

APLICAÇÃO DE REDES NEURAIS NO MOVIMENTO DE UM ROBÔ BÍPEDE

Max Suell Dutra

Armando Carlos de Pina Filho

Taltibio Araujo Ezequiel

Universidade Federal do Rio de Janeiro, Departamento de Engenharia Mecânica, Centro de Tecnologia, COPPE/PEM, C.P. 68503 - CEP. 21945-970, Rio de Janeiro, RJ, Brasil. E-mails: max@serv.com.ufrj.br, pina-filho@mailbr.com.br.

Resumo

A locomoção de seres humanos e animais, como a caminhada e a corrida, é desenvolvida através de movimentos rítmicos e sincronizados. Admitindo-se o ângulo formado pelas pernas quando realizamos um passo (chamado aqui de ângulo da bacia) como o principal parâmetro responsável pelo posicionamento da perna, o objetivo deste trabalho é determinar seu comportamento utilizando uma rede neural, de maneira a minimizar o tempo de cálculo para envio do sinal de posição. Através do emprego de uma rede neural, pode-se garantir que esse cálculo será realizado em “tempo real”, a partir do comprimento do passo desejado.

Palavras-chave: *Backpropagation*, Bípede, Controle, Rede Neural.

1. INTRODUÇÃO

Quando realizamos o movimento das pernas numa caminhada, um grande número de graus de liberdade está envolvido, tornando-se essencial uma boa coordenação entre eles. A maior parte dessa coordenação é realizada pelo sistema nervoso central, gerando sinais de acordo com o passo desejado. O processo de geração de sinais pode ser modelado por um gerador de padrões, sendo projetado como uma rede de osciladores não lineares mutuamente acoplados.

Uma outra maneira de gerar esses sinais é através de uma rede neural artificial, a qual consiste de elementos computacionais simples (neurônios), organizados em camadas e funcionando em paralelo. A rede neural tem habilidade para “aprender” relações complicadas de não-linearidades e tem sido amplamente utilizada na modelagem de sistemas complexos, proporcionando o controle de sistemas altamente não-lineares através do método clássico de *Backpropagation* (Wasserman, 1989).

Um dos maiores problemas (talvez o maior) para a elaboração de uma máquina para locomoção bípede é o controle, este sendo responsável pelo movimento, estabilidade da máquina e manutenção de certos requisitos adicionais, como por exemplo, baixo consumo de energia. Essas atividades dividem-se em tarefas como:

- controle simultâneo de atuadores;
- cálculo da trajetória das pernas e coordenação entre elas;
- posicionamento final dos pés;
- e adaptação global do movimento ao ambiente.

Todas essas tarefas precisam ser conduzidas em tempo real, sendo a rede neural a alternativa mais promissora ao controle tradicional, pois proporciona o aprendizado e tem alta adaptabilidade. A arquitetura de controle é compilada através do treinamento de uma rede neural em *Backpropagation*, modelagem também adotada por Lopes Júnior *et al.* (1999).

2. FATORES DETERMINANTES DO PASSO DE UM BÍPEDE

O movimento natural de um bípede envolve mais de 200 graus de liberdade, tornando-se a sua modelagem mais viável através da redução do número de graus de liberdade, analisando-se aqueles que serão os mais importantes para a determinação do passo, a saber: o compasso, que se apresenta com as pernas esticadas, como num pêndulo invertido; a rotação pélvica sobre o eixo vertical; a flexão do joelho; a flexão da planta do pé; o movimento lateral da pélvis; e a inclinação da pélvis (Saunders *et al.*, 1953).

Para uma melhor percepção desses fatores determinantes do passo, um modelo tridimensional com 15 graus de liberdade é necessário; entretanto, de maneira a simplificar o estudo técnico, admite-se adotar um modelo bidimensional (Dutra, 1995), que desempenha seu movimento em um plano, com 3 determinantes do passo (Figura 1).

