

Sistema Óptico de Reconhecimento de Trajetória para Veículos Autônomos Utilizando Redes Neurais

G. A. Borges e A. M. N. Lima

UFPB/CCT/DEE - Campus II

Laboratório de Instrumentação Eletrônica e Controle

58109-970 Campina Grande, PB, Brasil - Caixa Postal 10.105

e-mail: {geovany,marcus}@dee.ufpb.br

Abstract

This paper describes the use of neural networks in the implementation of the guidance of an Automated Guided Vehicle (AGV). The guidance system of the AGV is based on the fixed path strategy by using optical sensors. The optical sub-system consists of infrared light emitting diodes and photodiodes which are used to detect a reference track painted in the ground. Two Multilayer Perceptrons Feedforward Neural Networks were trained to extract from the image acquired by the optical sensors the position of the vehicle with respect to the reference track. This position information can be used by the controller of the AGV to maintain the vehicle aligned with the reference track along the desired trajectory. The experimental results obtained with a laboratory prototype are presented and demonstrate the feasibility of the proposed scheme.

Keywords— Neural Networks, Automated Guided Vehicles, Tracking System.

1 Introdução

Os Veículos de Transporte Autônomos (VTAs) são, de modo geral, empregados em ambientes industriais para o transporte de objetos, isto é, ferramentas, matérias primas e itens manufaturados entre máquinas ou células do sistema de produção. Estes veículos realizam deslocamento supervisionado a nível local ou por uma estação remota. A

trajetória desejada pode ser especificada em termos de rotas fixas, rotas semi-fixas ou rotas indefinidas [3, 4, 7]. Rotas fixas requerem a instalação de um guia fixo que pode ser ativo como um condutor por onde circula uma corrente elétrica, ou passivo como uma fita reflexiva que determina a trajetória desejada. Rotas semi-fixas podem ser especificadas por marcações em locais estratégicos tais como códigos de barras, magnetos ou balisas de deslocamento. Rotas indefinidas são geralmente empregadas com técnicas de localização relativamente complexas tais como GPS (Global Positioning System), reconhecimento do ambiente por imagens, giroscópios, raio laser ou mapas pré-programados.




Figura 1: Esquema simplificado do VTA e da marcação guia. RML: Roda de Movimento Livre. RMM: Roda de Movimento Motorizado.

O VTA utilizado neste trabalho foi projetado para utilizar o esquema de rotas fixas, como mostrado na Figura 1. Nesta figura é ilustrada uma marcação óptica (marcação guia) na forma de uma linha de tonalidade que contrasta com a cor do chão, que determina a trajetória desejada do VTA. Nos experimentos realizados, a marcação guia foi pin-

tada com a cor preta e o chão com a cor branca. Neste veículo, o objetivo do sistema de controle é manter o VTA sempre sobre a marcação guia durante todo o deslocamento. O protótipo do VTA utilizado possui três unidades que compõem o sistema de direcionamento: a Unidade de Aquisição de Imagem (UAI), a Unidade de Processamento de Imagem (UPI) e a Unidade de Controle de Trajetória (UCT).

A determinação da posição do veículo em relação à marcação guia é feita através do processamento de imagens adquiridas por sensores ópticos, geralmente câmeras CCD. No sistema em questão a determinação da posição do VTA é feita a partir dos dados obtidos de uma rede de fotodiodos. Ao conjunto formado pela rede de fotodiodos e os circuitos de condicionamento denomina-se de Unidade de Aquisição de Imagem (UAI). A informação coletada pela UAI é processada para determinar o desvio de trajetória do VTA relativo à marcação guia. Este processamento é feito pela UPI. A UCT recebe da UPI a informação relativa ao desvio do VTA em relação à marcação guia e faz a correção em tempo real da trajetória através do controle de velocidade dos motores de tração.

