

AUMENTO DA FREQUÊNCIA DE ENSAIOS DE FADIGA ATRAVÉS DE TÉCNICAS DE CONTROLE POR APRENDIZADO¹

*Juan Gerardo Castillo Alva²
Marco Antonio Meggiolaro³
Jaime Tupiassú Pinho de Castro⁴*

Resumo

Aumentar a frequência de ensaios de fadiga traz como vantagens a redução do tempo e do custo dos ensaios, sem interferir nos resultados. Para esse fim, é necessário um sistema de controle eficiente. Neste trabalho, técnicas de controle por aprendizado foram desenvolvidas e aplicadas a uma máquina de ensaios de materiais, permitindo a aplicação de carregamentos de amplitude variável em alta frequência. A metodologia usada consiste em um controle do tipo bang-bang, que trabalha sempre nos limites extremos de operação da servo-válvula, procurando mantê-la sempre completamente aberta em uma ou outra direção. O algoritmo de aprendizado obtém os instantes ótimos para as reversões. A lei de aprendizado preenche e atualiza constantemente os valores das tabelas durante a execução dos testes, melhorando a resposta do sistema a cada evento. A validação experimental é feita em uma máquina servo-hidráulica de ensaios de fadiga.

Palavras-chave: Aumento de frequência; Ensaios de fadiga; Controle por aprendizado; Sistemas servo-hidráulicos.

FREQUENCY INCREASE IN FATIGUE TESTS THROUGH LEARNING CONTROL TECHNIQUES

Abstract

Working with a material testing machine at high frequencies brings the advantages of reduction in time and cost, without significantly altering fatigue results. To achieve such frequencies, it is necessary to use an efficient control system. In this work, learning control techniques are developed and applied to a materials testing machine, allowing the application of constant or variable amplitude loads in high frequency. The proposed methodology consists of implementing a bang-bang type control, restricting the system servo-valve to always work at its extreme limits of operation, always keeping it completely open in one or the other direction. The learning algorithm tries to obtain the optimal instants for the reversions. The validation is made using a servo-hydraulic testing machine.

Key words: Frequency increase; Fatigue tests; Learning control; Servo-hydraulic systems.

¹ *Contribuição técnica ao 64º Congresso Anual da ABM, 13 a 17 de julho de 2009, Belo Horizonte, TMG, Brasil.*

² *Engenheiro Eletrônico, M.Sc., Dept. Eng. Mecânica., PUC-Rio*

³ *Engenheiro Mecânico, Ph.D., Professor Dept. Eng. Mecânica, PUC-Rio*

⁴ *Engenheiro Mecânico, Ph. D., Professor Dept. Eng. Mecânica, PUC-Rio*

1 INTRODUÇÃO

Sistemas hidráulicos são muito usados nos atuais sistemas industriais, por exemplo, nas plantas automatizadas, em robótica, simuladores de movimento, plantas de processamento de metal, exploração de minérios, prensas, sistemas de teste de fadiga de materiais, maquinaria pesada etc. Em geral eles são usados onde se requerem forças e torques relativamente altos, e alta velocidade de resposta para o início, parada e reversão da velocidade. As máquinas de testes de fadiga se baseiam em sistemas servo-hidráulicos e têm como propósito fazer ensaios nos materiais para prever a vida útil em serviço. A aplicação da carga pode ser repetida milhões de vezes, em frequências típicas de até cem vezes por segundo para metais. Para se atingirem estas frequências, relativamente altas para um teste de fadiga, é necessário um sistema de controle eficiente.