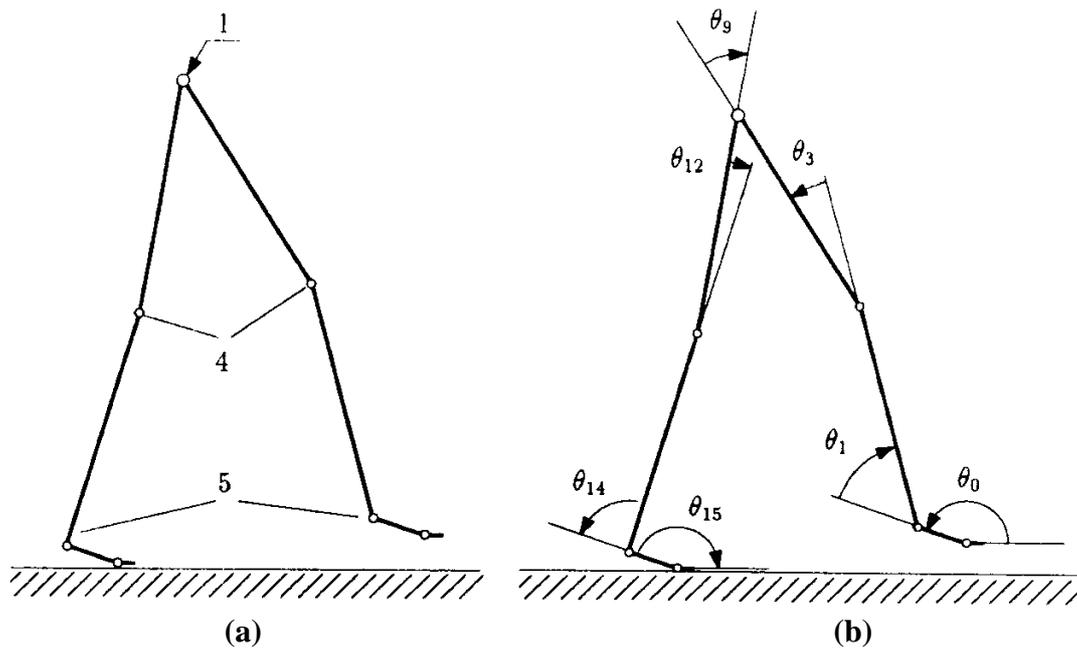


Figura 1. Modelo bidimensional de um robô bípede. (a) Determinantes principais do modo de andar: compasso (1), flexão do joelho (4) e flexão da planta do pé (5); (b) ângulos necessários para a descrição do movimento.

Uma vez que a locomoção de um bípede exige um movimento sincronizado, é necessário que o gerador de padrões proporcione ao sistema as referências adequadas para o movimento dos *links* (articulações). No presente estudo, o gerador de padrões fornece ao sistema de locomoção sinais de referência angular (θ_9) através de uma rede neural em *Backpropagation*.

3. TRABALHO EXPERIMENTAL E RESULTADOS

Estudos do movimento humano, bem como a análise de Fourier (Braune, 1987), levam aos resultados apresentados na Figura 2 para θ_1 , θ_3 , θ_9 , θ_{12} , e θ_{14} . A síntese desses dados mostra que o movimento dos ângulos dos joelhos θ_3 e θ_{12} , bem como o ângulo θ_9 , podem ser descritos com grande precisão por seu harmônico fundamental, estando o bípede nas fases de suporte duplo ou simples (Figura 3).

As funções harmônicas têm as seguintes formas:

$$\theta_3 = \theta_{30} + \hat{\theta}_3 \cos 2\omega t \quad (1)$$

$$\theta_9 = \theta_{90} + \hat{\theta}_9 \cos (\omega t - \alpha_9) \quad (2)$$

$$\theta_{12} = \theta_{120} + \hat{\theta}_{12} \cos 2\omega t \quad (3)$$

onde: θ_{30} , θ_{90} , e θ_{120} se referem aos valores iniciais dos ângulos; $\hat{\theta}_3$, $\hat{\theta}_9$, e $\hat{\theta}_{12}$ se referem às amplitudes; ω é a velocidade angular; t é o tempo; e α_9 corresponde ao ângulo de defasagem para determinação de θ_9 .

