aos encontrados em [13].

V. CONCLUSÕES

Nesse trabalho foram implementadas redes neurais *feed-forward* de duas camadas para estimar a posição e a velocidade de um alvo considerando um sistema de radares passivos. Para isso, utilizou-se como entradas as medidas de TDOA e/ou FDOA entre o sinal direto (TX-RX) e o sinal refletido no alvo (TX-alvo-RX) adquiridos nos RXs distribuídos.

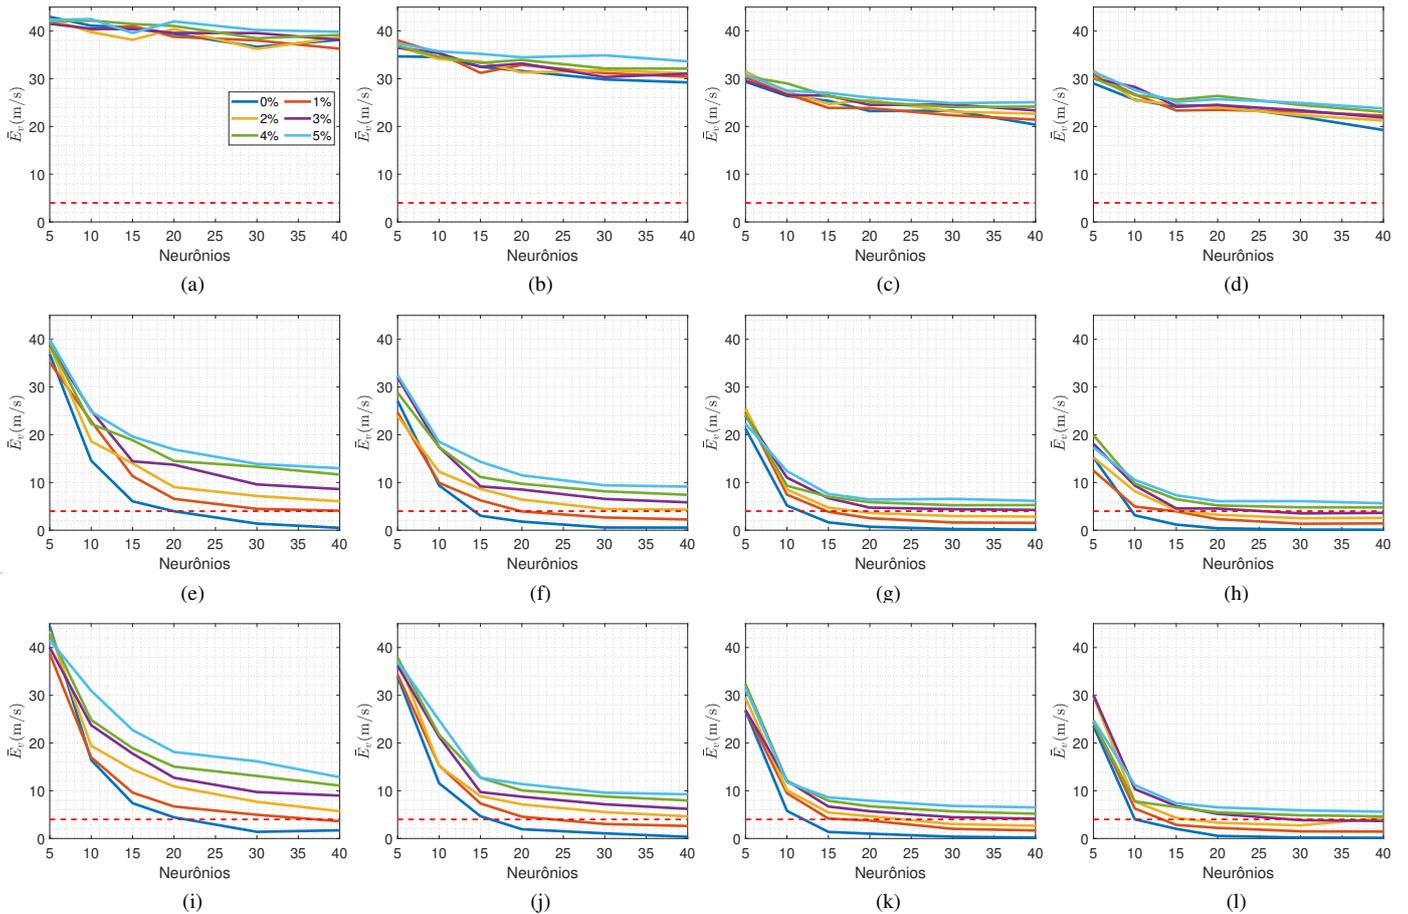


Fig. 4: Erro médio total da velocidade do alvo. Cada curva está associada a um nível de ruído. Rede NET_v com (a) $Nr = 4$ RXs, (b) $Nr = 6$ RXs, (c) $Nr = 10$ RXs, e (d) $Nr = 15$ RXs. Rede NET com (e) $Nr = 4$ RXs, (f) $Nr = 6$ RXs, (g) $Nr = 10$ RXs, e (h) $Nr = 15$ RXs. Rede NET_{v1} com (i) $Nr = 4$ RXs, (j) $Nr = 6$ RXs, (k) $Nr = 10$ RXs e (l) $Nr = 15$ RXs.

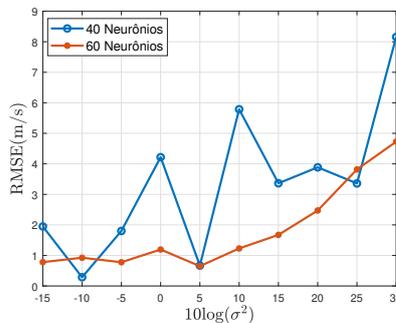


Fig. 5: RMSE associado à velocidade do alvo em (1000, 1500, 3000) m considerando 40 e 60 neurônios na camada oculta da rede.

O uso das redes neurais mostrou-se eficiente ao resolver as equações não lineares oriundas de TDOA e FDOA considerando erros associados às medidas. As comparações feitas entre as redes e as soluções fechadas existentes na literatura comprovam a eficiência em usar redes neurais para esse fim.

Os resultados indicam que para estimar a posição do alvo a rede cujas entradas foram somente as informações de TDOAs proporcionou o melhor resultado. Já para estimar a velocidade do alvo, a rede cujas entradas foram as informações de TDOAs e FDOAs propiciou o melhor resultado.

REFERÊNCIAS

- [1] Griffiths, Hugh D.; Baker, Christopher. *An introduction to passive radar*. Artech House, 2017.
- [2] Kuschel, Heiner; Cristallini, Diego; OLSEN, Karl Erik. *Tutorial: Passive radar tutorial*. IEEE Aerospace and Electronic Systems Magazine, v. 34, n. 2, p. 2-19, 2019.