2 Motivação e Objetivos

A motivação deste estudo é a concepção de um sistema simples e de baixo custo para a obtenção de variáveis de erro de trajetória de um VTA. São objetivos deste trabalho apresentar a UAI, baseada numa rede de fotodiodos e LEDs infravermelhos e a UPI composta de duas redes neurais treinadas com o objetivo de extrair da imagem coletada e tratada pela UAI, as variáveis relativas ao erro de trajetória. Neste trabalho o erro de trajetória é caracterizado pelo ângulo de desvio (Θ) e o deslocamento ortogonal (Γ) do VTA relação a marcação guia, conforma ilustra a Figura 2.

Na Figura 2 é mostrada a linha de referência sob a rede de sensores. O ângulo de desvio é tomado entre a marcação guia e a linha de referência. O deslocamento ortogonal é a distância ortogonal à linha de referência, tomada a partir do centro da rede de sensores, até a linha da marcação guia. Se o veículo estiver seguindo a trajetória, ou seja, sua linha de referência estiver sobre a marcação guia, estas duas variáveis devem ser nulas.

3 Rastreo da Marcação

A rede de sensores ópticos está configurada como mostra a Figura 3(a) e é dividida em duas colu-




Figura 2: Variáveis que definem o erro de trajetória.

nas com LEDs infravermelhos e fotodiodos alternados. A marcação guia deve possuir uma largura maior ou igual à distância entre dois fotodiodos adjacentes de uma mesma coluna (15,80mm). A linha de referência passa sobre os sensores 4 e 11. Para obter dados consistentes, a marcação guia deve passar abaixo das duas colunas de sensores. Na Figura 3(b) é mostrado o posicionamento da rede de sensores sobre a marcação guia.

Para a aquisição da imagem da marcação guia, os LEDs infravermelhos são ativados simultaneamente por um pulso de $100\mu s$ de largura. A luz emitida pelos LEDs infravermelhos é refletida pelo chão e uma parte retorna para os fotodiodos. A quantidade de energia luminosa captada por cada fotodiodo está relacionada ao índice de absorção da região do chão logo à frente do fotodiodo. No caso da presença da marcação guia, de cor preta, esta energia é consideravelmente menor do que a energia da luz refletida pelo chão, de cor branca. O diagrama em blocos do circuito de condicionamento de cada fotodiodo é mostrado na Figura 4. Os fotodiodos são polarizados reversamente e um filtro passa-altas é usado para rejeitar a iluminação ambiente e permitir a passagem de um pulso de tensão dado pelo acionamento dos LEDs infravermelhos. Este sinal é amplificado e processado através de um detector de pico e de um S/H (*Sample/Hold*). Os valores de pico dos sinais detectados pelos fotodiodos são representados por $\hat{V}_i$, $i = 1, 2, \dots, 14$. Os sinais provenientes dos fotodiodos são conectados a um




Figura 3: Rede de fotodiodos da UAI.




Figura 4: Diagrama em blocos do circuito condicionador de cada fotodiodo da UAI.




Figura 5: Vista frontal da plataforma de testes.

multiplexador analógico de 16 canais cuja saída é ligada a um conversor A/D de 8 bits. A UPI, sendo uma unidade microprocessada, faz a aquisição da imagem da marcação guia sequencialmente através da seleção do canal desejado do multiplexador e comando de uma conversão no conversor A/D para cada um dos sensores.

4 Plataforma de Testes

Para a coleta de dados experimentais foi construída uma plataforma de testes que é ligada a um microcomputador AMD5x86-133Mhz através de uma interface paralela. A Figura 5 apresenta a vista frontal da estrutura da plataforma na qual seus elementos constituintes estão numerados de 1 a 9. O suporte da UAI (1) pode ser movido através do eixo sem fim (2) que é acoplado diretamente ao motor de passo de posicionamento (3). O passo p do eixo sem fim é de $1,588mm$, que corresponde, para o motor utilizado, a 24 passos. O sensor óptico (4) é utilizado para detectar o ponto de parada de cada volta e é acoplado ortogonalmente ao eixo sem fim. As chaves mecânicas 5 e 6 são usadas como sensores de final de curso do lado direito e do esquerdo, respectivamente. Estas chaves foram posicionadas de forma que o espaço entre elas corresponda a $100p$. Uma escala linear de $-50p$ a $+50p$ é utilizada para indicar visualmente a posição da UAI. O disco de $330mm$ de diâmetro (7) que é movimentado por outro motor de passo (8) faz o posicionamento angular da marcação guia em relação a UAI. Com esta plataforma de testes consegue-se simular o ambiente de trabalho dos sensores e automatizar o procedimento de rastreamento da marcação guia e o treinamento das redes neurais da UPI.