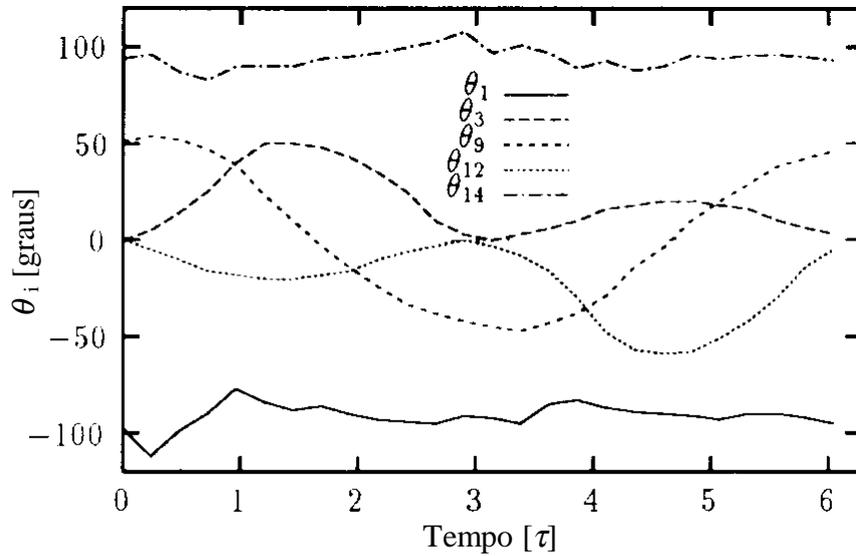


Figura 2. Comportamento dos ângulos das pernas em função do tempo.

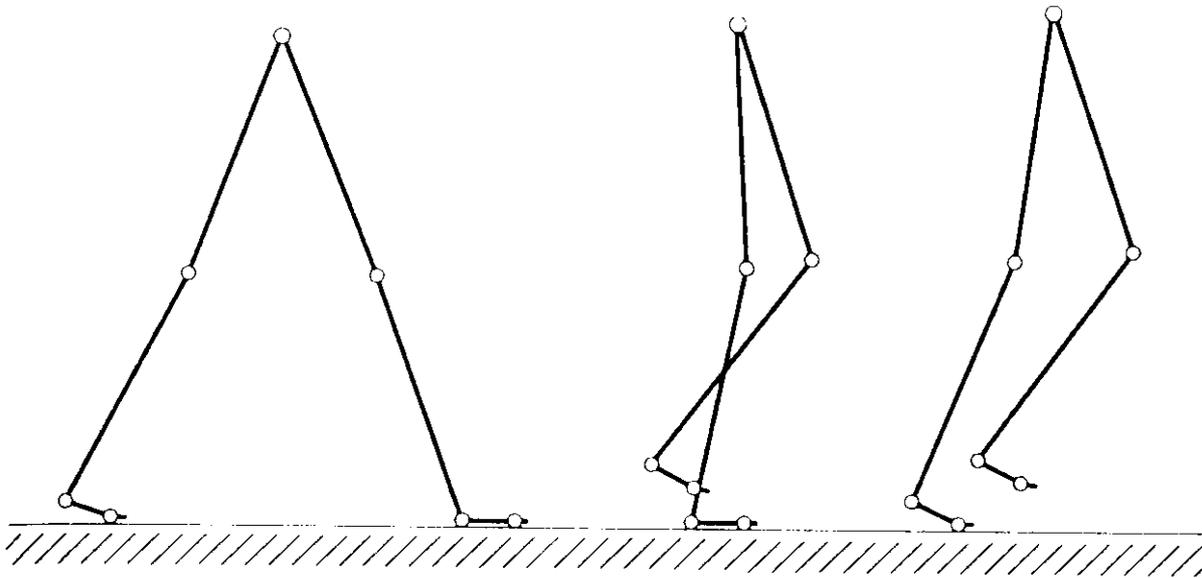


Figura 3. Movimentação das pernas, mostrando as fases de suporte duplo e simples.

A equação para geração dos comprimentos do passo é a seguinte (Dutra, 1995):

$$S = l_f (1 + \cos \theta_0) + l_u \cos (\theta_0 + \theta_1) + l_o \cos (\theta_0 + \theta_1 + \theta_3) - l_o \cos (\theta_0 + \theta_1 + \theta_3 + \theta_9) - l_u \cos (\theta_0 + \theta_1 + \theta_3 + \theta_9 + \theta_{12}) \quad (4)$$

onde: l_f é o comprimento do pé; l_u é o comprimento da tíbia; e l_o é o comprimento do fêmur.