Nos métodos clássicos de controle, toda a informação *a priori* do processo é conhecida e descrita de forma determinística. Se a informação *a priori* é desconhecida, pode-se projetar um controlador que seja capaz de estimar a informação durante a operação, e a informação aprendida seria usada como uma experiência para futuras decisões de controle. Um desses sistemas de controle é conhecido como controle por aprendizado. O controle de sistemas servo-hidráulicos apresenta muitos trabalhos de pesquisa aplicados a manipuladores industriais que desempenham tarefas repetitivas. Um deles é baseado em controlador de Lyapunov, onde a lei adaptativa foi também proposta para eliminar incertezas nos parâmetros hidráulicos. É conhecido que controladores não-lineares apresentam melhor desempenho, tanto em simulações quanto em experimentos, que um controlador proporcional-derivativo.⁽¹⁾ Controladores robustos com rejeição de perturbações também foram aplicados com sucesso em sistemas servo-hidráulicos.⁽²⁾

Neste trabalho é introduzida uma lei de controle por aprendizado com o objetivo de aumentar a frequência de ensaios de fadiga. A validação é feita em uma máquina de testes servo-hidráulica, e seu desempenho é avaliado.

2 CONTROLE POR APRENDIZADO

O processo de aprendizagem pode ser visto como um problema de estimação ou aproximações sucessivas de quantidades desconhecidas ou de uma função que representa o processo de controle em estudo. No presente trabalho, as quantidades desconhecidas a serem estimadas ou aprendidas pelo controlador são parâmetros relacionados à lei de controle da máquina de testes.

A metodologia do controle por aprendizado proposta neste trabalho consiste em manter a servo-válvula da máquina de testes trabalhando em seus limites extremos de operação, tentando mantê-la todo o tempo completamente aberta em uma ou outra direção.

Devido à dinâmica do sistema, os instantes de reversão da servo-válvula devem ficar antes dos picos e vales 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 em alguns casos por folgas na fixação dos corpos de prova.

A Figura 1 apresenta um diagrama de blocos com a representação do controle por aprendizado proposto. A cada ciclo, o sistema utiliza informações armazenadas na memória de parâmetros U_{ij} , definidos na seção 2.1, para controle por realimentação. Os erros medidos a cada ciclo são utilizados para atualizar os

parâmetros U_{ij} , através de uma lei de aprendizado. Esta lei é aplicada somente ao final de cada reversão k do movimento controlado, o que é representado pela chave que atualiza os valores $U_{ij}(k)$ e erro(k) com os novos valores $U_{ij}(k+1)$ e erro($k+1$).

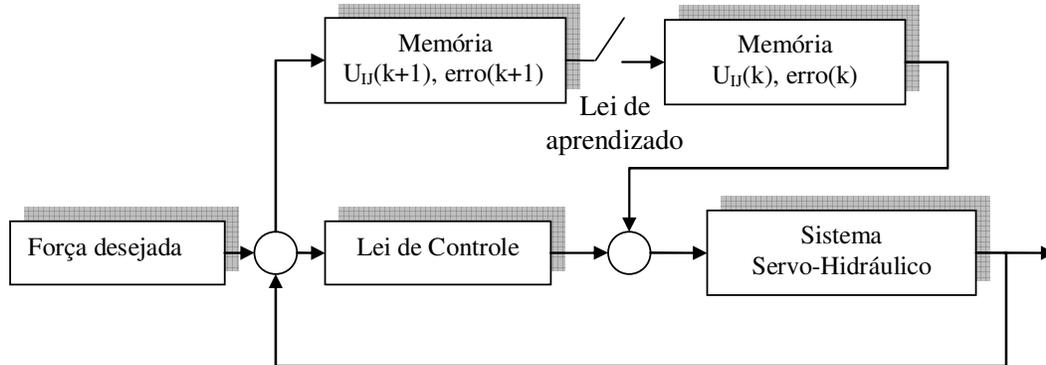


Figura 1. Diagrama de blocos do controle por aprendizado.

2.1 Tabelas de Aprendizado

As tabelas de aprendizado contêm os valores de parâmetros U_{ij} , os quais são valores adimensionais entre 0 e 1. Os valores de U_{ij} determinam o instante de reversão do sentido da servo-válvula, o qual sempre se encontra antes de um pico ou de um vale, devido ao efeito da dinâmica envolvida no sistema servo-hidráulico. U_{ij} é definido como a fração da gama do carregamento na qual a reversão da válvula será comandada. E.g., se $U_{ij} = 0,9$, isso implica que a reversão da servo-válvula será feita quando 90% do trajeto entre o vale e o pico (ou entre o pico e o vale) tiver sido percorrido. Neste exemplo, em um caso ideal, a dinâmica do sistema faria com que o sistema percorresse ainda os 10% restantes do trajeto mesmo após a reversão da servo-válvula, para só então reverter seu movimento. Observa-se experimentalmente que a fração U_{ij} depende da gama do carregamento e de seu valor mínimo. Portanto, é necessário definir uma tabela de valores U_{ij} .

