



Universidade Federal de São João del-Rei
Departamento de Engenharia Elétrica
Coordenadoria do Curso de Engenharia Elétrica

**IDENTIFICAÇÃO DE SISTEMAS COM APOIO DE SISTEMA
EMBARCADO**

SAMUEL CARLOS PESSOA OLIVEIRA

Orientador: Samir Ângelo Milani Martins

São João del-Rei/MG

Janeiro de 2023

AGRADECIMENTOS

À Juliana Isabelita Cyrino Pessoa, minha prima, que me incentivou a prosseguir os estudos mesmo com sua saúde demasiadamente debilitada, me mostrando que mesmo com as piores enfermidades ainda é possível seguir em frente.

À Silezia Doralice Pessoa Ramos, minha tia, que mesmo não estando mais entre nós, foi uma das pessoas que mais me incentivou a nunca parar de estudar.

Ao professor Samir Angelo Milani Martins que me apoiou durante todo o tempo de curso, não somente agindo como um orientador acadêmico, mas também como um grande amigo que me deu suporte mesmo nos momentos mais difíceis.

Agradecimentos especiais aos meus pais que sempre estiveram ao meu lado, me dando todo o apoio necessário mesmo nos momentos mais difíceis.

SUMÁRIO

1 INTRODUÇÃO	5
2 CONCEITOS PRELIMINARES	7
2.1 IDENTIFICAÇÃO DE SISTEMAS	7
2.1.1 TESTES DINÂMICOS E COLETA DE DADOS	7
2.1.2 ESCOLHA DA REPRESENTAÇÃO MATEMÁTICA	8
2.1.3 DETERMINAÇÃO DA ESTRUTURA	9
2.1.3.1 TAXA DE REDUÇÃO DE ERRO	9
2.1.3.2 CRITÉRIO DE INFORMAÇÃO	10
2.1.4 ESTIMAÇÃO DE PARÂMETROS	11
2.1.5 SIMULAÇÃO E VALIDAÇÃO DO MODELO	11
2.2 HARDWARE	12
3 METODOLOGIA	13
3.1 GERADOR DO SINAL DE EXCITAÇÃO	13
3.2 COMUNICAÇÃO <i>RASPBERRY PI</i> COM O <i>ARDUINO</i>	14
3.3 EXECUÇÃO DO TESTE E COLETA DE DADOS	15
3.4 COMUNICAÇÃO <i>ARDUINO</i> COM O <i>RASPBERRY PI</i>	15
3.5 IDENTIFICAÇÃO DO SISTEMA	16
3.6 MONTAGEM FÍSICA DA INTERFACE COM O SISTEMA	16
3.7 SISTEMAS DE TESTE	17
3.8 ESTIMAÇÃO DA INDUTÂNCIA DOS CIRCUITOS TESTE RLC	17
3.9 DETERMINAÇÃO DA TAXA DE AMOSTRAGEM	19
4 RESULTADOS	20
4.1 COMPARAÇÃO DAS TOPOLOGIAS DO ALGORITMO DE GERAÇÃO DO PRBS	21
4.2 DETERMINAÇÃO DA INDUTÂNCIA POR MEIO DO CIRCUITO TANQUE	21
4.3 CIRCUITO RC	22
4.4 CIRCUITO RLC SUPERAMORTECIDO	25
4.5 CIRCUITO RLC SUBAMORTECIDO	27
5 CONCLUSÃO	31

6 PROPOSTAS DE TRABALHOS FUTUROS	33
REFERÊNCIAS	34

RESUMO

A identificação de sistemas é uma área do controle que visa obter modelos matemáticos a partir de dados de entrada e saída coletados de algum sistema. Estes modelos podem ser utilizados em uma ampla gama de áreas que vão desde áreas da engenharia como sensoreamento ou controle por modelos, indo até aplicações em análises de mercado. Porém, mesmo sendo bastante funcionais, as técnicas de cada etapa da identificação de sistemas ainda precisam ser aplicadas de forma manual para cada problema abordado. No atual trabalho foi desenvolvido um equipamento que, de forma automatizada, efetua a excitação do sistema estudado, coleta os dados e efetua a identificação do sistema retornando um modelo NARX polinomial. Este equipamento foi implementado em um *Raspberry PI* em conjunto a um *Arduino Nano* para torná-lo portátil e foi testado em três circuitos com comportamento já conhecido, um circuito RC e dois RLC, a fim de verificar sua capacidade de gerar os modelos matemáticos adequados. Desta forma, foram obtidos modelos com grande capacidade de representar os sistemas estudados, com a métrica RRSE variando de 0,0686 a 0,0089. Contudo, mesmo o modelo representando bem os dados de todos os sistemas, no caso do circuito RLC subamortecido houve saturação na amostragem do sinal, evidenciando assim uma fragilidade crítica no projeto.