No entanto, como o interesse é especificar o ângulo θ_9 a partir de um comprimento do passo desejado, deve-se encontrar a expressão de θ_9 em função do passo. Usando a expressão anterior e fazendo as devidas manipulações algébricas, chega-se ao seguinte resultado:

$$\theta_9 = \arccos \left[\frac{B + \sqrt{B^2 - 4AC}}{2A} \right] \quad (5)$$

onde: $A = (\ell_o \cos x + \ell_u \cos y)^2 + (\ell_o \sin x + \ell_u \sin y)^2$;

$B = 2z (\ell_o \cos x + \ell_u \cos y)$;

$C = z^2 - (\ell_o \sin x + \ell_u \sin y)^2$;

$x = \theta_0 + \theta_1 + \theta_3$;

$y = \theta_0 + \theta_1 + \theta_3 + \theta_{12}$;

$z = -s + \ell_f (1 + \cos \theta_0) + \ell_u \cos(\theta_0 + \theta_1) + \ell_o \cos(\theta_0 + \theta_1 + \theta_3)$.

Segundo medidas experimentais, tem-se normalmente durante uma caminhada: $\theta_0 = 170^\circ$, $\theta_1 = -95^\circ$, $\theta_3 = 3^\circ$ e $\theta_{12} = -3^\circ$, que são, respectivamente, o ângulo da planta do pé com o solo, o ângulo entre a articulação inferior da perna (tornozelo) e a parte posterior do pé, e os ângulos referentes à flexão dos joelhos. Além disso, pode-se adotar as seguintes medidas para os comprimentos: $\ell_f = 0,11$ m, $\ell_u = 0,37$ m e $\ell_o = 0,37$ m. Com estas medidas pode-se então configurar a rede para gerar os resultados desejados.

A rede foi configurada para treinamento com os seguintes parâmetros:

- comprimento mínimo do passo: 0,165 m;
- comprimento máximo do passo: 0,715 m;
- camada intermediária com 5 neurônios do tipo sigmóide;
- camada de saída com 1 neurônio do tipo linear;
- função utilizada: *Levenberg-Marquardt backpropagation*;
- número máximo de épocas para treino: 1000;
- erro médio quadrático (MSE): 1×10^{-5} .

Após o processo de treinamento, verifica-se a capacidade de generalização da rede, escolhendo-se diferentes valores de passo e especificando-se θ_9 (fase de simulação da rede). Em conjunção com a simulação da rede realiza-se o cálculo teórico de θ_9 com o objetivo de comparar os resultados e avaliar o erro percentual dos valores fornecidos pela rede.

A rede neural foi programada no software MATLAB utilizando as seguintes funções (já existentes no próprio programa):

- NEWFF: cria uma rede do tipo “*feed-forward backpropagation*”;
- TRAINLM: usa a otimização de Levenberg-Marquardt para o treinamento;
- TANSIG: especifica o(s) neurônio(s) do tipo sigmóide;
- PURELIN: especifica o(s) neurônio(s) do tipo linear;
- TRAIN: efetua o treinamento da rede;
- SIM: efetua a simulação da rede.

Executando o programa pode-se observar então os resultados encontrados por meio dos gráficos apresentados pelo próprio programa (Figuras 4, 5, 6, e 7), possibilitando uma avaliação do desempenho da rede.

Além dos gráficos, com os valores fornecidos pelo programa foi criada a Tabela 1 contendo os dados de entrada (comprimento do passo), os dados de saída (ângulo da bacia), tanto teóricos como obtidos pela rede, e também o erro percentual (note que o mesmo se encontra abaixo de 0,1% em todos os pontos, o que significa que a rede apresentou um desempenho excelente).

