

5. Controle por Aprendizado Acelerado e Simulação

5.1. Introdução

Neste capítulo é apresentado o projeto de um controle por aprendizado acelerado, e os resultados da simulação desenvolvida em Matlab©. Além disso, é apresentada uma breve descrição da modelagem do sistema servo-hidráulico, e o controle por aprendizado desenvolvido na dissertação de Alva [5], o qual será otimizado neste trabalho.

5.2. Modelagem do Sistema Servo-Hidráulico

Um sistema servo-hidráulico é constituído de um conjunto de componentes tais como: fonte de potência hidráulica, servo-válvula, pistão hidráulico, mangueiras, e sensores. Na Figura 5.1, apresenta-se um sistema hidráulico de uma máquina utilizada para ensaios de fadiga.




Figura 5.1. Sistema Servo-Hidráulico

Na presente dissertação, é utilizada a modelagem do sistema hidráulico de uma máquina para ensaios de fadiga desenvolvida por Alva. Este modelo é utilizado para avaliar o desempenho na simulação dos controladores propostos.

A modelagem do sistema servo-hidráulico é determinada pela dinâmica de seus componentes, os quais são descritos a seguir.

5.2.1. Modelagem da Servo-válvula

A modelagem do comportamento dinâmico da servo-válvula envolve uma variedade de parâmetros, como ilustrado na Figura 5.2. Muitos destes parâmetros são determinados de diferentes fontes de informação, fazendo com que o modelo não reflita exatamente o comportamento real.




Figura 5.2. Representação esquemática da servo-válvula.

Aplicando a segunda lei de Newton, as forças sobre o carretel principal da servo-válvula podem ser obtidas:

$$m_{sm} \ddot{x}_{vm} + F_f(\dot{x}_{vm}) = A_{ss,m} (P_{A,pi} - P_{B,pi}) - F_{ax,m} \quad (5.1)$$

$$P_{A,pi} = \frac{E'}{V_{A,pi}} (Q_{A,pi} + A_{ss,m} \dot{x}_{vm}) \quad (5.2)$$

$$P_{B,pi} = \frac{E'}{V_{B,pi}} (Q_{B,pi} + A_{ss,m} \dot{x}_{vm}) \quad (5.3)$$

onde $m_{sm}, A_{ss,m}, \dot{x}_{vm}$ é a massa, área e velocidade do carretel principal respectivamente, $F_f(\dot{x}_{vm})$ é a força de atrito, $F_{ax,m}$ é a força de fluxo axial sobre o carretel, e $P_{A,pi}, Q_{A,pi}, P_{B,pi}, Q_{B,pi}$ são as pressões e fluxos nos pontos A e B do carretel piloto.

Como as forças de atrito e aceleração são muito menores que a força impulsora, e a relação entre a área lateral e os volumes das câmaras no carretel principal são relativamente grandes, a pressão dinâmica no carretel principal pode ser desprezada. Assim, simplificando as equações (5.1) e (5.3), obtêm-se duas relações:

$$Q_{B,pi} = A_{ss,m} \dot{x}_{vm} = -Q_{A,pi} \quad (5.4)$$

$$A_{ss,m} (P_{A,pi} - P_{B,pi}) = 0 \quad (5.5)$$

Finalmente, as equações que descrevem a dinâmica dos fluxos do atuador são:

$$\begin{aligned} Q_A &= C_{v1} \cdot sg(x_{vm}) \cdot sign(P_s - P_A) \cdot \sqrt{|P_s - P_A|} \\ &- C_{v2} \cdot sg(-x_{vm}) \cdot sign(P_A - P_T) \cdot \sqrt{|P_A - P_T|} \end{aligned} \quad (5.6)$$

$$\begin{aligned} Q_B &= C_{v3} \cdot sg(-x_{vm}) \cdot sign(P_s - P_B) \cdot \sqrt{|P_s - P_B|} \\ &- C_{v4} \cdot sg(x_{vm}) \cdot sign(P_B - P_T) \cdot \sqrt{|P_B - P_T|} \end{aligned} \quad (5.7)$$

onde Q_A, P_A, Q_B, P_B são as pressões e fluxos do carretel primário nos pontos A e B , e x_{vm} é a posição do carretel principal.

