

5 Controle e Simulação

Neste capítulo serão apresentadas as simulações do sistema, tanto para o controle PID quanto para o controle por aprendizado. Todos os programas de simulação foram desenvolvidos no software Matlab / Simulink.

5.1. Controle PID

Tendo a função de transferência que representa o sistema servo hidráulico, o próximo passo é simular a resposta de um controle PID. Para isso, temos que encontrar os valores apropriados dos ganhos do controlador PID para um melhor desempenho. Isso é conhecido como sintonização do PID.

5.1.1. Sintonização para Controladores PID

O método empregado para a sintonização do controlador PID é de Ziegler – Nichols, o qual se baseia em regras para determinar os valores dos parâmetros do ganho proporcional K_p , do termo integral T_i , e do termo derivativo T_d , com base nas características de resposta transitória de uma planta específica.

Existem dois métodos empíricos de sintonização propostos por Ziegler – Nichols. Para este caso, usou-se o segundo método de sintonização, que consiste em inicialmente estabelecer $T_i = \infty$ e $T_d = 0$. Usando só a ação do controlador proporcional, incrementa-se o valor de K_p desde zero até um valor crítico K_{cr} , onde a saída exiba oscilações em regime. Desse modo, o ganho crítico K_{cr} e o período P_{cr} são obtidos experimentalmente. Ziegler – Nichols sugeriram que se estabelecessem os valores dos parâmetros K_p , T_i e T_d de acordo com a formulação que aparece na seguinte Tabela 5.1.

Tabela 5.1. Valores de ganhos para sintonizar um controlador P, PI ou PID segundo as regras de Ziegler – Nichols.

Tipo de Controlador	K_p	T_i	T_d
P	0,50 k_{cr}	∞	0
PI	0,45 k_{cr}	$\frac{1}{1,2} P_{cr}$	0
PID	0,60 k_{cr}	0,5 P_{cr}	0,125 P_{cr}

O controlador PID sintonizado mediante o segundo método das regras de Ziegler – Nichols resulta em:

$$G_c(s) = K_p \left(1 + \frac{1}{T_i S} + T_d S \right) \quad (5.1)$$

$$G_c(s) = 0,6K_{cr} \left(1 + \frac{1}{0,5P_{cr}S} + 0,125P_{cr}S \right) \quad (5.2)$$

5.1.2. Resposta do controlador PID para o controle de força

Empregando o método de sintonização de Ziegler – Nichols a função de transferência do sistema de controle de força seria a apresentada no diagrama de blocos da Figura 5.1.

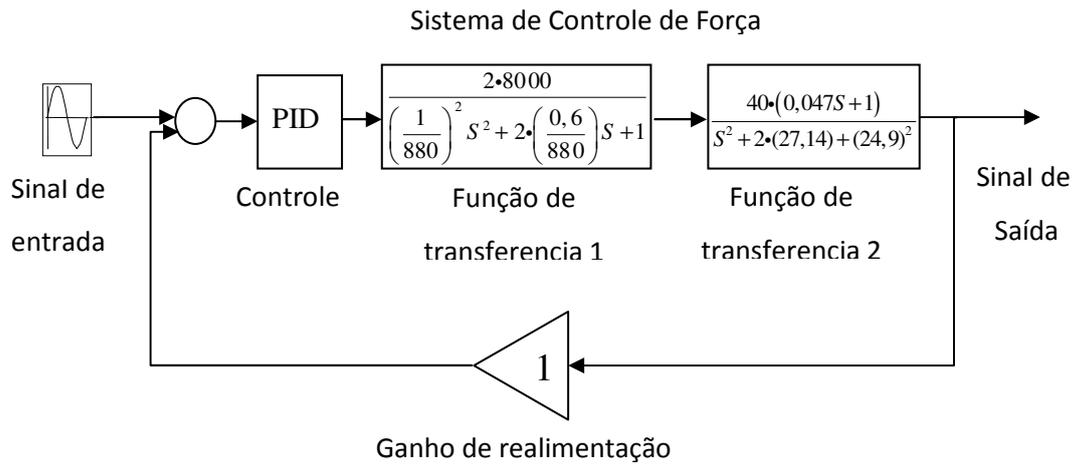


Figura 5.1. Diagrama de blocos para o controle de força incluindo o controlador PID.

A resposta do controlador PID para uma entrada senoidal de força de, e.g., 80 kN, é apresentada na Figura 5.2.