Palavras-chave: Sistema embarcado. NARX polinomial. Modelagem. Identificação de Sistemas. Arduino. Raspberry PI.

1 INTRODUÇÃO

Modelos são representações de sistemas, ou seja, objetos, processos ou eventos, que possibilitam o entendimento e previsão de comportamentos deste sistema por meio de simplificações do sistema real. Portanto, uma característica fundamental, de modelos é o fato de sempre existir um erro associado à predição justamente por se tratar de uma simplificação do sistema estudado.

A criação de modelos é uma tarefa inerente das atividades humanas, sejam estes modelos descritos por linguagens matemáticas, como os modelos de circuitos elétricos, ou os modelos mentais, como a atividade de dirigir um carro, que exige que o motorista mentalize a resposta do veículo a cada comando antes que este seja executado [Aguirre, 2015].

Modelos matemáticos podem ser utilizados em diversas áreas da engenharia como simulações de sistemas durante fases de projeto, sistemas de controle, programação de manutenção preditiva e inclusive como redundância virtual de sensores físicos. No contexto da engenharia elétrica o estudo das técnicas de modelagem, particularmente de sistemas dinâmicos, recebe o nome de identificação de sistemas.

Estes modelos matemáticos podem ser separados em três grupos principais: Modelos caixa branca, com a física dos processos conhecida e portanto sua representação se dá por formas matemáticas já estabelecidas; modelos caixa preta, no qual a física do sistema é desconhecida ou demasiadamente complexa para ser representada [Juditsky et al., 1995]; modelos caixa cinza, com a física do processo parcialmente conhecida a priori e é utilizada como elemento auxiliar para melhoria da qualidade do modelo final [Babuška e Verbruggen, 2003, Vizer et al., 2013], podendo reduzir o custo computacional para obtenção ou mesmo reduzindo o erro do modelo.

Particularmente os modelos caixa preta são de grande interesse prático, pois dependem apenas dos dados de entrada e saída do sistema, independente da natureza ou complexidade dos processos envolvidos. Este tipo de modelo é versátil ao ponto de ser empregado em uma grande variedade de problemas, desde aplicações de engenharia, como sensoriamento, planejamento de manutenção preditiva e otimização de processos, sistemas de controle por modelo [Montestruque e Antsaklis, 2003, Souza et al., 2016], até mesmo problemas econômicos, de negócio ou de detecção de comportamentos humanos, como aplicações no mercado financeiro, precificação de produtos ou mesmo detecção de potenciais clientes

[Guidotti et al., 2019, Polifke, 2014].

Dada a importância da modelagem de sistemas do tipo caixa preta, no atual trabalho é proposto o desenvolvimento de um equipamento portátil composto de hardware e software capaz de injetar um sinal conhecido em um sistema físico e coletar o sinal gerado pelo sistema para assim efetuar a modelagem deste sistema em um modelo do tipo caixa preta.

Sistemas físicos são naturalmente contínuos, contudo, para que estes possam ser modelados por sistemas digitais é necessário que sejam efetuadas amostragens em períodos fixos, e conhecidos, de tempo, tornando assim o modelo matemático discreto [Golnaraghi, 2009].

Dentre os modelos possíveis de serem utilizados, escolheu-se utilizar o modelo NARX polinomial, que consiste em um polinômio discreto não linear e auto regressivo por sua simplicidade aliada à sua capacidade de representar sistemas altamente complexos [Billings, 2013].

A simplicidade deste tipo de modelo decorre de características como sua linearidade nos parâmetros, o que permite a utilização de técnicas simples e eficientes de estimação de parâmetros como o método dos mínimos quadrados, assim como sua estrutura pode ser determinada com técnicas determinísticas como a taxa de redução de erro associada a um critério de informação [Aguirre, 2015].