A tabela de aprendizado, exemplificada na Figura 2, tem nas suas linhas o valor mínimo da grandeza física que esteja se controlando (seja ela força, deformação, deslocamento, etc.) e nas suas colunas o valor da gama da mesma grandeza física. Associa-se um sinal positivo à gama quando o carregamento é de um vale para um pico, enquanto que um sinal negativo representa uma trajetória de um pico para um vale. A matriz representada por esta tabela tem uma dimensão especificável. Para o sistema servo-hidráulico envolvido neste trabalho, escolheu-se uma matriz de 21 x 21 elementos. Tendo em consideração que o valor máximo de força gerado pela máquina de ensaios de fadiga estudada é de 100 kN, a tabela de aprendizado utilizada tem seus limites de gama e mínimo definidos ambos na faixa de -100kN a 100kN.

A tabela de aprendizado armazena de forma direta os valores de U_{ij} , para cada combinação de mínimo e gama. Por outro lado, U_{ij} (com sub-índices definidos em letras minúsculas) é definido 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 que coincida com algum min _{i} da tabela, e com gama também coincidente com algum gama _{j} , tem-se que $U_{ij} = U_{i,j}$.

		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	0,8684	0,8245	0,9005	0,9516
	-5	0,9520	0,9230	0,8456	0,8429	0,9406	0,9712
	5	0,9354	0,9081	0,7832	0,8765	0,9517	0,9804
	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 2. Tabela de Aprendizado.

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 dos elementos vizinhos $U_{i,j}$, $U_{i,j+1}$, $U_{i+1,j}$ e $U_{i+1,j+1}$ (Figura 3).

		Colunas (Gama)				
			gama _j	gama _{j+1}		
Linhas (mínimo)		0,8585	0,8364	0,8154	0,9314	0,9650
	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	0,9815	0,9934

Figura 3. Procedimento de interpolação quando os valores de gama e mínimo estão entre duas células.

Desse modo, o valor interpolado de U_{ij} é calculado por

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

Onde os valores de a e b são:

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

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

Todas estas equações apresentadas anteriormente podem ser generalizadas para qualquer tipo de carregamento. Uma vez calculado o valor de U_{ij} , pode-se calcular o ponto de reversão da servo-válvula por

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

2.2 Lei de Aprendizado

A lei de aprendizado é a que governa a atualização dos valores U_{ij} para um instante seguinte em relação ao valor atual. O valor de U_{ij} é atualizado em função do erro entre o pico (ou vale) atingido 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

$$erro = \frac{x_d - x}{x_d - x'}$$

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

Por outro lado, se x e x_d forem vales, x' terá sido um pico, e portanto $x_d - x'$ será negativo. No caso de *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 em uma subida (de vale para pico) ou descida (de pico para vale). Claramente, se houver *overshoot* então é preciso reverter a válvula mais cedo, o que implica em diminuir a fração U_{ij} ; por outro lado, no caso de *undershoot* precisamos aumentar U_{ij} .

Mesmo super-estimando U_{ij} , utilizando estimativas iniciais iguais a 1.0 para os valores de U_{ij} a serem populados inicialmente na tabela de aprendizado, observa-se em simulações e experimentos que não ocorre *overshoot* acima de 100%. Desse modo, pode-se assumir que sempre $-1 < erro < 1$, e assim pode-se propor a lei de aprendizado

$$U_{ij} := U_{ij} \cdot (1 + erro)$$

Esta lei não necessita de ganhos ajustáveis, e reproduz corretamente a necessidade do aumento de U_{ij} em casos de *undershoot* (erro > 0) e de sua diminuição em casos de *overshoot* (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_{ij} tiver sido originalmente obtido por interpolação na tabela de aprendizado, então é preciso atualizar os valores de U_{ij} , $U_{i,j+1}$, $U_{i+1,j}$ e $U_{i+1,j+1}$ que o geraram. Essa atualização também é feita de forma ponderada, i.e., as células vizinhas mais próximas de U_{ij} serão atualizadas em um maior grau que aquelas mais distantes. Isto é facilmente implementável com as equações