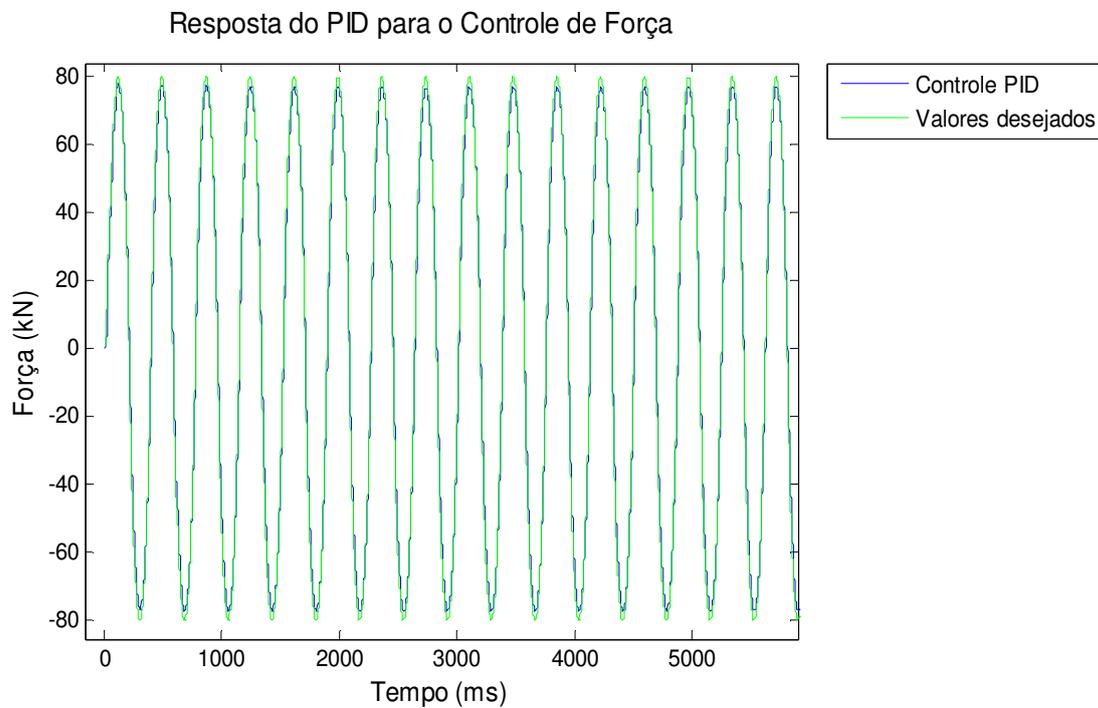


Figura 5.2. Resposta do controlador PID para um carregamento senoidal.

Pode-se observar na figura anterior como o controle PID consegue atingir o valor desejado com pequenos erros relativos.

5.1.3. Resposta do controlador PID para o controle de posição

O diagrama de blocos e a resposta do controlador PID para uma entrada senoidal de posição de, e.g., 50 mm, é apresentada nas Figuras 5.3 e 5.4.

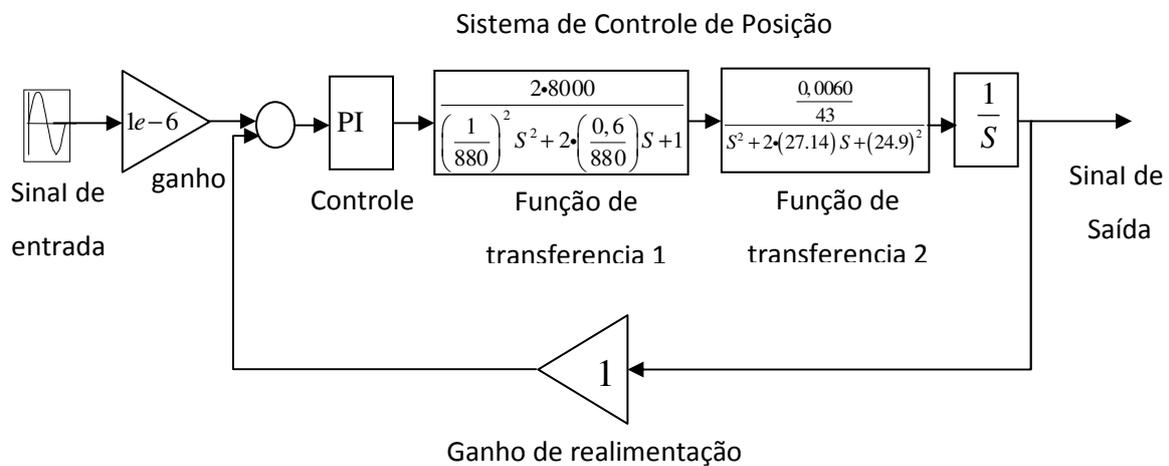


Figura 5.3. Malha fechada para o controle de posição.

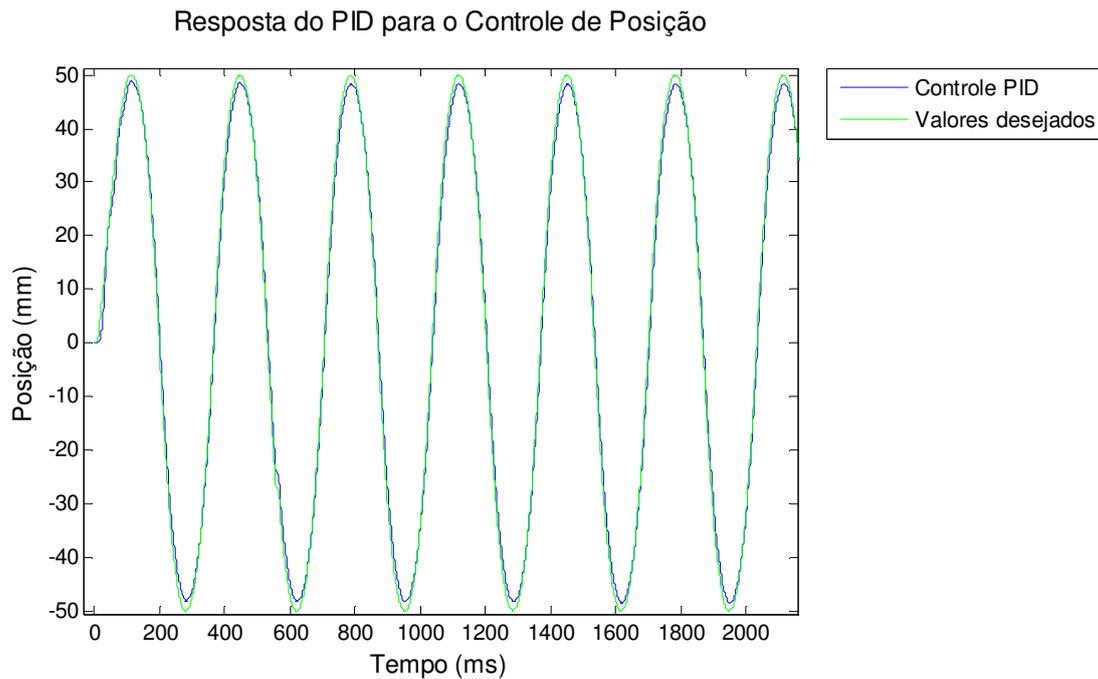


Figura 5.4. Resposta do controlador PID para um sinal senoidal de posição.