5.2.2. Modelagem do Pistão Hidráulico

A equação da dinâmica do pistão foi obtida aplicando a segunda lei de Newton nas forças do pistão, logo

$$m_t \cdot \ddot{x}_p + F_f(\dot{x}_p) = A_p \cdot (P_A - \alpha \cdot P_B) - F_{ext} \quad (5.8)$$

onde m_t é massa total, constituída pela massa do pistão (m_p), e pelas massas das câmaras do cilindro e suas tubulações, dadas por $m_{A,fl}$ e $m_{B,fl}$ respectivamente, i.e.

$$m_t = m_p + m_{A,fl} + m_{B,fl} \quad (5.9)$$

A massa do fluido é determinada por

$$m_{A,fl} = \rho \cdot [V_{PL,A} + (x_{p0} + x_p) \cdot A_p] \quad (5.10)$$

$$m_{B,fl} = \rho \cdot [V_{PL,B} + (x_{p0} + x_p) \cdot \alpha \cdot A_p] \quad (5.11)$$

A massa do fluido pode ser desprezada em relação à massa do pistão. Aplicando a equação de continuidade para cada uma das câmaras do cilindro, obtém-se

$$Q_A - Q_{Li} = \dot{V}_A + \frac{\dot{V}_A}{\dot{E}(P_A)} \cdot \dot{P}_A \quad (5.12)$$

$$Q_B + Q_{Li} - Q_{Le} = \dot{V} + \frac{\dot{V}_A}{\dot{E}(P_A)} \cdot \dot{P}_A \quad (5.13)$$

onde, V_A é o volume da câmara do pistão, V_B é o volume da câmara do anel e linhas de conexão, e Q_{Li} e Q_{Le} são os fluxos de escapamento interno e externo, respectivamente.

5.2.3. Modelos lineares

Combinando os modelos dinâmicos da servo-válvula com o modelo do pistão hidráulico, podem-se obter as funções de transferência que modelam o sistema servo hidráulico, como descrito a seguir.

5.2.3.1. Função de Transferência da Posição

A função de transferência para o controle de posição é determinado pela equação

$$G_x(S) = \frac{X_p(S)}{I(S)} = \left[\frac{K_v \cdot K_Q}{\frac{1}{\omega_v^2} \cdot S^2 + \frac{2 \cdot D_v}{\omega_v} \cdot S + 1} \right] \left[\frac{\frac{A_p}{m_p}}{S^2 + 2 \cdot D_h \cdot \omega_h \cdot S + \omega_h^2} \right] \left[\frac{1}{S} \right] \quad (5.14)$$

onde ω_h é a frequência natural do sistema servo-hidráulico, a qual é determinada por

$$\omega_h = \sqrt{\frac{\sigma}{m_p \cdot T_h} + \frac{A_p}{m_p} \cdot K_d} \quad (5.15)$$

A taxa de amortecimento D_h é dada por

$$D_h = \frac{\frac{1}{T_m} + \frac{1}{T_h}}{2 \cdot \omega_h} \quad (5.16)$$

Os parâmetros T_m e K_d são determinados por

$$\begin{aligned} T_m &= \frac{m_p}{\sigma} \\ K_d &= \frac{A_p}{C_h} \end{aligned} \quad (5.17)$$

onde m_p e A_p são a massa e área do pistão, e C_h é a capacitância hidráulica.

5.2.3.2. Função de Transferência da Força

A função de transferência para o controle de força é obtida a partir da função de transferência de posição, sendo conhecida a seguinte equação:

$$P_L = \left(\frac{m_p}{A_p} + \frac{\sigma}{A_p} \cdot \frac{1}{S} \right) \quad (5.18)$$

Usando a relação $F_L = A_p \cdot P_L$, obtém-se:

$$G_F(S) = \frac{F_L(S)}{I(S)} = \left[\frac{K_v \cdot K_Q}{\frac{1}{\omega_v^2} \cdot S^2 + 2 \cdot D_v \cdot \omega_v \cdot S + 1} \right] \left[\frac{A_p \cdot \left(S + \frac{\sigma}{m_p} \right)}{S^2 + 2 \cdot D_h \cdot \omega_h \cdot S + \omega_h^2} \right] \quad (5.19)$$

onde ω_v é a frequência natural e D_v é a taxa de amortecimento, e os demais parâmetros forem definidos na Equação (5.14).