A interface entre a unidade de processamento e o sistema físico foi prototipada utilizando-se um *Arduino Nano*, que tanto fornece o sinal de excitação do sistema, por meio de uma saída digital, quanto coleta o sinal de saída do sistema por meio de uma de seus conversores analógico-digital (ADC). Como sistemas de teste foram adotados um circuito RC e dois circuitos RLC, um subamortecido e outro superamortecido.

Como unidade de processamento, foi adotado um *Raspberry PI* executando um script em *Python* que cria um sinal de excitação binário que pode ser uma onda quadrada, um sinal de período aleatório em uma distribuição uniforme ou um sinal do tipo PRBS (do inglês *Pseudo Random Binary Signal*) a ser executado no *arduino*. A comunicação entre a unidade de processamento e a interface com o sistema foi feita por meio de porta serial e o modelo gerado pelo script é exibido em prompt de comando.

2 CONCEITOS PRELIMINARES

O atual trabalho se suporta em dois pilares, a identificação de sistemas, que dá a base do software implementado e possibilita a determinação do modelo, e o hardware que executa o algoritmo e faz a interface com o sistema testado injetando o sinal de excitação e amostrando o sinal de resposta.

2.1 IDENTIFICAÇÃO DE SISTEMAS

A identificação de sistemas é uma área do controle que busca representar sistemas a partir de modelos matemáticos. Para que estes sejam construídos, deve-se adotar a sequência lógica de ações:

1. Testes dinâmicos e coleta de dados
2. Escolha da representação matemática
3. Determinação da estrutura
4. Estimação dos parâmetros
5. Simulação e validação do modelo

2.1.1 TESTES DINÂMICOS E COLETA DE DADOS

Nesta etapa o sistema físico é excitado com sinais conhecidos e que possibilitem que este se mantenha no comportamento desejado. Como, por exemplo, mantendo um sistema constantemente em seu regime de resposta dinâmica.

Além da forma do sinal de excitação, também deve ser definida a taxa de amostragem, ou seja, o intervalo de tempo entre a tomada de cada amostra, e conseqüentemente a taxa na qual os sinais de excitação são enviados para o sistema. Esta etapa deve ser executada de forma criteriosa já que altas taxas de amostragem causarão uma grande contaminação do sinal por ruídos, que representam desvios dos dados do sistema, gerados por fatores estocásticos, enquanto baixas taxas de amostragem causarão perda de informação.

A rigor, caso as características de energia, entropia e largura de banda do sinal de resposta do sistema fossem conhecidas, a taxa de amostragem poderia ser obtida analiticamente [Shannon, 1949].

Contudo, como estas informações raramente são conhecidas em sistemas reais, a taxa de amostragem pode ser obtida empiricamente pelo teorema de Nyquist-Shannon com uma taxa de amostragem de pelo menos 2 vezes superior à maior frequência do sistema [Shannon, 2001].

Caso exista dificuldade em se obter a taxa de amostragem adequada de forma empírica por conta de alta contaminação do sinal por ruído, pode-se efetuar a amostragem com a maior taxa possível e então decimar o sinal obtido por uma análise da autocovariância do sinal de saída. O fator de decimação Δ é um valor inteiro no intervalo dado pela equação 2.1.

$$\frac{\tau}{20} \leq \Delta \leq \frac{\tau}{10} \quad (2.1)$$

Sendo τ o atraso no sinal onde ocorre o primeiro mínimo local na autocovariância do sinal de saída [Aguirre, 2015].

2.1.2 ESCOLHA DA REPRESENTAÇÃO MATEMÁTICA

Nesta etapa é definido a representação matemática na qual o modelo será construído. No atual trabalho escolheu-se o modelo NARX Polinomial (sigla do inglês *Nonlinear AutoRegressive with eXogenous input*), um modelo polinomial discreto dependente das entradas exógenas, ou seja, variáveis independentes, e dos valores passados de saída do modelo [Billings, 2013], na forma como mostrado na equação 2.2.

$$y(k) = F^\ell [y(k-1), \dots, y(k-n_y), u(k-1), \dots, u(k-n_u)] + \Xi(k) \quad (2.2)$$

Com F^ℓ representando um polinômio, de grau que será determinado em etapas futuras do processo, linear nos parâmetros, $y(k-n)$ e $u(k-n)$ o valor da saída e da entrada, respectivamente, n instantes passados e que apresenta um erro de predição Ξ com os termos que compõem o polinômio denominados regressores.