5.1.4. Resposta a uma entrada degrau máxima

A Figura 5.5 mostra a função de transferência que relaciona a força gerada pelo pistão com a entrada de corrente na servo-válvula. Nela aplica-se uma entrada do máximo valor recomendado pela MOOG [18] de corrente na servo-válvula, neste caso é de 40 mA. Na saída se obtém o valor de força de 95 kN, o qual está muito próximo do valor máximo de força que pode atingir, segundo o manual [19], o pistão da máquina INSTRON 8501, que é 100 kN.

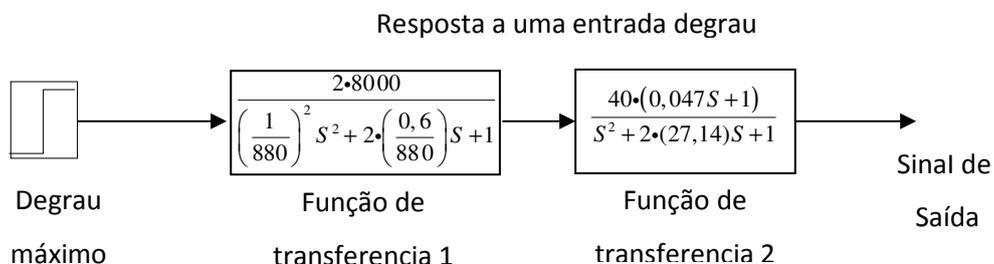


Figura 5.5. Função de transferência em malha aberta de força em relação à corrente de entrada.

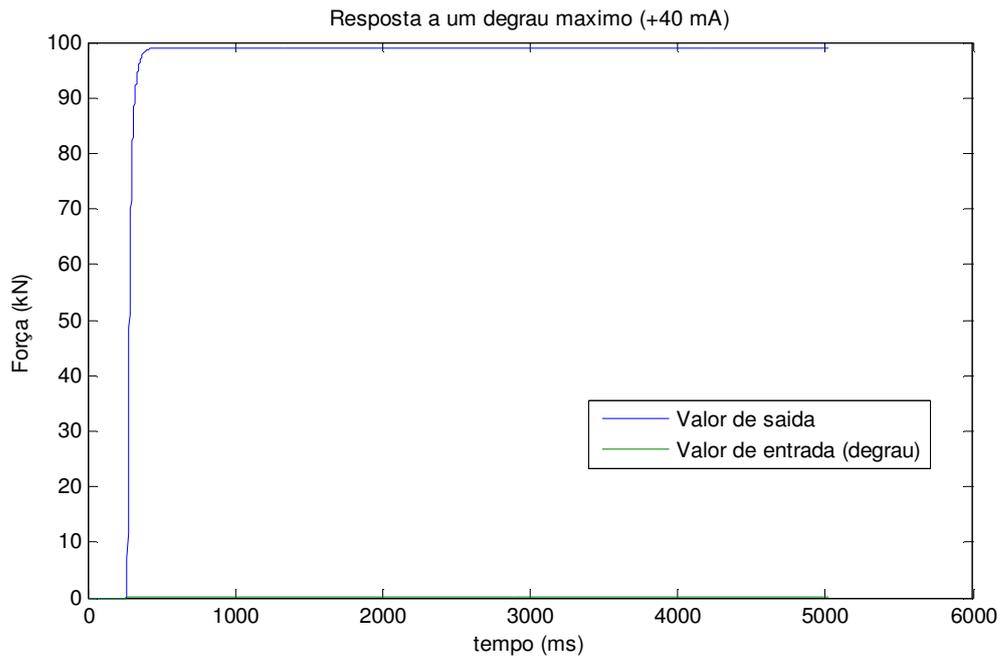


Figura 5.6. Resposta a uma entrada degrau máxima.

5.2. Controle por Aprendizado

No projeto de um sistema de controle ótimo, se toda a informação do processo controlado (dinâmica da planta) é conhecida e pode ser descrita deterministicamente, o regulador ótimo é desenhado geralmente por técnicas de otimização determinística. Se toda ou parte da informação puder ser descrita de maneira estatística, por exemplo, em termos das funções de probabilidade ou de distribuição de densidade, então só se utilizam ou técnicas de projeto estatístico ou estocástico.

No entanto, se a informação *a priori* requerida é desconhecida ou não é totalmente conhecida, em geral um desenho projeto não pode ser atingido com os métodos clássicos (programação dinâmica, o princípio máximo, cálculo variacional, etc.). Dois diferentes enfoques foram desenvolvidos para solucionar esta classe de problemas. Um enfoque é projetar um controlador baseado somente na quantidade de informação disponível. Neste caso, a informação desconhecida é ou ignorada ou é assumida para tomar alguns valores conhecidos da melhor estimativa do projetista.

A segunda alternativa é projetar um controlador que seja capaz de estimar a informação desconhecida durante sua operação, Neste caso, uma ação de controle ótima é determinada baseada na informação estimada. No primeiro caso, um critério de projeto de taxa conservativa (exemplo critério mínimo) é usado; os sistemas projetados são, em geral, ineficientes e sub-ótimos.

No segundo caso, se a informação estimada aproximasse gradualmente à informação verdadeira conforme passa o tempo, o controlador projetado se aproximaria do controlador ótimo. Isto é, o funcionamento do regulador projetado será tão bom quanto no caso onde toda a informação *a priori* requerida seria conhecida. Com a melhora gradual do desempenho devido à melhora da estimação da informação desconhecida, esta classe de sistema de controle pode ser chamada de sistema de controle por aprendizagem. O controlador aprende a informação desconhecida durante a operação e a informação aprendida é usada como uma experiência para futuras decisões de controle.

Do conceito acima introduzido, o problema de aprendizagem pode ser visto como um problema de estimação ou aproximações sucessivas das quantidades desconhecidas ou de uma função que representa o processo de controle em estudo. As quantidades desconhecidas a serem estimadas ou aprendidas pelo controlador podem ser ou somente os parâmetros ou a forma e parâmetros que descrevem uma função probabilística ou determinística. A relação entre as leis de controle e essa função é usualmente escolhida pelo projetista, e.g. em termos de seleção de um critério de otimização. Portanto, como o controlador acumula mais informação a respeito da função ou parâmetros desconhecidos, a lei de controle pode ser alterada de acordo com a informação atualizada para melhorar o desempenho do sistema.