O posicionamento da UAI é especificado pelas variáveis de erro de trajetória: deslocamento ortogonal Γ e ângulo de desvio Θ . O ângulo de desvio está no intervalo $-180^\circ \leq \Theta \leq 180^\circ$, com um passo de $0,75^\circ$. Utilizando a plataforma de testes, foram gerados aleatoriamente $N = 400$ pontos de posicionamento, de forma que a marcação guia sempre ficava abaixo das duas colunas de fotodiodos. Desse modo, foram adquiridos os seguintes dados: i) Uma matriz de dimensão $14 \times N$, denominada R , onde cada coluna representa uma imagem da marcação guia. ii) Dois vetores contendo os valores reais do deslocamento ortogonal, Γ_r e do ângulo de desvio, Θ_r , de dimensão $N \times 1$. Cada elemento i destes vetores corresponde a uma imagem dada por uma coluna i da matriz R . iii) Um vetor normalizador r_n (dimensão 14×1), que é a resposta dos sensores sem a presença da marcação guia. Este vetor pode ser usado para representar a máxima resposta de cada fotodiodo para fins de normalização.

5 Redes Neurais

A UPI é composta de duas redes neurais de três camadas treinadas para receberem como entrada uma imagem da marcação guia, que corresponde a uma coluna da matriz R , e apresentarem como saída as estimativas $\hat{\Gamma}$ e $\hat{\Theta}$ das variáveis de desvio de trajetória. Desta forma admite-se que as variáveis Γ e Θ são independentes. O treinamento destas redes caracteriza um procedimento de mapeamento não-linear.

Foi escolhido um modelo de identificação neuronal não-linear com redes *feedforward* do tipo *multilayer perceptron* (MLP) de três camadas, com uma camada oculta não-linear e uma camada de saída linear [2, 6, 5]. Este modelo apresenta aproximações globais, ou generalizações, em regiões do espaço de entrada pouco exploradas pelos pontos de treinamento [1]. No contexto do trabalho, deseja-se esta generalização uma vez que o número de pontos de treinamento é limitado devido ao posicionamento descontínuo dos sensores pela plataforma de testes.

A estrutura das MLPs é apresentada na Figura 6. A camada de entrada possui 14 elementos, que corresponde à dimensão de um vetor de imagem armazenados na forma de uma coluna da matriz R . Os vetores relativos à imagem da marcação são normalizados pela resposta máxima de cada sensor, que são os elementos do vetor r_n , antes de serem aplicados à camada de entrada das redes. O i -ésimo elemento do vetor de entrada x_q (q -ésima




Figura 6: Estrutura das redes utilizadas para a estimação das variáveis.

imagem) de cada rede neural é dado por

$$x_q(i) = \frac{R(i, q)}{r_n(i)} - 0,5 \quad (1)$$

com $i = 1, 2, \dots, 14$ e $q = 1, 2, \dots, N$.

A dimensão da camada oculta foi tomada como um parâmetro do projeto, e portanto ela é composta por N_{oc} neurônios, com funções de ativação do tipo tangente hiperbólicas para cada neurônio índice j da forma

$$\varphi_j(v_j) = \theta_j \frac{1 - \exp(-\beta_j v_j + \alpha_j)}{1 + \exp(-\beta_j v_j + \alpha_j)}, \quad j = 1, \dots, N_{oc}. \quad (2)$$

O nível de ativação do neurônio, v_j é dado por

$$v_j = W_{pol2}(j) + \sum_{i=1}^{14} x_q(i) W_{21}(j, i), \quad (3)$$

onde $W_{pol2}(j)$ é o peso de polarização do neurônio j , e $W_{21}(j, i)$ é o peso associado à entrada i do neurônio j da camada oculta.