2.1.3 DETERMINAÇÃO DA ESTRUTURA

Nesta etapa são determinados quais regressores poderão compor o modelo. Como o atual trabalho utiliza modelos NARX polinomiais, esta etapa será executada por meio da técnica da taxa de redução de erro para classificar os regressores por ordem de importância para a representação, e, por meio de um critério de informação, quantos destes regressores serão empregados.

2.1.3.1 TAXA DE REDUÇÃO DE ERRO

A taxa de redução de erro, cuja sigla é ERR (do inglês *Error Reduction Ratio*), é uma técnica de classificação de relevância dos regressores baseada em análise de resíduos proposta por Korenberg em 1988 [Korenberg et al., 1988].

Para que esta técnica seja aplicada, a matriz de regressores deve ser ortogonal e calculada um passo à frente ($w_i(k-1)$), ou seja, valores de saída medidos são utilizados para construção desta matriz, em suas colunas a fim de isolar a contribuição de cada regressor para o modelo.

Este modelo modificado é representado então como na forma 2.3 com n_θ^* representando o espaço de busca dos regressores, \hat{g} o vetor de parâmetros dos regressores ortogonalizados e ξ o erro de predição deste modelo.

$$y(k) = \left(\sum_{i=1}^{n_\theta^*} \hat{g}_i w_i(k-1) \right) + \xi(k) \quad (2.3)$$

Desta forma, o ERR do i -ésimo regressor (ERR_i) pode ser calculado pela equação 2.4.

$$ERR_i = \frac{\hat{g}_i^2 \langle \mathbf{w}_i, \mathbf{w}_i \rangle}{\langle \mathbf{y}, \mathbf{y} \rangle} \quad (2.4)$$

Considerando-se que a matriz de regressores composta por w_i é ortogonal, o produto interno de $\langle w_i, w_j \rangle = 0, \forall i \neq j$ e assim o ERR_i se torna uma métrica que mede a representatividade do i -ésimo regressor no modelo.

2.1.3.2 CRITÉRIO DE INFORMAÇÃO

Quando se define os regressores que podem representar um sistema, pode ocorrer de nem todos estes regressores serem suficientemente representativos, assim como alguns podem ser espúrios, levando o modelo à instabilidade e, conseqüentemente, deixando de representar o sistema estudado.

Para solucionar tal problema pode-se aplicar um critério de informação, que consiste em uma medida da função de verossimilhança penalizada pela complexidade do modelo [Akaike, 1998] e portanto esta métrica, que apresenta a forma $J^* = CP - 2 \cdot LH$, com LH sendo a função de verossimilhança e CP a função de penalização por complexidade do modelo. Desta forma o objetivo neste critério de informação é maximizar J^* .

No caso dos modelos NARX polinomiais, a função de verossimilhança pode ser estimada com o resíduo de predição um passo à frente assumindo a forma da equação 2.5, sendo N o número de amostras, $\sigma_{erro}^2(n_\Theta)$ a variância do resíduo de predição um passo à frente e $CP(n_\theta)$ a função de complexidade do modelo com n_θ graus de liberdade, ou seja, n_θ parâmetros.

$$J = N \cdot \ln[\sigma_{erro}^2(n_\Theta)] + CP(n_\theta) \quad (2.5)$$

Dentre as funções de penalização por complexidade a literatura lista algumas mais usadas, que podem ser escolhidas de acordo com a necessidade [Mendez e Billings, 2001]:

1. $CP(n_\theta) = 2 \cdot n_\theta$ - O critério de informação originalmente proposto por Akaike [Akaike, 1974].
2. $CP(n_\theta) = \ln(N) \cdot n_\theta$ - O critério de informação de Bayes [Schwarz, 1978].
3. $CP(n_\theta) = N \cdot \ln\left(\frac{N+n_\theta}{N-n_\theta}\right)$ - O erro final de predição (FPE) [Akaike, 1974].
4. $CP(n_\theta) = 2 \cdot \ln(\ln(N)) \cdot n_\theta$ - A lei de Khundrin do logaritmo iterado [Hannan e Quinn, 1979].