A Figura 5.7 mostra um diagrama de blocos que representa o processo de controle por aprendizado. A cada ciclo, o sistema utiliza informações armazenadas na memória em variáveis U_{II} para controlar o sistema através de *feedforward*. Os erros medidos a cada ciclo são utilizados para atualizar os parâmetros U_{II} , através de uma lei de aprendizado. Esta lei é aplicada somente ao final de cada reversão k do movimento controlado, o que é representado na

Fig.5.7 pela chave que atualiza os valores $U_{II}(k)$ e erro(k) com os novos valores $U_{II}(k+1)$ e erro(k+1).

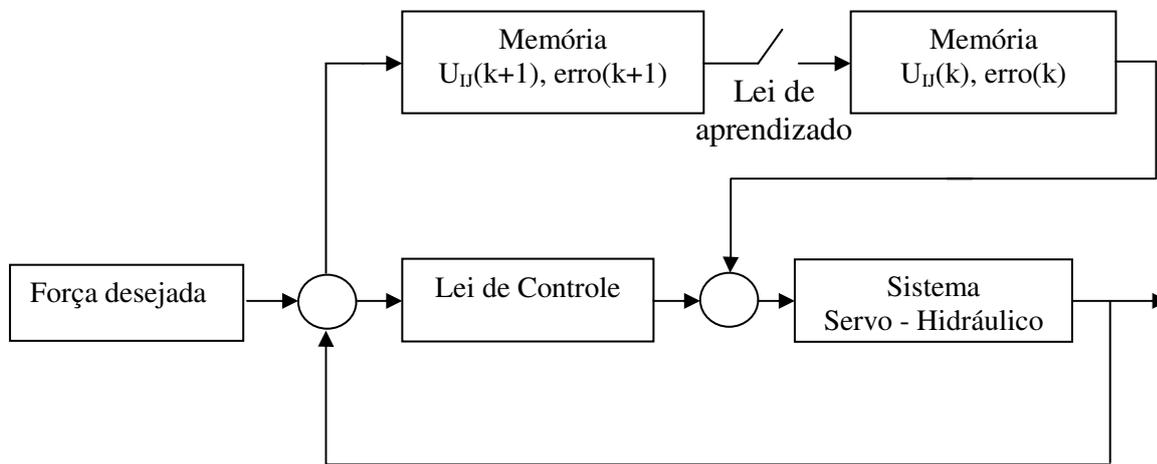


Figura 5.7. Diagrama de blocos do controle por aprendizado.

A metodologia do controle por aprendizado apresentada nesta dissertação consiste em manter a servo-válvula trabalhando em seus limites extremos de operação, tentando mantê-la a maior parte do tempo completamente aberta em uma ou outra direção. Devido à dinâmica do sistema, os pontos de reversão devem ficar antes dos picos e vales de força ou tensão desejados. O instante de reversão é um parâmetro que depende de diversos fatores, como a amplitude e carga média da solicitação, e é influenciado também por zonas mortas causadas, por exemplo, por folgas na fixação dos corpos de prova.

5.2.1. Tabela de Aprendizado

As tabelas de aprendizado são as que contêm os valores de U_{II} . Estes valores armazenados são adimensionais com valores entre 0 e 1, e são específicos para cada combinação de mínimo e gama do carregamento. Eles vão determinar, junto com outros parâmetros, o ponto de reversão no qual vai se inverter o sentido da servo-válvula. O ponto de reversão sempre está antes de um pico ou de um vale,

devido ao efeito da dinâmica envolvida no sistema servo-hidráulico, para conseguir atingir o pico ou vale desejado. U_{ij} é então definido como a fração de gama do carregamento na qual a reversão da válvula será comandada. E.g., se $U_{ij} = 0,8$, isso implica que a reversão será feita quando 80% do trajeto entre o vale e o pico (ou entre o pico e o vale) tiverem sido percorridos.

A tabela tem nas suas linhas o valor mínimo da magnitude física que esteja se controlando e nas suas colunas o valor da gama da mesma magnitude física, tão como se apresenta na Figura 5.8. A matriz representada por esta tabela tem um tamanho específico, para o sistema deste trabalho, escolho-se uma matriz de 21 x 21 elementos. Nesta estão envolvidas duas matrizes, uma pra quando o sistema esta indo para um pico e outra para quando o sistema esta indo para um vale. Para unificar ambas as matrizes definiu-se o conceito de gama negativa, indicando a ida de um pico para um vale. Por isso é que há valores positivos e negativos tanto para a gama como pra o mínimo. Tendo em consideração que o valor máximo de força gerado pela máquina de ensaios de fadiga é de 100 kN. Os valores de força de tração estão representados por valores de 0 a 100 kN e os valores de força de compressão representados por valores de -100 a 0 kN.

		Colunas (gama)					
		-25	-15	-5	5	15	25
Linhas (mínimo)	-25	0,9810	0,9602	0,8795	0,8016	0,8712	0,9475
	-15	0,9688	0,9415	U_{ij}	0,8245	0,9005	0,9516
	-5	0,9520	0,9230	0,8456	0,8429	0,9406	0,9712
	15	0,9256	0,8910	0,7415	0,9038	0,9668	0,9856
	25	0,9086	0,8723	0,6879	0,9312	0,9765	0,9901

Figura 5.8. Tabela de Aprendizado.

5.2.2. Leitura do valor de U_{IJ}

A tabela de aprendizado armazena de forma direta os valores de U_{IJ} , para cada combinação de mínimo e gama. Define-se U_{ij} (em letras minúsculas) como o elemento da tabela associado à linha i (valor mínimo “ \min_i ”) e coluna j (associada à gama “ gama_j ”). Assim, para um carregamento com valor mínimo \min_i , e gama igual a gama_j , tem-se que $U_{IJ} = U_{ij}$.