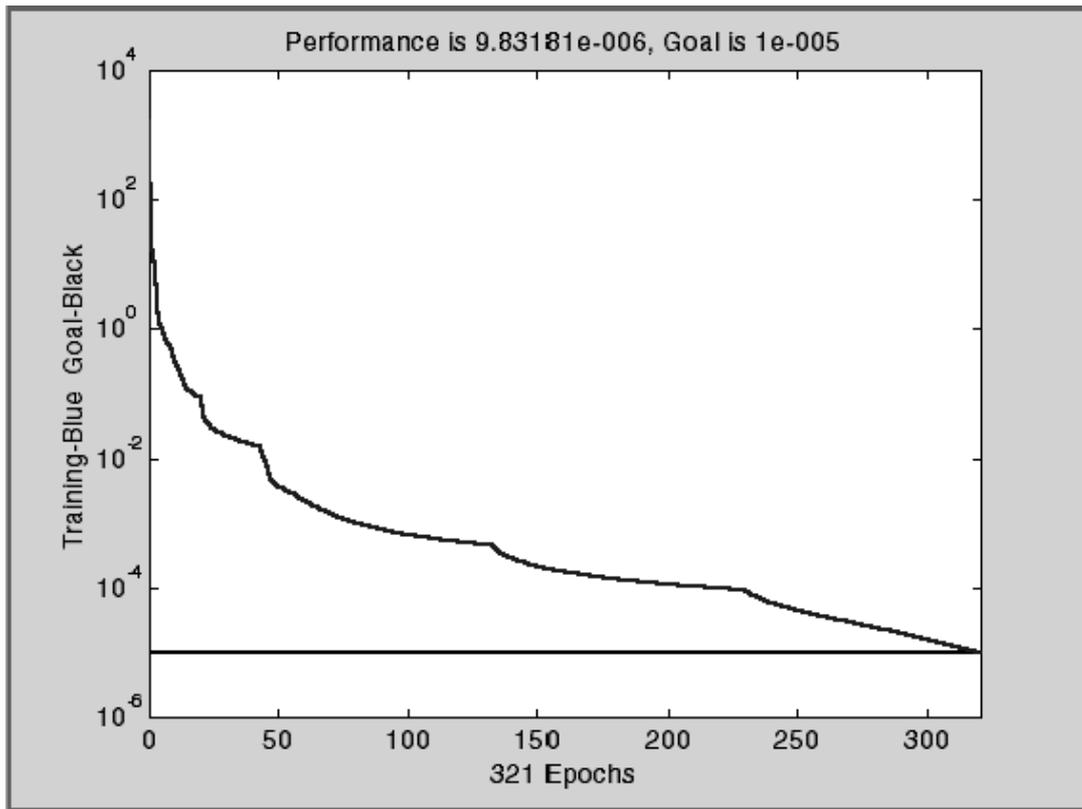


Figura 4. Treinamento da rede (erro médio quadrático: 1×10^{-5}).

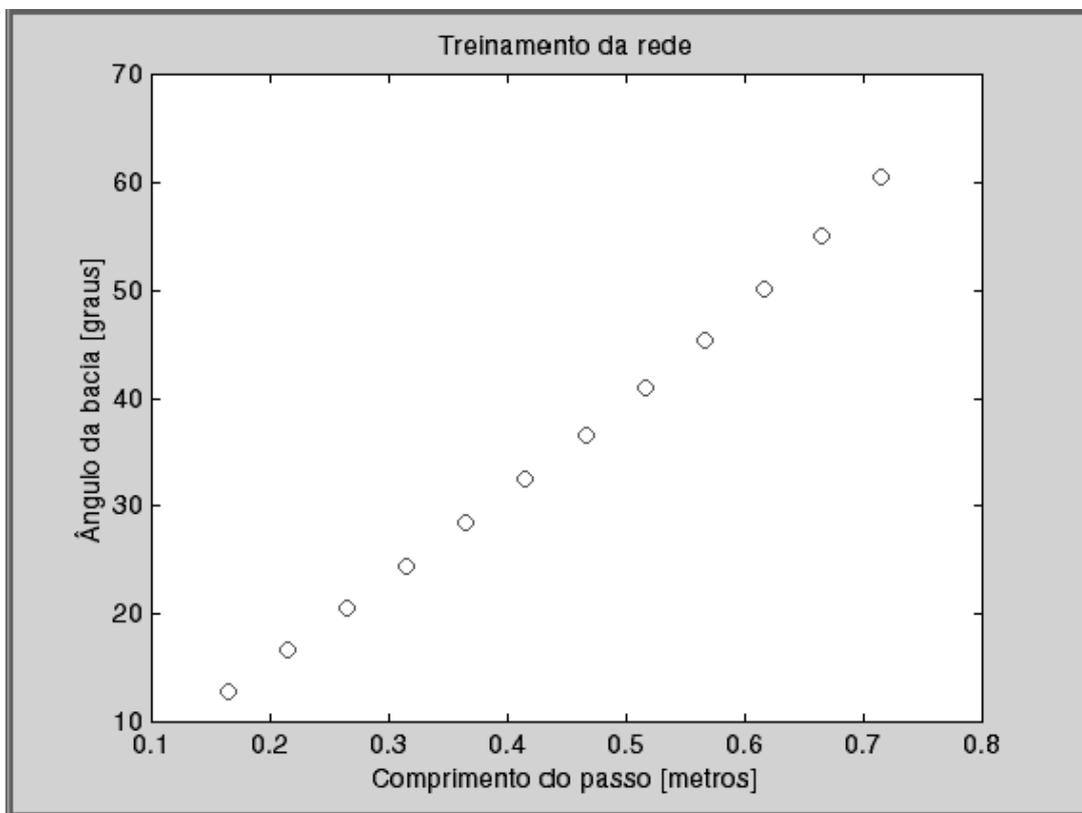


Figura 5. Resultados do treinamento (ângulo da bacia em função do passo).