Nesta forma, o modelo mais representativo do sistema seria o modelo que minimizasse o critério de informação J , contudo, como esta função possui como domínio o resíduo de predição um passo à frente, existe uma grande possibilidade de incluir regressores espúrios ao modelo quando executada a simulação livre e, portanto, adota-se n_θ onde o critério de informação forma o primeiro ponto de "joelho" no gráfico, ou seja, quando a variação do valor do critério

de informação no próximo valor de n_θ seja irrisório em relação ao valor no atual valor de n_θ [Satopaa et al., 2011].

2.1.4 ESTIMAÇÃO DE PARÂMETROS

Com a estrutura do modelo determinada, é necessário calcular o valor dos parâmetros do modelo. Devido ao fato do modelo NARX Polinomial ser linear nos parâmetros, é possível utilizar a técnica dos mínimos quadrados [Aguirre, 2015].

Partindo-se de um modelo linear nos parâmetros na forma $\mathbf{y} = \mathbf{X}\Theta + \xi$, com a matriz de regressores \mathbf{X} , ξ o erro de predição, que será omitido por ser desconhecido à priori, pode-se obter o vetor de parâmetros Θ por meio da relação 2.6 [Korenberg et al., 1988].

$$\hat{\Theta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y} \quad (2.6)$$

Por esta relação pode-se perceber que a matriz $(\mathbf{X}^T \mathbf{X})$, chamada matriz de informação, deve ser não singular para que o método seja aplicável.

2.1.5 SIMULAÇÃO E VALIDAÇÃO DO MODELO

A validação de um modelo representa aplicar valores de entrada à este para verificar se existe uma resposta adequada ao sistema [Billings, 2013]. Para efetuar esta verificação, compara-se os valores obtidos na simulação do modelo com valores já medidos no sistema e que não foram utilizados no processo da modelagem.

Para efetuar esta comparação é necessário aplicar uma métrica que seja capaz de mensurar a representatividade do modelo obtido, assim, uma métrica bastante eficiente para esta finalidade é o RRSE (do inglês *Relative Root Squared Error*), dado pela equação 2.7, com y_v representando os valores do sinal medido, \hat{y} os valores obtidos pelo modelo e \bar{y}_v o valor médio do sinal medido.

$$RRSE = \frac{\sqrt{\sum_{k=1}^N (y_v(k) - \hat{y}(k))^2}}{\sqrt{\sum_{k=1}^N (y_v(k) - \bar{y}_v)^2}} \quad (2.7)$$

Assim, o erro de predição é comparado ao erro em relação à média dos valores e, desta forma, caso o valor do RRSE seja inferior a 1, o modelo representa o sistema melhor que uma

reta média dos valores de saída e, portanto, em um primeiro momento, quanto mais próximo à zero, melhor é essa representação.

Porém, em aplicações reais, esta métrica deve ser usada com cautela, já que, valores demasiadamente próximos à zero significam que o modelo possa estar representando ruídos, efeito este indesejado e parte de um efeito denominado sobreajuste (*overfit*), o que indica que o modelo perde capacidade de predição conforme os dados de entrada se tornam distantes dos dados utilizados para determinar a estrutura e estimar os parâmetros.

Para detectar este efeito, portanto, utiliza-se a técnica de análise de correlação dos resíduos de predição. Caso os resíduos de predição estejam correlacionados com as entradas ou, caso o resíduo de predição esteja altamente autocorrelacionado, estes são fatores indicativos do efeito de sobreajuste.

2.2 HARDWARE

Para geração do sinal de excitação e coleta do sinal de resposta do sistema é necessário um equipamento capaz de chavear uma tensão conhecida para gerar o sinal de excitação e possuir um conversor analógico-digital para interpretar os dados gerados pelo sistema.

Um hardware capaz de efetuar estas funções é o *Arduino Nano*, que consiste em um microcontrolador que possui tanto saídas digitais capazes de chavear tensões de $5V$ e também possui um conversor analógico-digital de 10-bits de resolução com uma faixa de leitura de $0V$ a $5V$ caso não seja fornecida uma tensão de referência.

Porém, mesmo sendo capaz de efetuar tanto a excitação quanto a coleta de dados, este equipamento não possui poder de processamento suficiente para executar todo o algoritmo de identificação de sistemas, o que significa que outro equipamento deve ser usado se comunicando com o *Arduino* para efetuar a identificação do sistema analisado. Esta unidade de processamento pode ser, a priori, qualquer sistema microprocessado, inclusive um *raspberry PI*, que possui um processador ARM capaz de executar os algoritmos necessários.