Se os valores do mínimo e gama do carregamento estiverem entre dois valores consecutivos discretizados na tabela, e.g. $\min_i < \min < \min_{i+1}$ e $\text{gama}_j < \text{gama} < \text{gama}_{j+1}$, então U_{IJ} é obtido por interpolação (Figura 5.9).

Colunas (gamma)

			gama_j	gama_{j+1}		
	0,8595	0,8364	0,8153	0,9314	0,9650	
Linhas (mínimo)	\min_i	0,8143	0,7923	$U_{i,j}$	$U_{i,j+1}$	0,9736
	\min_{i+1}	0,7640	0,7289	$U_{i+1,j}$	$U_{i+1,j+1}$	0,9812
	0,7128	0,6935	0,9216	0,9715	0,9878	
	0,6550	0,6320	0,9418	0,9835	0,9934	

Figura 5.9 Procedimento de interpolação quando os valores de gama e mínimo estão entre duas células.

$$U_{IJ} = a + (b - a) \cdot \frac{(\text{gama} - \text{gama}_j)}{(\text{gama}_{j+1} - \text{gama}_j)} \quad (5.3)$$

onde

$$a = U_{i,j} + (U_{i+1,j} - U_{i,j}) \cdot \frac{(min - min_i)}{(min_{i+1} - min_i)} \quad (5.4)$$

$$b = U_{i,j+1} + (U_{i+1,j+1} - U_{i,j+1}) \cdot \frac{(min - min_i)}{(min_{i+1} - min_i)} \quad (5.5)$$

Estas equações apresentadas podem ser generalizar para qualquer tipo de carregamento. Uma vez calculado o valor de U_{II} , pode-se calcular o ponto de reversão da servo-válvula, pela seguinte equação:

$$Ponto_Reversão = \begin{cases} min + U_{II} \cdot gama & (na\ subida) \\ (min + gama) - U_{II} \cdot gama & (na\ descida) \end{cases} \quad (5.6)$$

5.2.3. Lei de aprendizado

A lei de aprendizado é a que governa a atualização dos valores $U_{i,j}$ em um instante seguinte com o valor atual. O valor de U_{II} é atualizado em função do erro entre o pico (ou vale) atingido (medido) x e o pico (ou vale) desejado x_d . Sendo x' o vale (ou pico, respectivamente) medido na reversão anterior, define-se o erro pelo valor adimensional

$$erro = \frac{x_d - x}{x_d - x'} \quad (5.7)$$

Se x e x_d forem picos, x' terá sido um vale, e por tanto $x_d - x'$ será positivo. Assim, se houve *undershoot* neste evento, $x < x_d$ e assim $erro > 0$. Analogamente, se houver *overshoot*, então $erro > 0$. Analogamente, se houver *overshoot*, então $erro < 0$.

Se x e x_d forem vales, x' terá sido um pico, e por tanto $x_d - x'$ será negativo. No caso do *undershoot*, como o carregamento está diminuindo, então $x > x_d$, logo o *erro* > 0 . Analogamente, para *overshoot* teríamos aqui *erro* < 0 .

Conclui-se assim que erros positivos estão sempre associados ao *undershoot*, e negativos ao *overshoot*, seja numa subida (vale – pico) ou descida (pico – vale). Claramente, se houver *overshoot* então é preciso reverter à válvula mais cedo, o que implica em diminuir U_{II} ; por outro lado, no caso de *undershoot* precisamos aumentar U_{II} .

Uma vez que, em geral, $-1 < \text{erro} < 1$, pode-se propor a lei de aprendizado

$$U_{II} := U_{II} \cdot (1 + \text{erro}) \quad (5.8)$$

Esta lei não necessita de ganhos ajustáveis, e implica corretamente em aumento de U_{II} em casos de *undershoot* ($\text{erro} > 0$) e diminuição em casos de *overshoot* ($\text{erro} < 0$). É possível introduzir um ganho a ser multiplicado pelo erro na equação acima para ajustar a taxa de aprendizado, no entanto um ganho unitário se mostrou suficiente neste trabalho.

Se U_{II} tiver sido originalmente obtido por interpolação na tabela de aprendizado, então é preciso atualizar os valores de $U_{i,j}$, $U_{i,j+1}$, $U_{i+1,j}$, $U_{i+1,j+1}$ que o geraram. Essa atualização também é feita de forma ponderada, i.e., as células vizinhas mais próximas de U_{II} serão atualizadas em um maior grau que aquelas mais distantes. Isto é facilmente implementável com as leis de aprendizado

$$U_{i,j} := U_{i,j} \cdot [1 + (1 - \alpha) \cdot (1 - \beta) \cdot \text{erro}] \quad (5.9)$$

$$U_{i,j+1} := U_{i,j+1} \cdot [1 + (1 - \alpha) \cdot \beta \cdot \text{erro}] \quad (5.10)$$

$$U_{i+1,j} := U_{i+1,j} \cdot [1 + \alpha \cdot (1 - \beta) \cdot erro] \quad (5.11)$$

$$U_{i+1,j+1} := U_{i+1,j+1} \cdot [1 + \alpha \cdot \beta \cdot erro] \quad (5.12)$$

Onde

$$\alpha = \frac{\min - \min_i}{\min_{i+1} - \min_i}, 0 < \alpha < 1 \quad (5.13)$$

$$\beta = \frac{gama - gama_j}{gama_{j+1} - gama_j}, 0 < \beta < 1 \quad (5.14)$$

Note que as equações (5.3) a (5.5) podem ser re-escritas em função dos α e β acima, resultando em:

$$U_{ij} := U_{i,j} \cdot (1 - \alpha) \cdot (1 - \beta) + U_{i+1,j} \cdot \alpha \cdot (1 - \beta) + U_{i,j+1} \cdot (1 - \alpha) \cdot \beta + U_{i+1,j+1} \cdot \alpha \cdot \beta \quad (5.15)$$

5.2.4. Algoritmo de Controle

No seguinte fluxograma do algoritmo de controle se apresenta os passos seguidos para realizar a tarefa de controle baseada no aprendizado