A camada de saída é formada por apenas um neurônio com função de ativação dada por

$$\varphi_{saída} = K \left[W_{pol3} + \sum_{j=1}^{N_{oc}} \varphi_j(v_j) W_{32}(j) \right], \quad (4)$$

onde W_{pol3} é o peso de polarização do neurônio de saída e $W_{32}(j)$ é o peso associado à entrada j do neurônio de saída.

O procedimento de treinamento consiste em utilizar o algoritmo *back-propagation*, que é o método newtoniano *steepest descent* aplicado à redes neurais, para ajustar os pesos W_{21} , W_{32} , W_{pol2} e W_{pol3} . O mesmo método é utilizado para ajustar os parâmetros α_j , β_j e θ_j da função de ativação do j -ésimo neurônio da camada oculta [6]. O objetivo do treinamento é a minimização da função de custo




Figura 7: Progressões das funções de custo durante o treinamento das redes MLP com $N_{oc} = 4$.

dada por

$$J = \frac{1}{2N} \sum_{q=1}^N (F_r(x_q) - \varphi_{saída})^2$$

onde $F_r(x_q)$ é a saída desejada para o vetor de entrada x_q , dada por $\Gamma_r(q)$ ou $\Theta_r(q)$, dependendo da rede que está sendo treinada. N é o número de pontos avaliados pela função de custo.

6 Treinamento das Redes

Para cada variável de erro de trajetória Γ e Θ , foram treinadas quatro redes MLP, com 4, 7, 14 ou 28 neurônios na camada oculta. Em todas foram feitos ajustes nos pesos W_{21} , W_{32} , W_{pol2} , W_{pol3} e nos parâmetros α_j , β_j e θ_j das funções de ativação da segunda camada.

Foram adquiridos 1150 pontos, onde 750 foram utilizados no treinamento e 400 foram usados na validação das redes. Os pontos de treinamento foram adquiridos aleatoriamente pela plataforma de testes. Durante a fase de treinamento, os pontos foram apresentados às redes de forma aleatória, de forma que é reduzida a possibilidade de que o método *back-propagation* estabilize em um mínimo local da função de custo J [1]. Na geração dos pontos de validação, simulou-se uma marcação guia de forma senoidal com a linha de referência na direção do seu centro e os pontos foram adquiridos como se o veículo se deslocasse sobre a linha de referência sem realizar desvios. Desta forma, Γ deve apresentar uma forma senoidal, e Θ uma forma cossenoidal, como se para cada ponto adquirido a marcação guia fosse um seguimento de reta de inclinação dada por Θ .

As Figuras 7, 8, 9 e 10 apresentam a




Figura 8: Progressões das funções de custo durante o treinamento das redes MLP com $N_{oc} = 7$.




Figura 10: Progressões das funções de custo durante o treinamento das redes MLP com $N_{oc} = 28$.




Figura 9: Progressões das funções de custo durante o treinamento das redes MLP com $N_{oc} = 14$.




Figura 11: Validação das redes MLP com $N_{oc} = 4$.

progressão da função de custo durante a fase de treinamento para $N_{oc} = 4, 7, 14$ e 28 , respectivamente. As Figuras 11, 12, 13 e 14 mostram os gráficos dos resultados de validação das redes MLP com $N_{oc} = 4, 7, 14$ e 28 , respectivamente, que estimam o deslocamento ortogonal e o ângulo de desvio. Para cada gráfico são apresentados os valores da função de custo J . As curvas contínuas representam as saídas desejadas das redes, e as curvas pontilhadas representam as saídas estimadas pelas duas redes ($\hat{\Gamma}$ e $\hat{\Theta}$).

A Tabela 1 apresenta os valores das funções de custo das MLP de diferentes quantidades de neurônios na camada oculta (N_{oc}), avaliadas com os pontos de validação.