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

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

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

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

onde α e β são definidos por

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

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

Note que a equação de interpolação apresentada na seção 2.1 em função de a e b pode ser re-escrita em função de α e β , resultando em

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

3 SIMULAÇÕES

As simulações do sistema foram implementadas no *software* MATLAB. A modelagem do sistema foi desenvolvida a partir de modelos do comportamento do fluido hidráulico^(3,4) e das servo-válvulas.⁽⁵⁾ O simulador foi validado através da comparação de seus resultados com os de outras simulações apresentadas na literatura⁽⁶⁻¹⁰⁾.

A metodologia de controle por aprendizado proposta foi então implementada no simulador. Escolheram-se para as simulações carregamentos de amplitudes constantes e variáveis. As Figuras 4 a 6 mostram que o controlador é capaz de aprender o instante ótimo de reversão da servo-válvula, representado pelos símbolos “x” nos gráficos. Note-se que os picos e vales dos valores de saída inicialmente possuem grandes erros em relação aos picos e vales desejados, no entanto o controle por aprendizado é capaz de eliminar estes erros após cerca de 7 ciclos ao ajustar os valores de U_{ij} , tanto para amplitude constante quanto variável.

Excluído: .

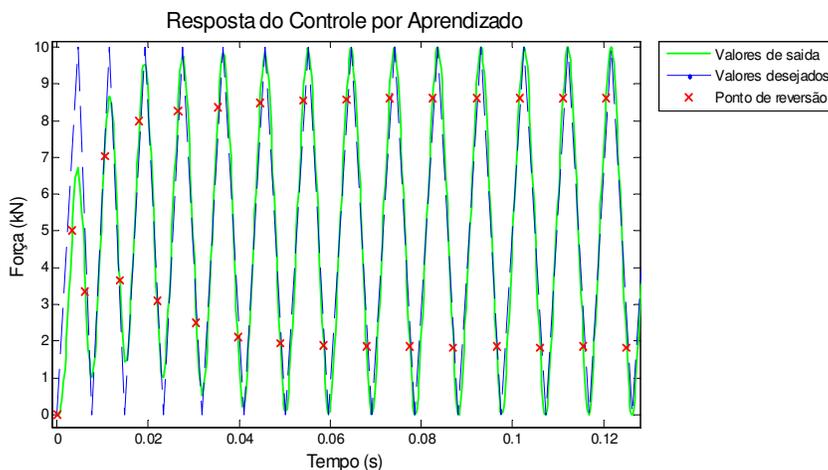


Figura 4. Resposta do controle por aprendizado para uma entrada de amplitude constante.

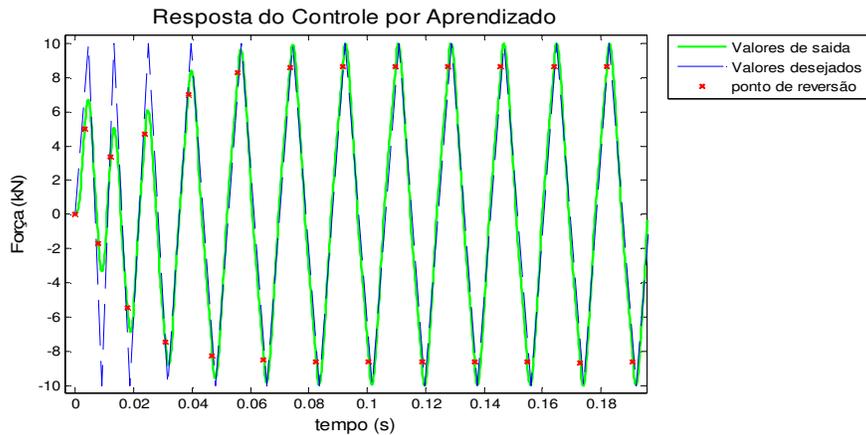


Figura 5. Resposta do controle por aprendizado para uma entrada de 20 kN de amplitude.