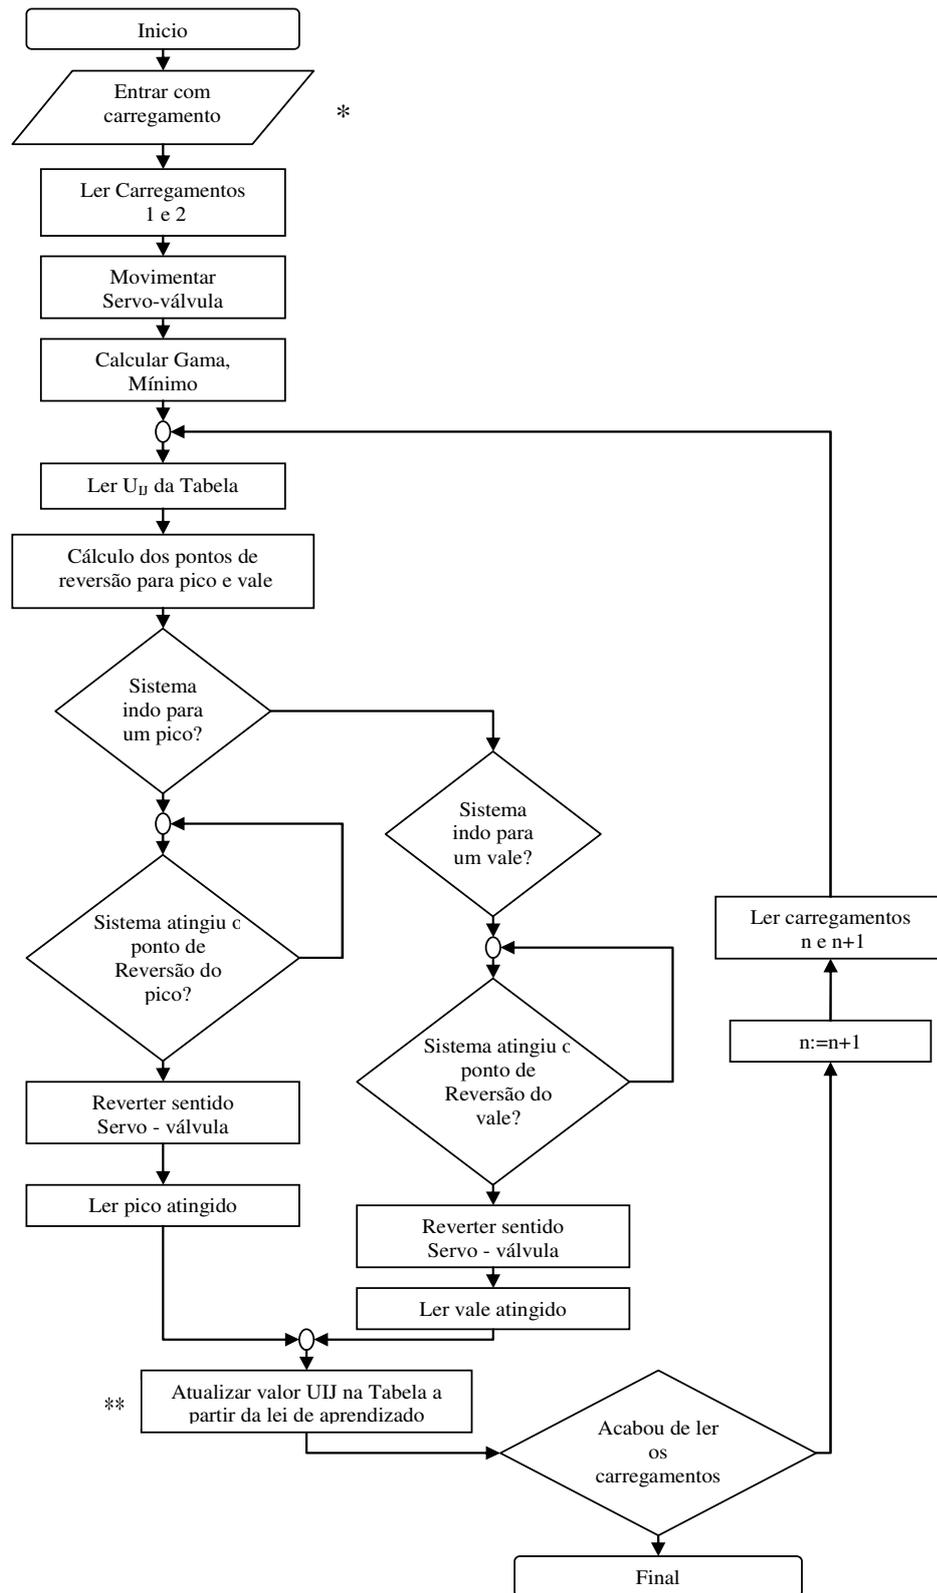


Figura 5.10. Algoritmo de controle por aprendizado.

* Os carregamentos são picos e vales requeridos para o ensaio de fadiga

** Para atualizar o valor U_{ij} é calculado o erro do pico e/ou do vale.

5.2.5. Resultado das simulações do controle por aprendizado

As simulações do sistema de controle proposto foram feitas no software em Matlab. Escolheram-se para as simulações carregamentos de amplitudes constantes e variáveis, tendo excelentes resultados. Nas Figuras 5.11 a 5.14 pode-se observar como o controlador vai aprendendo, mudando os pontos de reversão da servo-válvula até o valor ótimo no qual irá atingir o valor do carregamento desejado. Observa-se nestas simulações que em cerca de apenas 5 ciclos o aprendizado é completado.