5.2.3.3. Função de Transferência da Deformação

Para controle de deformação em ensaios em corpos de prova, a rigidez da máquina deve ser muito maior que a dos corpos de prova testados. Assumindo-se que isto seja verdade, a função de transferência para o controle de deformação é dada por

$$G_F(S) = \frac{F_L(S)}{I(S)} = \left[\frac{K_v \cdot K_Q}{\frac{1}{\omega_v^2} \cdot S^2 + 2 \cdot D_v \cdot \omega_v \cdot S + 1} \right] \left[\frac{A_p \cdot \left(S + \frac{\sigma}{m_p} \right)}{S^2 + 2 \cdot D_h \cdot \omega_h \cdot S + \omega_h^2} \right] \left[\frac{1}{m_p \cdot S^2 + b \cdot S + k} \right] \quad (5.20)$$

5.3. Controle por Aprendizado Acelerado

Na etapa de modelagem de um sistema de controle ótimo, toda a informação do sistema controlado (dinâmica da planta) é conhecida e descrita deterministicamente. O controlador ótimo é então projetado baseado em diferentes técnicas matemáticas de controle robusto. No caso em que parte ou toda a informação é descrita de maneira estatística (funções de probabilidade, distribuição de densidade de probabilidade), o processo de projeto do controlador utiliza técnicas estatísticas.

No caso em que a informação *a priori* requerida é desconhecida ou parcialmente conhecida, geralmente não é possível projetar um controlador ótimo utilizando técnicas de controle clássico. Para solucionar este problema, existem dois enfoques. Um enfoque é projetar um controlador baseado somente na quantidade de informação disponível; entretanto, a informação desconhecida é ignorada ou são assumidos alguns valores conhecidos para melhorar seu desempenho. O segundo enfoque é projetar um controlador com a capacidade de estimar a informação desconhecida ao longo de sua operação, e baseado nesta informação estimada mudar a ação de controle.

O processo de aprendizagem pode ser visto como um processo de estimação ou de aproximações sucessivas de informações desconhecidas. Na presente aplicação, esta informação representa a função de controle. Esta informação desconhecida é estimada ou aprendida pelo controlador ao longo de seu funcionamento, sendo constituídas de parâmetros ou características que descrevem uma função probabilística ou determinística. A relação entre estas funções e a lei de controle geralmente é determinada pelo projetista baseado em algum critério, como por exemplo, a otimização do desempenho. Assim, à medida que o controlador armazena mais informação dos parâmetros desconhecidos, a lei de controle é atualizada, melhorando o desempenho do sistema.

Na Figura 5.3 ilustra-se um diagrama de blocos que representa um sistema de controle por aprendizado. Neste controlador, a informação estimada é representada pela variável adimensional U_H , e armazenada na memória. Esta

variável é utilizada para mudar a ação de controle, e é atualizada após cada ciclo de operação através de uma lei de aprendizado baseada nos erros medidos.




Figura 5.3. Diagrama de blocos do controle por aprendizado.

Na Figura 5.3, os valores de $U_H(k)$ e $erro(k)$ são atualizados pela chave representada, após cada ciclo, a partir dos valores $U_H(k+1)$ e $erro(k+1)$.

5.3.1. Metodologia de controle

A metodologia de controle por aprendizado acelerado (*CAL - Control for Accelerated Learning*) apresentada nesta dissertação é uma otimização da lei de controle por aprendizado desenvolvido por Alva [5], com o objetivo de obter um melhor desempenho. Este controle por aprendizado, implementado em uma máquina para ensaios de fadiga, consiste em manter uma servo-válvula trabalhando em seus limites extremos de operação, tentando sempre mantê-la completamente aberta em uma ou outra direção.