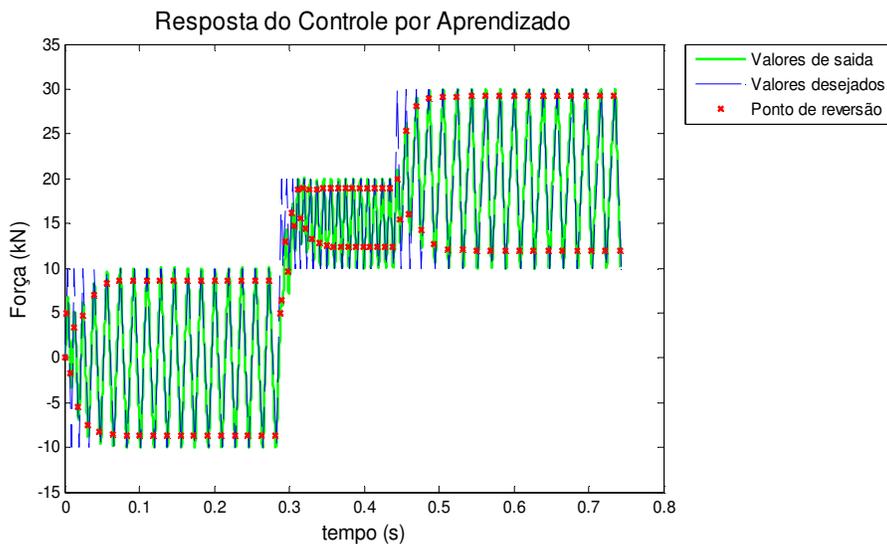


Figura 6. Resposta do controle por aprendizado para uma entrada de amplitude variável.

4 EXPERIMENTOS

A metodologia proposta foi aplicada a uma máquina de ensaios de fadiga, INSTRON modelo 8501, que possui uma servo-válvula MOOG modelo D562 com uma sinal de comando de corrente de ± 40 mA. A máquina possui um pistão com capacidade de gerar 100 kN de força, e que pode se deslocar a partir de uma posição central por ± 50 mm. O sistema também possui um LVDT para medir o deslocamento do pistão, e uma célula de carga para medir a força gerada pelo pistão, aplicada ao corpo de prova. Para medir deformações no corpo de prova, é utilizado um clip gage. O fluido hidráulico é fornecido por uma bomba hidráulica a uma pressão de 190 bar.

Para o desenvolvimento do sistema de controle por aprendizado, utilizou-se um sistema computacional em tempo real CompactRIO, da National Instruments, o qual possui módulos de entradas analógicas, saídas analógicas, e um módulo excitador de extensômetros. O sistema experimental encontra-se esquematizado na Figura 7.