De acordo com os valores da função de custo para os pontos de validação, observa-se que melhores resultados na estimativa de Γ foram obtidos com uma MLP com $N_{oc} = 4$. Da mesma forma, os melhores resultados para a estimativa de Θ foram obtidos de uma MLP com $N_{oc} = 7$.




Figura 12: Validação das redes MLP com $N_{oc} = 7$.

Rede Neural	Γ	Θ
MLP ($N_{oc} = 4$)	$J = 1,128$	$J = 9,247$
MLP ($N_{oc} = 7$)	$J = 1,216$	$J = 5,034$
MLP ($N_{oc} = 14$)	$J = 1,364$	$J = 10,308$
MLP ($N_{oc} = 28$)	$J = 1,189$	$J = 7,488$

Tabela 1: Valores da função de custo para diferentes redes.




Figura 13: Validação das redes MLP com $N_{oc} = 14$.




Figura 14: Validação das redes MLP com $N_{oc} = 28$.

Para avaliar a complexidade computacional da estratégia de reconhecimento proposta neste trabalho, os tempos de estimação das variáveis Γ e Θ foram determinados utilizando o mesmo microcomputador hospedeiro da plataforma de testes. Para esta avaliação considerou-se duas redes MLP com $N_{oc} = 14$, para as estimativas de Γ e Θ . O tempo de estimação é composto de três parcelas: o tempo de aquisição de uma imagem (τ_x), tempo de estimação de Γ (τ_Γ) e o tempo de estimação de Θ (τ_Θ). A Tabela 2 mostra estes resultados.

O valor do tempo de aquisição de imagem τ_x é relativamente grande se comparado com τ_Γ e τ_Θ . Isto é devido ao uso de um conversor A/D com tempo de conversão de $150\mu s$ (ADC0804). Este valor pode ser reduzido usando-se um conversor A/D

Rede Neural	τ_x	τ_Γ	τ_Θ
MLP ($N_{oc} = 14$)	2,7ms	1,05ms	1,05ms

Tabela 2: Tempos de aquisição de uma imagem e processamento por duas redes MLP.

mais rápido (e.g. ADC0820, com tempo de conversão de $2\mu s$).

7 Conclusões

Os resultados obtidos até este ponto do trabalho são considerados satisfatórios. Neste caso específico, uma boa aproximação e generalização por parte das redes treinadas é primordial para o bom desempenho da Unidade de Controle de Trajetória de um VTA industrial. Como este sistema ainda está em desenvolvimento, novas alternativas serão empregadas na busca de melhores resultados. Propõe-se através de resultados experimentais e da Tabela 1 o uso de uma rede MLP com 4 neurônios na camada oculta para a estimativa da variável Γ , e uma rede com 7 neurônios na camada oculta para a estimativa da variável Θ . A estrutura mecânica de um VTA já foi construída e sua arquitetura multiprocessada está definida. Uma boa performance do sistema de reconhecimento de trajetórias por marcações ópticas poderá ser comprovada com testes reais no veículo.

Referências

- [1] Simon Haykin. *Neural Networks - A Comprehensive Foundation*. Prentice Hall, 1994.
- [2] L. Ljung and J. Söberg. A system identification perspective on neural nets. Technical report, Linköping University, 1992.
- [3] P.E. Miyagi, J.C. Adamowski, L.A. Moscato, J. Okamoto, and M.R.P. Barretto. Veículos autônomos de transporte e seus controles. pages 226–233.
- [4] R. Andrew Russel. Laying and sensing odor markings as a strategy for assisting mobile robot navigation tasks. *Robotics and Automation Magazine*, pages 3–9, 1995.
- [5] J. Sjöberg. *Non-Linear System Identification with Neural Networks*. PhD thesis, Linköping University, 1995.
- [6] J. Sjöberg, H. Hjalmarsson, and L. Ljung. Neural networks in system identification. Technical report, Linköping University, 1993.
- [7] Eruc Sung, Ng Kok Loon, and Yee Chiang Yin. Parallel linkage steering for an automated guided vehicle. *IEEE Control Systems Magazine*, pages 3–8, 1989.