O ponto de reversão está associado ao instante no qual a servo-válvula muda de direção. Este parâmetro depende de diversos fatores, como da amplitude de carga desejada e carga média requerida, e é influenciado pelos níveis de corrente aplicada na servo-válvula, e pela zona morta causada por folgas na fixação dos corpos de prova.

Devido à dinâmica do sistema, após a reversão da servo-válvula não há uma reversão imediata do sentido de crescimento da força aplicada ao corpo de prova. Portanto, os pontos de reversão precisam ocorrer antes dos picos ou vales de força desejada. Na Figura 5.4, são apresentados exemplos de pontos de reversão.




Figura 5.4. Pontos de reversão da servo-válvula.

5.3.2. Tabelas de Aprendizado

O algoritmo de controle por aprendizado acelerado tem duas tabelas, a primeira é a tabela de aprendizado que contém os valores de U_{ij} , e a segunda é a tabela de momentum (ou gradientes) que contém os valores adimensionais de V_{ij} , definidos adiante. A tabela de aprendizado armazena valores adimensionais entre 0 e 1, que junto com outros parâmetros determina o valor de U_{ij} , o qual representa o ponto de reversão como uma fração da amplitude do carregamento.

Assim, o ponto de reversão no qual a servo-válvula irá inverter seu sentido sempre se encontra antes de um pico ou de um vale, de maneira que o pico ou vale desejado é atingido pelos efeitos da dinâmica do sistema. Exemplo, se $U_{ij} = 0.95$, então a mudança do sentido da servo-válvula será comandada quando 95% do trajeto entre o vale e o pico (ou entre o pico e o vale) tiver sido percorrido. Se este valor de U_{ij} for ótimo, então espera-se que o movimento seja revertido após percorrer os 5% restantes do trajeto, devido aos efeitos da dinâmica do sistema.

Os valores de U_{ij} determinam a fração U_{ij} , enquanto que os valores de V_{ij} permitem acelerar o processo de aprendizado. Estes dependem do valor de gama (o dobro da amplitude do carregamento) e de seu valor mínimo. Portanto, é

necessário de definir duas tabelas para U_{ij} e V_{ij} com valores iniciais de 0,5 e 0 respectivamente.

As colunas da tabela de aprendizado representam o valor de gama da magnitude física que se esteja controlando, onde gama é o dobro da amplitude desta magnitude física (que neste caso é a força, em kN). E em cada linha são representados os valores mínimos, e máximo, da mesma magnitude física, como ilustrado na Tabela 1.

		Colunas (gama)					
Linhas (mínimo)		-50	-30	-10	10	30	50
	-30	0,9810	0,9645	0,8795	0,8016	0,8742	0,9475
	-15	0,9688	0,9415	0,8425	0,8245	0,8956	0,9515
	0	0,9520	0,9230	U_{ij}	0,8526	0,9285	0,9756
	15	0,9256	0,8910	0,7489	0,9189	0,9415	0,9889
	30	0,9086	0,8723	0,6896	0,9387	0,9678	0,9915

Tabela 1. Tabela de aprendizado.

Na Tabela 1, o sinal positivo associado ao valor de gama indica que o sistema está indo de um vale para um pico, enquanto que o sinal negativo indica que o sistema está indo de um pico para um vale. Esta diferenciação é importante devido a efeitos não lineares, e.g. de zona morta. A tabela de aprendizado é representada por uma matriz de dimensão específica. Neste trabalho, assim como no trabalho de Alva, escolheu-se uma matriz de 21×21 para efeito de comparação.

Levando em consideração que o valor máximo de força lançado pela máquina de ensaio de fadiga estudada é 100 kN, a tabela de aprendizado utilizada tem seus limites de valores de gama na faixa de $[-200, 200]$ kN, enquanto que o mínimo tem seus limites de valores na faixa de $[-100, 100]$ kN.