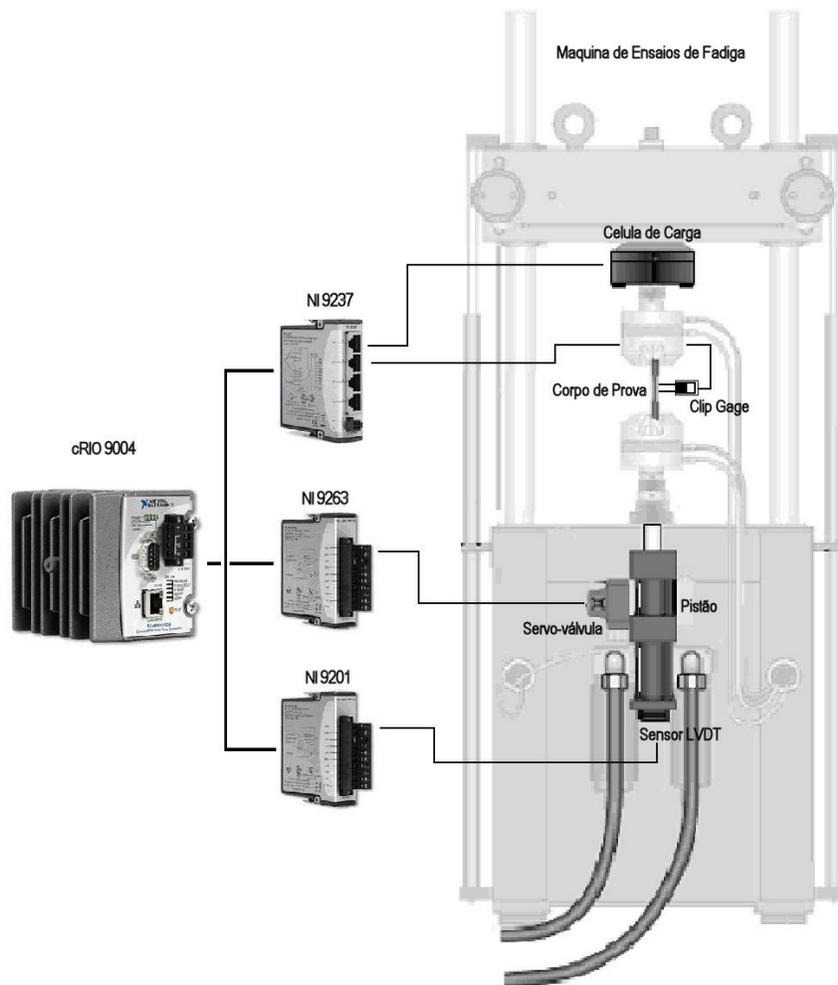


Figura 7. Sistema experimental.

Foram feitos ensaios de amplitudes 10 kN, 20 kN, 30 kN e 40 kN, todos eles utilizando correntes de $\pm 20\text{mA}$ na servo-válvula, com os instantes das reversões entre $+20\text{mA}$ e -20mA definidos pela lei de controle proposta. Os testes foram feitos com ciclos de carregamentos de amplitude constantes, em corpos de prova ϵN de aço com 12mm de diâmetro. O sistema de medição registrou um overshoot máximo de 7% em regime após o término do aprendizado.

Na Figura 8 observa-se o desempenho do controle por aprendizado para testes controlados por carga, e compara-se com o desempenho do controlador padrão da máquina para diversas amplitudes de carga. Uma vez que os ensaios de fadiga são praticamente independentes da frequência, quanto maior for seu valor melhor será o desempenho da máquina de testes, minimizando o tempo total envolvido. No entanto, frequências muito altas podem gerar erros na amplitude de força aplicada aos corpos de prova. Nesse trabalho, o desempenho é medido pela máxima frequência obtível que garanta erros máximos de amplitude de força abaixo de 7%, como representado na Figura 8.