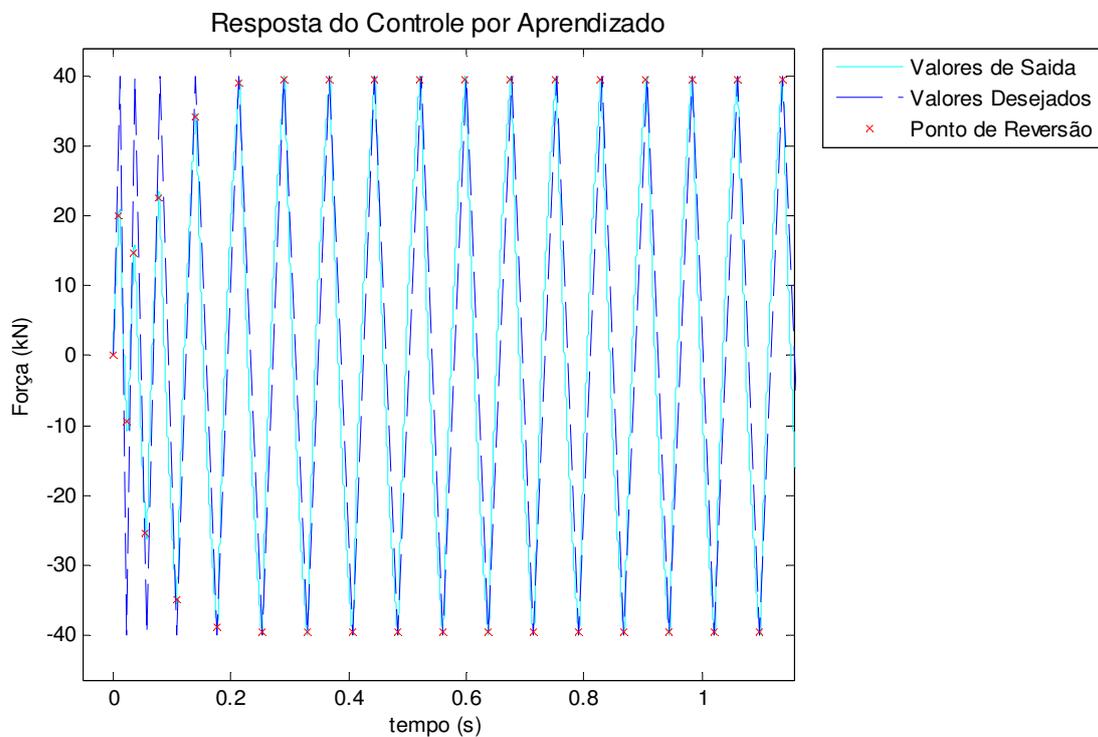


Figura 5.11. Resposta do controle por aprendizado para uma entrada de amplitude constante.

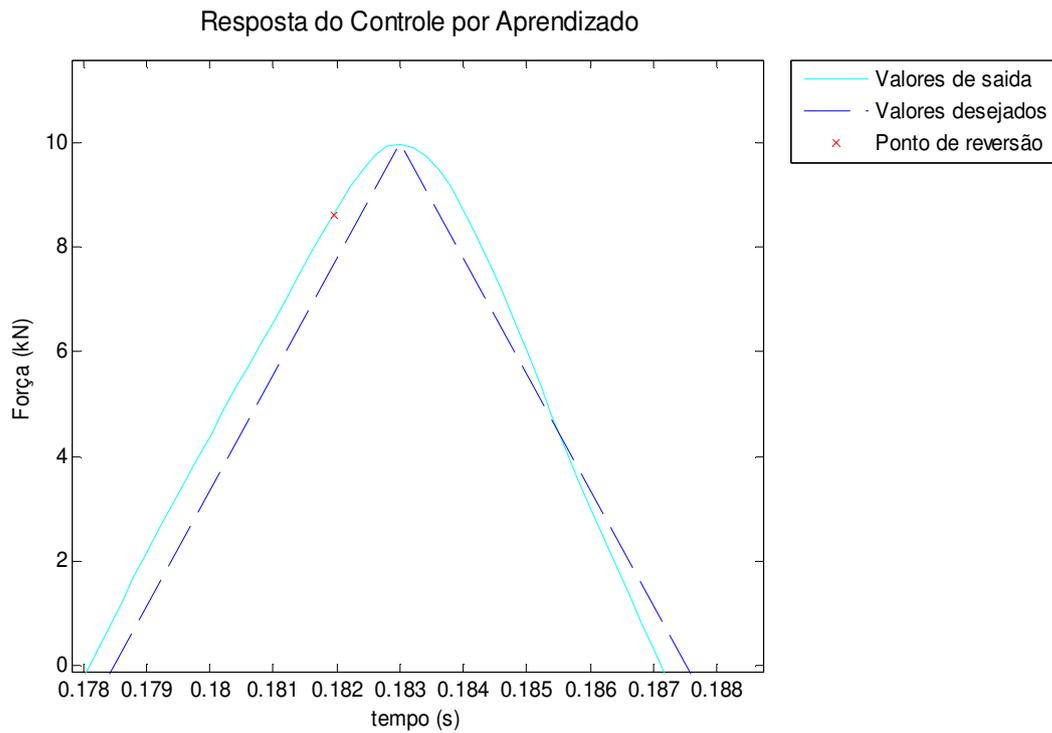


Figura 5.12. Vista ampliada de um pico e do Ponto de reversão da servo-válvula.