Tabela de Aprendizado				Tabela de Momentum			Colunas (gama)				
					-50	-30	-10	10	30	50	
				-30	0.2810	0.058	-0.156	-0.0586	0.0451	0.0982	
Linhas (mínimo)		-50	-30	-10	10	30	50	.0854	-0.0958	-0.0015	0.0191
	-30	0.9810	0.9645	0.8795	0.8016	0.8742	0.9475	Vij	0.0826	0.0985	0.0656
	-15	0.9688	0.9415	0.8425	0.8245	0.8956	0.9515	.0035	-0.0919	0.1415	0.1589
	0	0.9520	0.9230	Uij	0.8526	0.9285	0.9756	.0425	0.0387	-0.0678	0.0715
	15	0.9256	0.8910	0.7489	0.9189	0.9415	0.9889				
	30	0.9086	0.8723	0.6896	0.9387	0.9678	0.9915				

Na Tabela 2, a tabela de momentum armazena valores positivos ou negativos que representam a gradiente de U_{ij} ; o conhecimento destes gradientes permite acelerar o processo de aprendizagem.

O valor de U_{ij} é calculado a partir dos valores de U_{ij} armazenados na tabela de aprendizado para cada combinação de mínimo e gama. U_{ij} (com sub-índices e m letras minúsculas) é definido como o elemento da tabela de aprendizado associado à linha i (para um valor mínimo igual a “ min_i ”) e coluna j (valor de gama associada a “ $gama_j$ ”). Assim, para um carregamento com valores de mínimo e gama que coincidam com algum valor de min_i e $gama_j$ da tabela, respectivamente, tem-se:

Por exemplo, na tabela 1, para um $min_i = 15$ e um $gama_j = -10$ o valor de U_{ij} seria 0,7489. Na tabela de momentum, o valor do gradiente correspondente a

este carregamento utilizado no processo de aprendizado também incidiria com V_{ij} .

No caso em que os valores de mínimo e gama do carregamento estejam entre dois valores discretos na tabela, e.g. $\min_i < \min < \min_{i+1}$ e $\text{gama}_j < \text{gama} < \text{gama}_{j+1}$, o valor de U_{ij} é determinado como uma interpolação dos elementos vizinhos $U_{i,j}$, $U_{i,j+1}$, $U_{i+1,j}$ e $U_{i+1,j+1}$, como ilustrado na Tabela 3.

Colunas (gama)

Linhas (mínimo)

			gama_j	gama_{j+1}		
	0.9810	0.9645	0.8795	0.8016	0.8742	0.9475
min_i	0.9688	0.9415	$U_{i,j}$	$U_{i,j+1}$	0.8956	0.9515
min_{i+1}	0.9520	0.9230	$U_{i+1,j}$	$U_{i+1,j+1}$	0.9285	0.9756
	0.9256	0.8910	0.7489	0.9189	0.9415	0.9889
	0.9086	0.8723	0.6896	0.9387	0.9678	0.9915

Tabela 3. Método de interpolação quando os valores de gama e mínimo estão entre duas células.

O valor interpolado de U_{ij} é dada pela seguinte equação,

$$U_{ij} = a + (b - a) \cdot \frac{(\text{gama} - \text{gama}_j)}{(\text{gama}_{j+1} - \text{gama}_j)} \quad (5.22)$$

onde os valores de a e b são determinados pelos elementos da vizinhança de $U_{i,j}$

$$a = U_{i,j} + (U_{i+1,j} - U_{i,j}) \cdot \frac{(\min - \min_i)}{(\min_{i+1} - \min_i)} \quad (5.23)$$

$$b = U_{i,j+1} + (U_{i+1,j+1} - U_{i,j+1}) \cdot \frac{(\min - \min_i)}{(\min_{i+1} - \min_i)} \quad (5.24)$$

As equações (5.22-5.24) permitem generalizar o cálculo de U_{ij} para qualquer tipo de carregamento. Note que o valor de U_{ij} obtido quando o sistema vai para um pico é em geral diferente do valor quando o sistema vai para um vale, devido à definição de gamas negativas.