Excluído: ¶

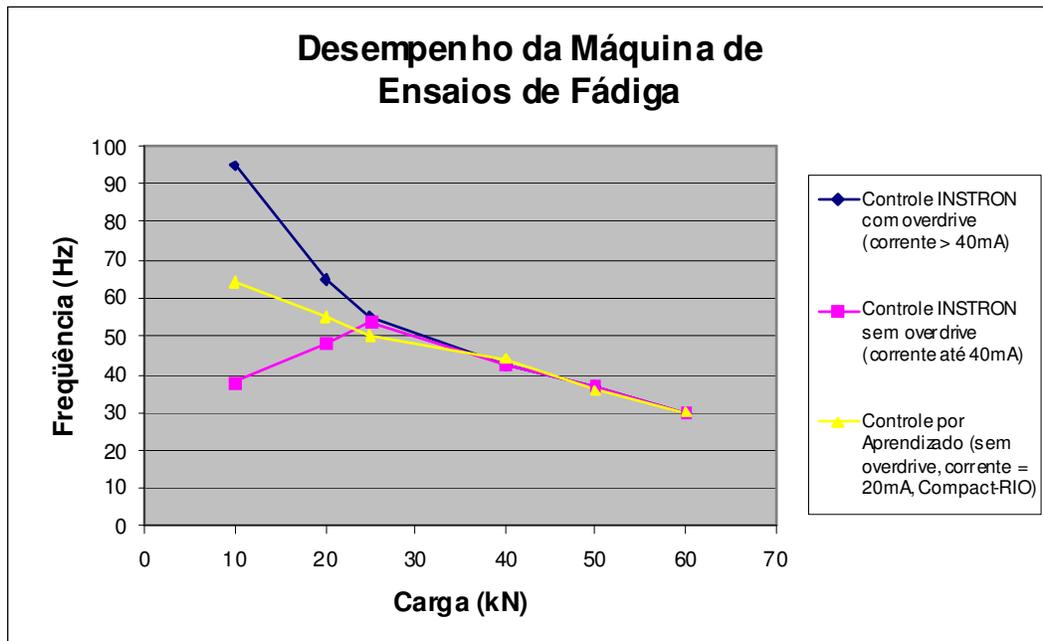


Figura 8. Comparação do desempenho do controle por aprendizado proposto com o do controlador padrão da INSTRON.

Observa-se da Figura 8 um melhor desempenho do controle por aprendizado, atingindo frequências mais altas, para baixas amplitudes de carga, e um desempenho igual ou similar para altas amplitudes, quando comparado ao controlador padrão limitado a $\pm 40\text{mA}$. Cabe lembrar que os testes do controle por aprendizado foram feitos com apenas $\pm 20\text{mA}$ de corrente, e mesmo assim obteve melhores ou iguais resultados que os do controlador padrão, que utilizou correntes até duas vezes maiores. Espera-se que com a mesma corrente de $\pm 40\text{mA}$ se obtenham resultados ainda melhores do controle por aprendizado proposto. A figura mostra também os resultados do controlador padrão com *overdrive*, ou seja, permitindo o uso de correntes maiores que 40mA (em módulo), apresentando melhores resultados que o controle por aprendizado limitado a $\pm 20\text{mA}$ apenas para baixas amplitudes de carga.

5 CONCLUSÃO

Neste trabalho, foi possível obter um aumento da frequência de trabalho de uma máquina servo-hidráulica de testes mediante técnicas de aprendizado. Tanto o controle quanto a lei de aprendizado propostos não necessitam de ganhos ajustáveis, simplificando sua implementação. O controle proposto foi simulado e aplicado a uma máquina de ensaios de fadiga, implementando-se o controlador em um sistema computacional CompactRIO. Os resultados mostraram que o controle proposto é capaz de gerar frequências mais altas que as do controlador original, utilizando correntes mais baixas para o acionamento da servo-válvula.

REFERÊNCIAS

- 1 JELALI, M.; KROLL, A. Hydraulic servo-systems: modeling, identification and control. New York. Springer, p. 10-126, 2003.
- 2 CHING LU, H.; WEN CHEN L. Robust Controller with Disturbance Rejection for Hydraulic Servo Systems. IEEE Transactions on Industrial Electronics, 40, 1993, pp. 152-162.
- 3 MERRITT, H.E. Hydraulic Control Systems. John Wiley and Sons, 1967.
- 4 VIERSMA, T.J. Analysis, Synthesis and Design of Hydraulic Servosystems and Pipelines. Elsevier.
- 5 THAYER W.J. Transfer Functions for MOOG Servovalves. Technical Bulletin. New York. USA, 1965.
- 6 SIROUSPOUR, M., SALCUDEAN S. On the Nonlinear Control of Hydraulic Servo-Systems. IEEE International Conference on Robotics and Automation, San Francisco, 2000.
- 7 DOEBELIN, E.O. System Dynamics: System Modeling and response. Prentice Hall, 1976.
- 8 SUN, H.; CHIU, G. Nonlinear Observer Based Force Control of Electro Hydraulic Actuators. American Control Conference. San Diego, EUA, 1999.
- 9 O' BRIEN, R.T., Bang Bang Control for Type-2 Systems. 38th Southeastern Symposium System Theory. Tennessee, EUA, 2006.
- 10 KING-SUN, F. Learning Control System. IEEE Transactions on Automatic Control. p.210 – 221, 1970.