- [3] Thomä, Reiner, et al. *Joint communication and radar sensing: An overview*. 2021 15th IEEE European Conference on Antennas and Propagation (EuCAP). IEEE, 2021. p. 1-5.
- [4] Malanowski, Mateusz. *Signal Processing for Passive Bistatic Radar*. Artech House, 2019.
- [5] Kuschel, Heiner. *Passive Coherent Locator History and Fundamentals*. STO-EN-SET-243-01 Educational Notes Paper, 2017.
- [6] Pak, Sean; Chalise, Batu K.; Himed, Braham. *Target localization in multi-static passive radar systems with artificial neural networks*. In: 2019 International Radar Conference (RADAR). IEEE, 2019. p. 1-5.
- [7] da Silva, Ivan; Spatti, Danilo; Flauzino, Rogério. *Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas: Fundamentos Teóricos e Aspectos Práticos*. Artliber Ed, 2016.
- [8] Nicolalde-Rodríguez, Daniel; Martins, Wallace; Apolinário Jr, José; Calôba, Luiz. *Localização coerente passiva de um alvo usando redes neurais feedforward*. Simpósio Brasileiro de Telecomunicações, 2021.
- [9] Lei, Peng-zheng; Huang, Xiao-tao. *Multistatic radar analysis based on ambiguity function and Cramér-Rao lower bounds*. Journal of Central South University, v. 21, n. 8, p. 3092-3097, 2014.
- [10] Smith, Julius; Abel, Jonathan. *Closed-form least-squares source location estimation from range-difference measurements*. IEEE Transactions on Acoustics, Speech, and Signal Processing, v. 35, n. 12, p. 1661-1669, 1987.
- [11] S. Haykin. *Neural Networks and Learning Machines*. Pearson – Prentice Hall, 3rd edition, 2008.
- [12] Nicolalde-Rodríguez, Daniel P; Apolinário Jr. José; Martins, Wallace. *Robust passive coherent location via nonlinearly constrained least squares*. 12th IEEE Latin American Symposium on Circuits & Systems (LASCAS), Arequipa, Peru, Feb. 2021, pp. 1-4.
- [13] Yang, Lijuan et al. *Joint position and velocity estimation of a moving target in multistatic radar by bistatic range, TDOA, and Doppler shifts*. 2019 International Journal of Antennas and Propagation.