Uma vez determinado o valor de U_{ij} , o ponto de reversão da servo-válvula é determinado por

$$Ponto_Reversão = \begin{cases} \min + U_{ij} \cdot gama & (na\ subida) \\ (\min + gama) - U_{ij} \cdot gama & (na\ descida) \end{cases} \quad (5.25)$$

Para cada um dos elementos da vizinhança de U_{ij} , é determinado na tabela de momentum seu respectivo valor do gradiente V_{ij} , bastando trocar U por V nas equações (5.22) a (5.24). O valor de V_{ij} assim obtido é utilizado no processo de aprendizado para acelerar a convergência do erro, como descrito a seguir.

5.3.4. Processo de Aprendizado

No processo de aprendizagem, são feitas atualizações dos valores de U_{ij} seguindo uma lei de aprendizado. Os valores de U_{ij} e V_{ij} são atualizados em função do erro normalizado da grandeza controlada x (que pode ser e.g., força, deformação ou deslocamento), da taxa de aprendizagem, e do termo de momentum. O erro normalizado é o erro obtido entre o pico (ou vale) desejado x_d e o pico (ou vale) atingido x , dividido pela gama obtida entre o pico (ou vale) desejado x_d e o valor de pico (ou vale) atingido na reversão anterior x' , ou seja:

$$erro = \frac{x_d - x}{x_d - x'} \quad (5.26)$$

Se o sistema for de um vale para um pico (subida), os valores de x e x_d estão perto do pico e x' terá sido um vale, portanto $x_d - x'$ se torna positivo.

Assim, se $x < x_d$ então o erro é positivo ($erro > 0$), apresentando um caso de *undershoot*, enquanto se $x > x_d$ o erro é negativo ($erro < 0$), apresentando um caso de *overshoot*.

No caso em que o sistema for de pico para vale (descida), os valores de x e x_d estão perto do vale e x' terá sido um pico, portanto $x_d - x'$ se torna negativo. Neste caso, como o carregamento está diminuindo, se $x > x_d$ o erro é positivo ($erro > 0$), um caso de *undershoot*, enquanto que se $x < x_d$ o erro é negativo ($erro < 0$), um caso de *overshoot*.

Assim, um erro positivo sempre está associado a um caso de *undershoot*, enquanto um erro negativo implica em um caso de *overshoot*, independentemente se o sistema sair de um pico ou vale. No caso de *overshoot*, é preciso que o ponto de reversão da servo-válvula seja antecipado, o que implica em diminuir os valores de U_{ij} . Por outro lado no caso de *undershoot* é preciso aumentar os valores de U_{ij} .

No caso em que o valor de gama e mínimo coincidem com os valores discretizados da tabela de aprendizado, de maneira que $U_{IJ} = U_{ij}$, é proposta a seguinte lei de aprendizado:

$$U_{IJ} := U_{IJ}(1 + \eta \cdot erro + \Omega \cdot V_{IJ}) \quad (5.27)$$

$$V_{IJ} := \eta \cdot erro + \Omega \cdot V_{IJ} \quad (5.28)$$

onde η é a taxa de aprendizado, Ω é o termo de momentum, e V_{IJ} é o valor obtido na tabela de momentum para a mesma fila e coluna nas quais foi obtido U_{IJ} na tabela de aprendizado.

O termo de momentum utilizado na lei de aprendizado é obtido em função do erro normalizado, resultando em

$$\Omega = \begin{cases} \frac{1}{1 + \exp^{-a(\text{erro} - b)}} & \text{se } \text{erro} \geq 0 \\ -\frac{1}{1 + \exp^{a(\text{erro} + b)}} & \text{erro} < 0 \end{cases} \quad (5.29)$$

onde a e b são constantes. Na Figura 5.5 mostra-se o termo de momentum em função do erro, para $a = 10$ e $b = 0,5$.




Figura 5.5. Termo de momentum em função do erro para $a = 10$ e $b = 0,5$.

Em geral, da Figura 5.4 pode-se observar que o valor do erro normalizado e do termo de momentum estão na faixa de $[-1, 1]$.