Outra limitação do *arduino* é seu conversor analógico-digital que, com o clock padrão do cristal instalado na placa, atinge apenas taxas de amostragem de no máximo $4kHz$ [Cooperation, 2015], o que limita os sistemas físicos que podem ser analisados a no máximo sistemas que possuam a maior componente de frequência em até $2kHz$.

3 METODOLOGIA

Devido às limitações de poder computacional do *Arduino*, o algoritmo de identificação foi implementado em um *Raspberry PI 3 B+*. Esta implementação iniciou-se com a implementação, em python, de uma função capaz de codificar os sinais de excitação, seguido da implementação dos algoritmos de comunicação serial para se comunicar com o *Arduino* e, por fim, o algoritmo de identificação de sistemas.

Do processo de identificação de sistemas, a determinação da taxa de amostragem ocorre fornecendo-se o valor do *delay* entre cada mudança de estado.

3.1 GERADOR DO SINAL DE EXCITAÇÃO

Para a geração dos sinais foi implementado um *iterator* para cada forma de excitação que é chamado em um *list comprehension* um número de vezes referente à quantidade de amostras a serem geradas, retornando assim um *array* com a sequência de estados que deverão ser aplicados à entrada do sistema.

Para o caso do sinal quadrado, o *iterator* retorna Verdadeiro ou Falso de acordo com o último estado, permutando a cada chamada. Para o caso do sinal aleatório em distribuição uniforme, o *iterator* retorna um estado escolhido aleatoriamente de acordo com a função *random.choice*, função esta *built-in* do python.

Por fim, para o caso do gerador de sinal PRBS (do inglês *Pseudo Random Binary Signal*), sinal este capaz de manter o sistema excitado constantemente em comportamento dinâmico, foi implementado um *Linear-Feedback Shift Register* (LFSR), que consiste em um registrador de N bits de forma que, a cada ciclo, exista um deslocamento desses bits, o bit menos significativo se torna o estado da saída e o bit mais significativo é gerado a partir de uma operação XOR ou XNOR como visto na figura 1.




Figura 1 – Estrutura base de um algoritmo LFSR.

Em ambos os casos uma sequência de bits inicial, denominada *seed*, é gerada ou fornecida e o algoritmo é capaz de gerar uma sequência de bits com comportamento estatisticamente aleatórios, ou seja, a autocorrelação é estatisticamente nula para qualquer atraso maior que zero dentro de um período, repetindo após um dado número de bits gerado, com essa quantidade de bits função do tamanho do registrador empregado na geração do PRBS. A determinação de quais bits são operados para se gerar o novo bit é feita a partir da tabela 1 [Alfke, 1996] com o critério de escolha o tamanho (N) do registrador do LFSR.

N	Bits Operados	N	Bits Operados
3	3,2	15	15,14
4	4,3	17	17,14
5	5,3	18	18,11
6	6,5	20	20,17
7	7,6	21	21,19
9	9,5	22	22,21
10	10,7	23	23,18
11	11,9	25	25,22

Tabela 1 – Bits operados no LFSR de acordo com o tamanho do registrador.

3.2 COMUNICAÇÃO RASPBERRY PI COM O ARDUINO

Para efetuar a comunicação entre a unidade de processamento (*Raspberry PI*) e a interface com o sistema físico (*Arduino*) foi adotada uma interface serial USB.

Por padrão tanto o *Arduino* quanto o *Python* já possuem bibliotecas para efetuar comunicação serial, simplificando o processo, já que cálculos como bit de paridade já são automaticamente calculados.

O protocolo adotado para a transmissão da mensagem da unidade de processamento para o *Arduino* foi da forma 3.1.

$$TtttSbbbbbbbX \quad (3.1)$$

Com T o byte referente ao comando de início da transmissão, $tttt$ o tempo entre cada atualização do estado da porta de saída de excitação em milissegundos e deve conter exatos 4 bytes de tamanho, S o byte que indica o início da transmissão dos estados da porta de saída de excitação, $bbbbbbb$ correspondendo aos estados da porta de excitação codificado em hexadecimal

e X o byte indicador do final da transmissão, indicando que o *arduino* pode iniciar o processo de excitação do sistema e coleta dos dados de saída.