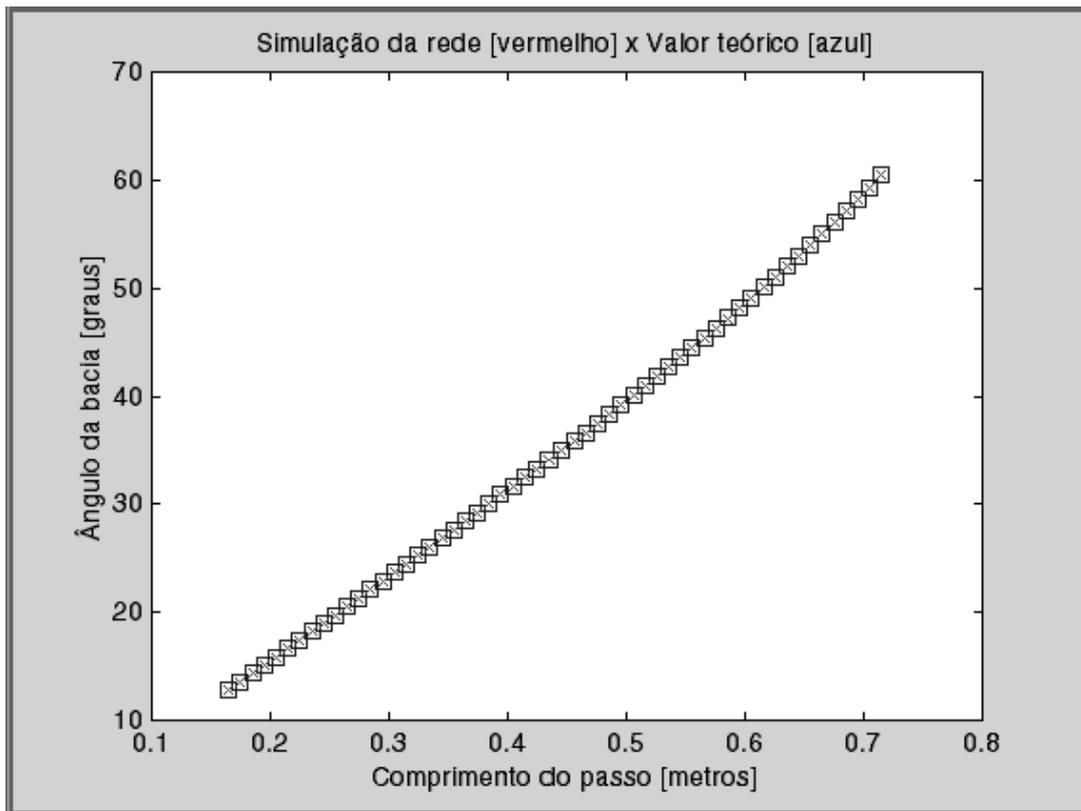


Figura 6. Comparação entre os valores da rede (×) e valores teóricos ().