No caso em que U_{IJ} foi determinado por interpolação na tabela de aprendizado, 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, e também os valores de $V_{i,j}$, $V_{i,j+1}$, $V_{i+1,j}$, $V_{i+1,j+1}$ que aceleram o processo de aprendizado. Essas atualizações são feitas em função do grau de influência que cada célula da vizinhança tem sobre U_{IJ} . Ou seja, as células da vizinhança que estão mais próximas de U_{IJ} têm um maior grau de atualização que aquelas mais distantes. Isto é ilustrado na Figura 5.6.




Figura 5.6. Esquema do grau de influência do erro.

O erro normalizado é distribuído nas células da vizinhança de U_D de acordo como grau de influência. E.g, na Figura 5.6 o erro $e_{2,2}$ relativo à célula $U_{i+1,j+1}$ tem o maior grau de influência devido a que esta célula está mais perto de U_D . A variável γ é definida como o maior de todos os graus de influência, o que permite normalizar o grau de influência de maneira que a célula mais próxima receba um grau de atualização unitário.

$$\gamma := \max([(1-\alpha).(1-\beta), \alpha.(1-\beta), (1-\alpha).\beta, \alpha.\beta]) \quad (5.30)$$

onde

$$\alpha := \frac{\min - \min_i}{\min_{i+1} - \min_i}, \quad 0 < \alpha < 1 \quad (5.31)$$

$$\beta := \frac{\text{gama} - \text{gama}_j}{\text{gama}_{j+1} - \text{gama}_j}, \quad 0 < \beta < 1 \quad (5.32)$$

Assim, a distribuição do erro nas células da vizinhança é dada pelas equações:

$$e_{1,1} := \frac{(1-\alpha).(1-\beta)}{\gamma}.erro \quad (5.33)$$

$$e_{1,2} := \frac{\alpha.(1-\beta)}{\gamma}.erro \quad (5.34)$$

$$e_{2,1} := \frac{(1-\alpha).\beta}{\gamma}.erro \quad (5.35)$$

$$e_{2,2} := \frac{\alpha.\beta}{\gamma}.erro \quad (5.36)$$

O termo de momentum Ω é calculado em função do *erro* e para uma taxa de aprendizado η , as atualizações dos valores da tabela de momentum em função do erro distribuído em cada uma das células é dada pela seguinte lei de aprendizado.

$$V_{i,j} := \eta.e_{1,1} + \Omega.V_{i,j} \quad (5.37)$$

$$V_{i,j+1} := \eta.e_{1,2} + \Omega.V_{i,j+1} \quad (5.38)$$

$$V_{i+1,j} := \eta.e_{2,1} + \Omega.V_{i+1,j} \quad (5.39)$$

$$V_{i+1,j+1} := \eta.e_{2,2} + \Omega.V_{i+1,j+1} \quad (5.40)$$

As atualizações das células da tabela de aprendizado são então obtidas pela seguinte lei de aprendizado:

$$U_{i,j} := U_{i,j} \cdot (1 + V_{i,j}) \quad (5.41)$$

$$U_{i,j+1} := U_{i,j+1} \cdot (1 + V_{i,j+1}) \quad (5.42)$$

$$U_{i+1,j} := U_{i+1,j} \cdot (1 + V_{i+1,j}) \quad (5.43)$$

$$U_{i+1,j+1} := U_{i+1,j+1} \cdot (1 + V_{i+1,j+1}) \quad (5.44)$$

Note que o cálculo de U_{ij} pelas equações (5.22) a (5.24) pode ser reescrito em função de α e β , resultando em:

$$U_{ij} := U_{i,j} \cdot (1 - \alpha) \cdot (1 - \beta) + U_{i,j+1} \cdot (1 - \alpha) \cdot \beta + U_{i+1,j} \cdot \alpha \cdot (1 - \beta) + U_{i+1,j+1} \cdot \alpha \cdot \beta \frac{\pi}{4} \quad (5.45)$$

5.3.5. Algoritmo de Aprendizado

O fluxograma do algoritmo de controle por aprendizado acelerado representado na Figura 5.7 apresenta os passos seguidos pelo fluxograma do controle desenvolvido por Aíva[5], com a diferença que a lei utilizada para as atualizações de $U_{i,j}$ na tabela de aprendizado incluem a taxa η e o termo de momentum Ω , os quais permitem acelerar este processo.