Importante notar que o tamanho da mensagem *bbbbbbb* é arbitrário e deve apenas respeitar o limite da capacidade de memória do *Arduino* pois esta sequência será armazenada em memória e o tamanho do vetor de resposta é proporcional ao tamanho do vetor gerado pela mensagem *bbbbbbb*. Na implementação atual, o limite de memória do *Arduino* restringe a sequência de bits para 768 estados, ou seja, o tamanho máximo da mensagem *bbbbbbb* é de 192 bytes.

Ao término do envio desta mensagem, a unidade de processamento entra em modo de espera, aguardando a resposta do *Arduino* com os valores coletados.

3.3 EXECUÇÃO DO TESTE E COLETA DE DADOS

Com os estados da porta de excitação alocados em memória, o *arduino* executa um laço com uma iteração para cada estado sendo, a cada iteração, o valor da porta digital de saída *D8* alterado para o valor correspondente.

Em seguida é efetuada a leitura da porta analógica *A0*, o valor obtido desta leitura é alocado em um *array* e então é executado um *delay* com o tempo, em milissegundos, informado na mensagem recebida da unidade de processamento. Ao término deste laço, o *Arduino* abre uma nova comunicação serial para envio dos valores coletados pelo ADC.

Importante verificar que a taxa de amostragem é a mesma da excitação realizada já que a troca de estado da saída de excitação ocorre junto com a amostragem.

3.4 COMUNICAÇÃO ARDUINO COM O RASPBERRY PI

Ao iniciar a comunicação de resposta, o *Arduino* envia o byte T informando a unidade de processamento que começará a enviar os valores de resposta.

Os valores de tensão são amostrados pelo ADC, armazenados no *array* e então convertidos, com cada valor de 10 bits (resolução do ADC), para um valor hexadecimal de 3 caracteres que são enviados via serial. Ao término dos valores do *array*, é enviado o byte X indicando o final da transmissão.

3.5 IDENTIFICAÇÃO DO SISTEMA

Ao receber a resposta do *Arduino* com o byte X , a unidade de processamento decodifica os valores recebidos e converte estes valores, que inicialmente são proporcionais à tensão medida pelo ADC e adimensionais, para uma faixa de $0V$ a $5V$. O mesmo processo é efetuado com o vetor de estados de excitação, que é convertido de 0 ou 1 para $0V$ ou $5V$.

Com os dados amostrados, as demais etapas da identificação de sistemas são aplicadas pelo pacote *SysidentPy* [Lacerda et al., 2020]. Desta forma o processo de identificação foi todo automatizado, dispensando assim tratamentos mais específicos como a verificação da não singularidade da matriz de informação.

O critério de informação utilizado foi o de Bayes (BIC) por tornar o "joelho" do gráfico mais visível e a distribuição dos dados amostrados foi de 80% dos dados utilizados para identificar o sistema e 20% para validação pelo cálculo do RRSE e também para a análise de correlação dos resíduos de predição.

3.6 MONTAGEM FÍSICA DA INTERFACE COM O SISTEMA

Como citado anteriormente, a interface entre a unidade de processamento e o sistema a ser identificado é feita por um *Arduino Nano*. Este equipamento possui as características necessárias para efetuar esta interface, contudo existem algumas limitações em seu funcionamento que foram atenuadas na montagem.

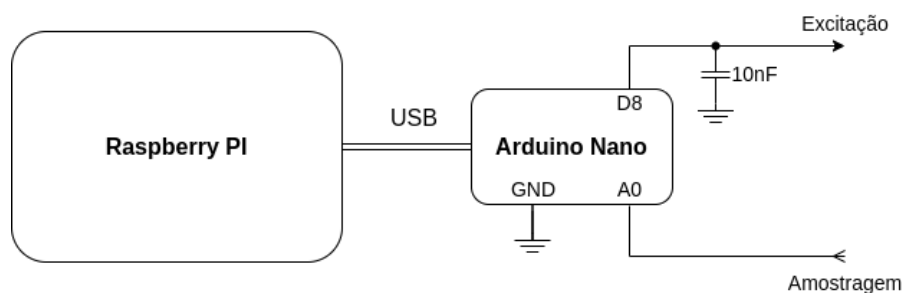


Figura 2 – Diagrama da montagem do equipamento.