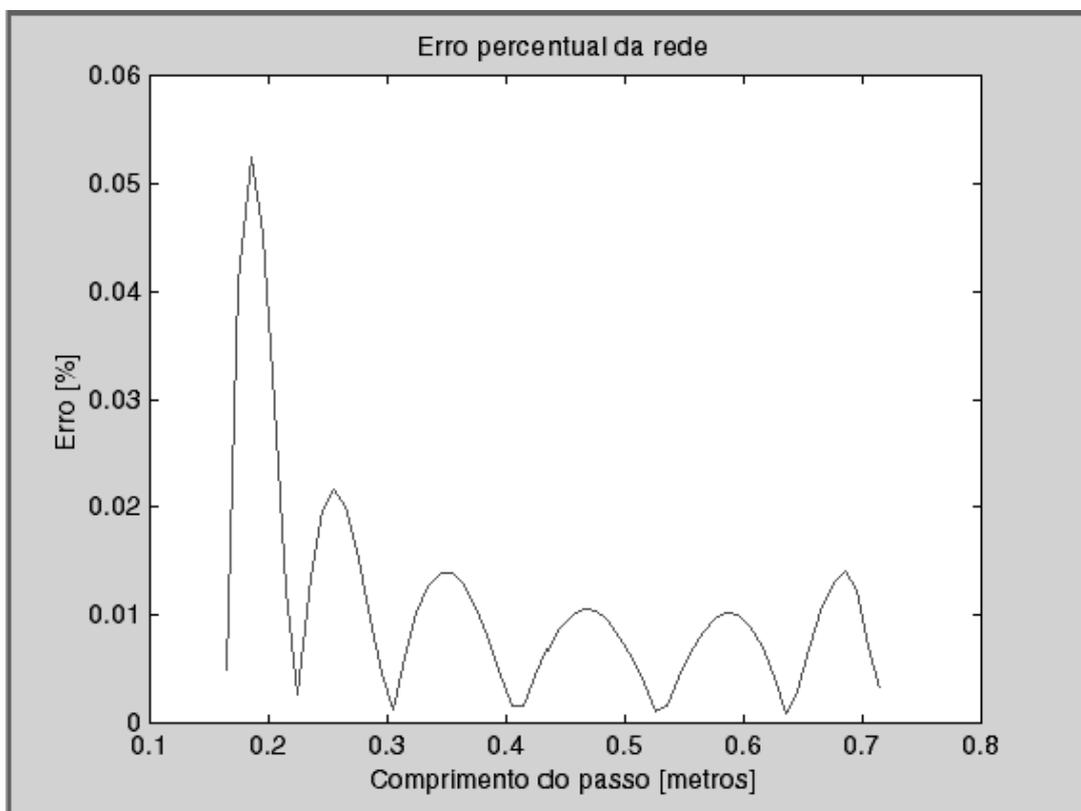


Figura 7. Avaliação do erro percentual dos resultados da rede.

Tabela 1. Alguns resultados experimentais finais.

Comp. do passo [m]	θ , teórico [graus]	θ , da rede [graus]	Erro da rede [%]
0,1650	12,7749	12,7755	0,0049
0,1850	14,3240	14,3165	0,0525
0,2050	15,8737	15,8690	0,0296
0,2250	17,4252	17,4257	0,0027
0,2450	18,9795	18,9833	0,0197
0,2650	20,5379	20,5420	0,0200
0,2850	22,1016	22,1039	0,0105
0,3050	23,6717	23,6714	0,0012
0,3250	25,2496	25,2471	0,0101
0,3450	26,8366	26,8329	0,0140
0,3650	28,4341	28,4305	0,0128
0,3850	30,0436	30,0411	0,0080
0,4050	31,6666	31,6660	0,0017
0,4250	33,3048	33,3063	0,0044
0,4450	34,9601	34,9632	0,0088
0,4650	36,6344	36,6383	0,0105
0,4850	38,3299	38,3335	0,0095
0,5050	40,0489	40,0513	0,0060
0,5250	41,7941	41,7946	0,0010
0,5450	43,5685	43,5666	0,0042
0,5650	45,3752	45,3714	0,0084
0,5850	47,2181	47,2132	0,0103
0,6050	49,1014	49,0970	0,0090
0,6250	51,0302	51,0280	0,0043
0,6450	53,0102	53,0118	0,0029
0,6650	55,0484	55,0541	0,0104
0,6850	57,1530	57,1610	0,0140
0,7050	59,3341	59,3383	0,0071
0,7150	60,4571	60,4552	0,0032

4. CONCLUSÕES

Este estudo demonstra a possibilidade do emprego de redes neurais para determinação dos ângulos de posicionamento para um sistema mecânico de locomoção bípede, fornecendo resultados excelentes, onde os erros apresentados pela rede se encontram abaixo de 0,1% em todos os pontos.

Vale ressaltar a grande importância da fase de treinamento, onde a rede consegue assimilar as informações relativas ao problema, possibilitando um desempenho ótimo na simulação e consequentemente apresentando os resultados desejados ao final do processo. A Figura 8 mostra o que aconteceria no caso de um treinamento mal sucedido.

A utilização de redes neurais para locomoção em velocidades normais (caminhada) se mostrou muito eficiente, porém não foram analisados casos onde o ângulo da bacia seja maior que 70° (como na subida de uma escada), ou mesmo em situações onde ambos os pés deixam de ter contato com o solo por alguns instantes (como na corrida).