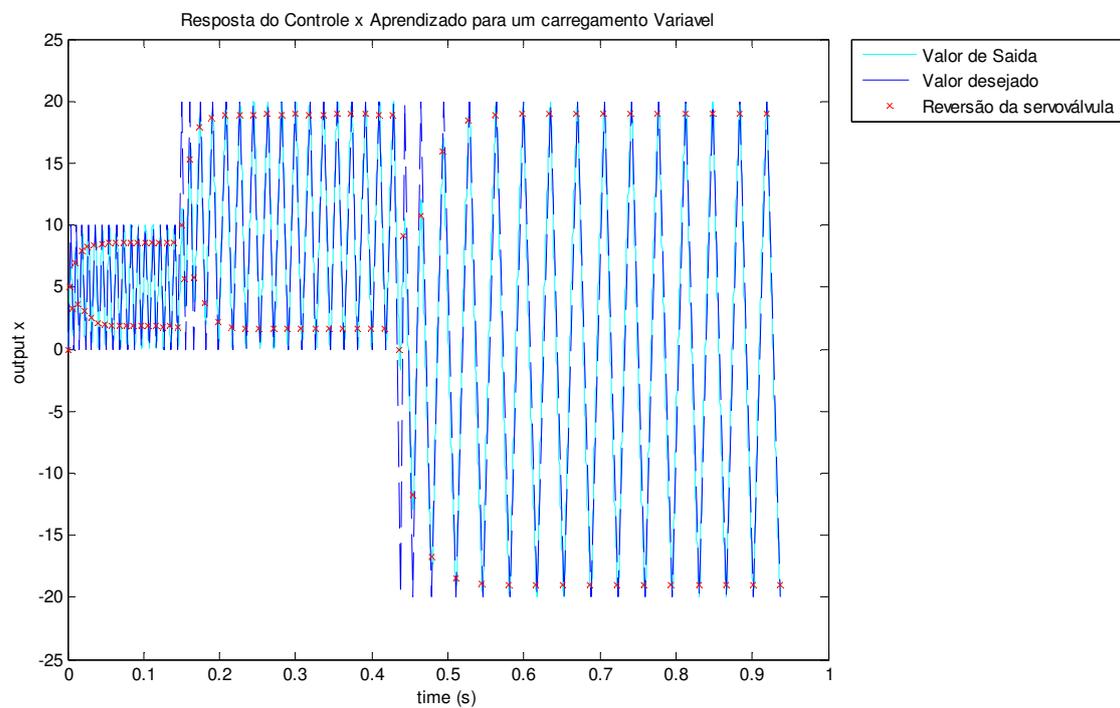


Figura 5.13. Resposta do controle por aprendizado para uma entrada de amplitude variável.

À medida que os carregamentos são impostos ao sistema, a tabela de aprendizado é atualizada até convergir para parâmetros $U_{i,j}$ ótimos. Desse modo, o sistema poderá responder a carregamentos futuros imediatamente sem a necessidade de reaprendizado, a menos que os parâmetros do sistema mudem (e.g. devido ao crescimento de trincas no corpo de prova). Mesmo nesse caso, basta não desligar a rotina de aprendizado para que o sistema automaticamente se ajuste a essas mudanças.

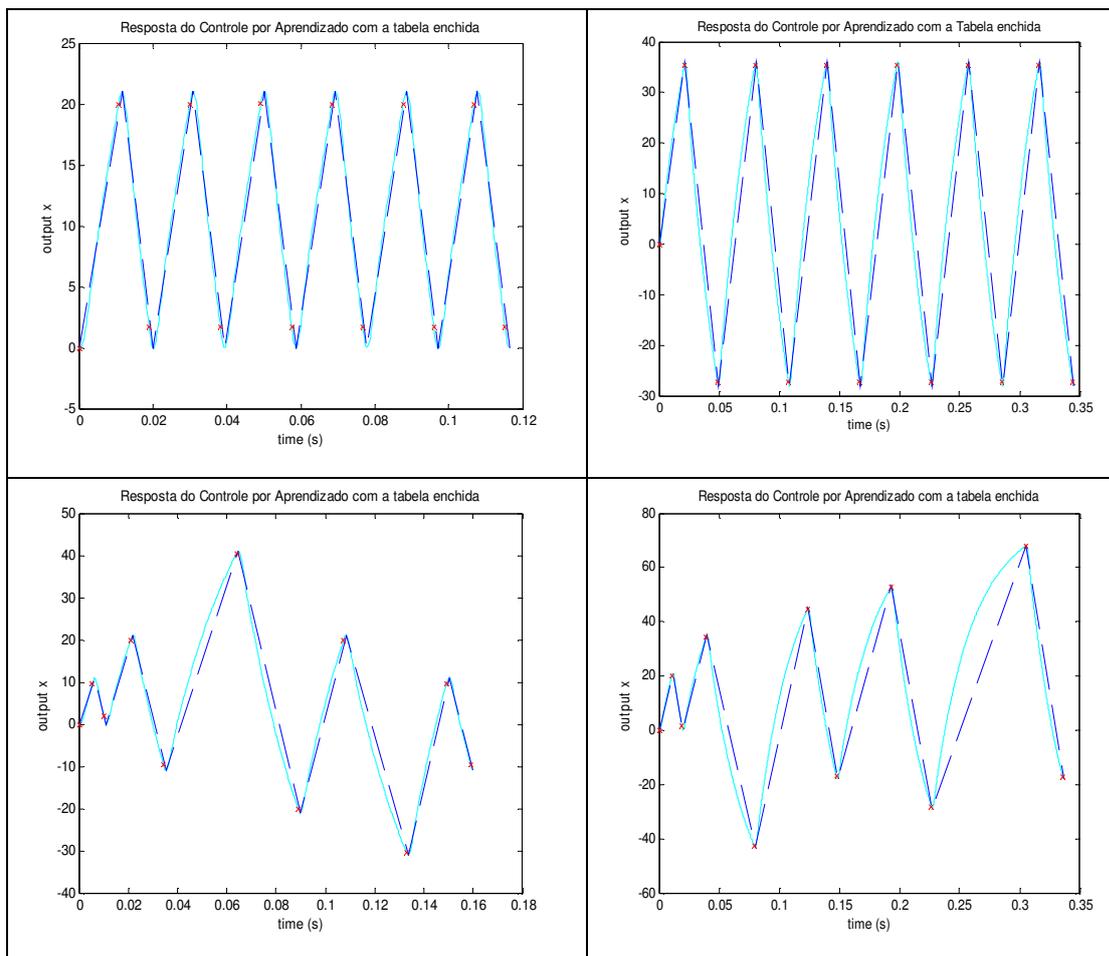


Figura 5.14. Gráfico das respostas do sistema de controle após o aprendizado para carregamentos (note que o sistema já inicia com erros quase nulos para os picos e vales).

Depois que todos os carregamentos que possam se gerar com a máquina de ensaios de fadiga foram apresentados ao sistema de controle, a tabela de aprendizado fica completa, e ela pode ser representada por uma superfície que contém os valores de U_{II} .

No próximo capítulo o sistema experimental e os resultados obtidos são apresentados.