Figura 5.7. Algoritmo de controle por aprendizado acelerado.

* 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 e o termo de momentum.

5.3.6. Resultado das simulações do Algoritmo de Controle por Aprendizado Acelerado

As simulações do controle por aprendizado acelerado proposto foram feitas no software de MATLAB®. As simulações foram aplicadas à máquina servo-hidráulica modelada anteriormente. Escolheram-se para as simulações carregamentos de amplitude constante e variáveis, e com uma taxa de aprendizado $\eta = 0.95$, obtendo bons resultados, apresentados nas Figuras 5.8 e 5.9.




Figura 5.8. Resposta do controle por aprendizado acelerado para um carregamento de amplitude constante de ± 10 kN.




Figura 5.9. Resposta do controle por aprendizado acelerado para um carregamento de amplitude constante de ± 75 kN.

Nas Figuras 5.8 e 5.9 pode-se notar que os pontos de reversão são modificados até convergir em um valor ótimo de U_{IJ} que minimiza o erro entre os valores (de pico e vales) reais e desejados. Assim, no futuro, para carregamentos de mesma amplitude, o controlador pode responder satisfatoriamente sem a necessidade de reaprendizado, desde que não haja alterações significativas no sistema. Note que para altos carregamentos desejados, como nos ± 75 kN da Figura 5.9, a forma da curva da força de saída é muito diferente da forma da curva desejada, no entanto sob o ponto de vista de ensaios de fadiga isto é irrelevante, pois somente os valores dos picos e vales atingidos é que influenciam na vida da peça.

No caso em que haja mudança nas amplitudes do carregamento, o algoritmo de aprendizado ajusta automaticamente os pontos de reversão, como é mostrado na Figura 5.10. Todos os pontos de reversão ótimos U_{IJ} obtidos ao longo do funcionamento do controlador são armazenados na tabela de aprendizado. Assim, no futuro, o sistema não tem a necessidade de reaprendizado para carregamentos que já tiverem sido apresentados anteriormente.




Figura 5.10. Resposta do controle por aprendizado acelerado para diferentes amplitudes de carregamento.

A Figura 5.11 apresenta a resposta do controle por aprendizado acelerado para carregamentos que já foram apresentados anteriormente. Pode-se notar que apresenta um ótimo desempenho desde o primeiro evento, sem a necessidade de um transiente de aprendizado.




Figura 5.11. Resposta do controle por aprendizado acelerado para carregamento já apresentados.

Na figura 5.9 e 5.11 mostra-se que força de saída (“linha verde”) apresenta uma forma curva a qual é mais notória para amplitudes grandes. Entretanto a forma da curva da força de saída não é relevante nos ensaios de fadiga (sempre que não tenha envolvido efeitos de corrosão e fluência).

Na Figura 5.12 é apresentada a comparação entre o controle por aprendizado desenvolvido por Alva [5] e o controle por aprendizado acelerado proposto nesta dissertação. O controle por aprendizado acelerado tem uma maior velocidade de aprendizagem em relação ao controle por aprendizado de Alva [5].





Figura 5. 12. Resposta para um carregamento constante de ± 25 kN: (a) Controle por aprendizado de Alva e (b) Controle por aprendizado acelerado.

Na Figura 5. 13 é apresentada a velocidade de convergência do erro normalizado do controle por aprendizado de Alva [5] (“linha vermelha”) e o erro normalizado do controle por aprendizado acelerado (“linha azul”). O controle por aprendizado acelerado tem uma rápida convergência do erro em relação ao controle por aprendizado de Alva, convergindo após 5 ciclos, enquanto que o controle por aprendizado de Alva convergiu após 12 ciclos.




Figura 5.13. Erro do controle por aprendizado de Alva e aprendizado acelerado.

No próximo capítulo será apresentado o controle por aprendizado Neuro-Fuzzy, assim como as simulações e comparações em três dos três métodos de controle descrito nesta dissertação.