Logo, verifica-se que o estudo aqui apresentado é o ponto de partida para elaboração de redes mais complexas, aplicáveis não somente ao caso de uma caminhada, mas também a situações como a corrida e subida de uma escada.

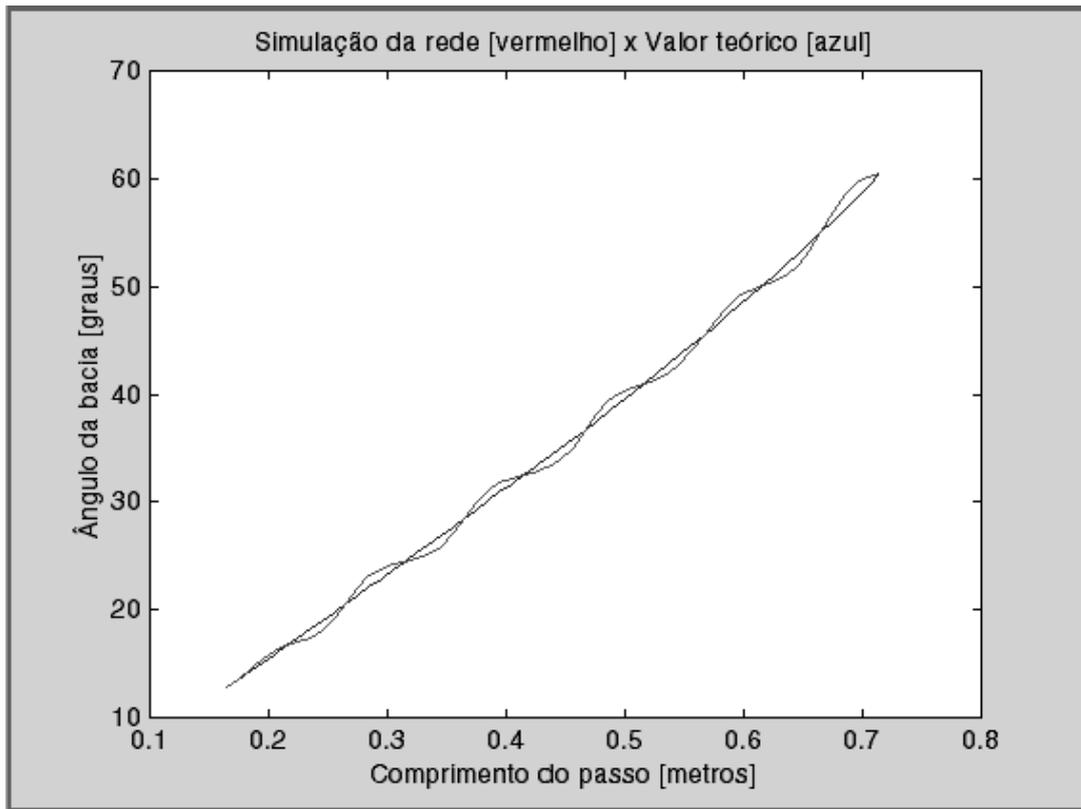


Figura 8. Treinamento mal sucedido (os resultados fornecidos pela rede apresentam discrepâncias, oscilando em torno dos valores teóricos).

5. REFERÊNCIAS BIBLIOGRÁFICAS

- Braune, W., Fischer, O., 1987, “The Human Gait”. Springer Verlag, Berlin, Germany. Translated from Der Gang des Menschen, B.G. Teubner, 1904.
- Dutra, M. S., 1995, “Bewegungskoordination und Steuerung einer zweibeinigen Gehmaschine”, Shaker Verlag, Aachen, Germany.
- Lopes Júnior, V., Dutra, M. S., Nascimento, Á. O. do, 1999, “Modeling of a Bipedal Locomotor Using Neural Networks”, Applied Mechanics in the Americas, Vol. 8, AAM and ABCM, Rio de Janeiro, Brazil.
- Saunders, J. B., Inman, V., Eberhart, H. D., 1953, “The Major Determinants in Normal and Pathological Gait”, J. Bone Jt. Surgery 35 A.
- Wasserman, P. D., 1989, “Neural Computing: Theory and Practice”, Van Nostrand Reinhold, New York, USA.