Na figura 2 pode-se verificar a montagem do equipamento de identificação evidenciando-se uma das maiores limitações do equipamento, a tensão de referência tanto do gerador de

sinal de excitação quanto a amostragem pelo ADC ocorrem com a mesma referência em GND, portanto, este será um ponto de atenção nas montagens utilizadas nos experimentos.

Outro ponto evidenciado no diagrama é a existência de um capacitor de $10nF$ na porta do gerador de sinal de excitação que filtra os sinais de alta frequência reduzindo a interferência de ruídos externos no sinal de excitação.

Caso este capacitor seja removido, o *arduino* pode reiniciar durante o processo de coleta de dados devido aos ruídos provenientes do sistema testado. Porém, a existência deste capacitor remove as componentes de alta frequência do sinal de excitação, o que implica em uma limitação do equipamento em modelar os comportamentos de maiores frequências do sistema.

3.7 SISTEMAS DE TESTE

Para verificar o funcionamento do equipamento, dadas suas limitações, foram montados três sistemas de teste que foram montados em *protoboard* e a alimentação do *arduino* se deu via USB, recebendo a tensão de alimentação diretamente do *Raspberry PI*.

- Circuito RC - um sistema de primeira ordem.
- Circuito RLC Superamortecido - um sistema de segunda ordem mas com comportamento não oscilatório.
- Circuito RLC Subamortecido - um sistema de segunda ordem oscilatório.

Nos circuitos RLC, foi utilizado como indutor um transformador de características inicialmente desconhecidas, com seu secundário aberto e sua indutância foi estimada por meio da análise de resposta de um circuito oscilador tanque LC. O conhecimento a priori destas características não é fundamental para a identificação do sistema, porém, é útil em um momento inicial para estimar a taxa de amostragem inicialmente utilizada.

3.8 ESTIMAÇÃO DA INDUTÂNCIA DOS CIRCUITOS TESTE RLC

Para estimar a indutância do transformador empregado nos circuitos de teste RLC, foi montado um circuito oscilador tanque excitado por um degrau de $5V$ que passou por um capacitor de $1,65nF$, filtrando assim apenas o pulso da mudança de estado, e então, este pulso excita

o circuito tanque formado por um capacitor de 100nF e o indutor que se deseja determinar a indutância. A topologia desta montagem pode ser vista no diagrama da figura 3.




Figura 3 – Diagrama do circuito tanque.




Figura 4 – Montagem do circuito tanque.

O circuito montado pode ser visto na figura 4, onde 1 mostra a associação de capacitores que formam o capacitor filtro, 2 o capacitor do circuito tanque, 3 o indutor em teste, 4 a entrada do sinal degrau e 5 a amostragem da tensão no indutor.

Com esta montagem, obtém-se um gráfico de saída no osciloscópio com característica oscilante como visto na figura 5, com a frequência dada pela equação 3.2.



Figura 5 – Resposta esperada do circuito tanque.

$$f = \frac{1}{2 \cdot \pi \cdot \sqrt{100 \cdot 10^{-9} \cdot L}} \quad (3.2)$$

Com f a frequência de oscilação medida em Hertz, L a indutância que se deseja obter em Henry. Assim, é possível estimar a indutância de indutores desconhecidos em baixa frequência,

pois os efeitos resistivos e capacitivos parasitas do indutor podem ser desprezados devido à sua baixa influência nas medições.

3.9 DETERMINAÇÃO DA TAXA DE AMOSTRAGEM

Inicialmente arbitra-se a quantidade de pontos que serão tomados. Esta quantidade determinará a quantidade de amostras disponíveis para efetuar a identificação do sistema, portanto, em sistemas que apresentam comportamentos mais complexos, uma quantidade maior de amostras é necessária para detectar todos os comportamentos que o sistema pode apresentar, contudo, um maior número de amostras implica também em maior esforço computacional e, conseqüentemente, maior tempo de processamento.

Com as características do sistema conhecidas ou estimadas, determina-se a taxa de amostragem com base na excitação do sistema. Assim, arbitra-se o tempo entre cada bit baixo o suficiente para que o sistema não entre em regime permanente, e alto o suficiente para que o sistema não apresente nenhuma tendência além do comportamento dinâmico.

Um exemplo de sinal de excitação com tempo entre bits muito baixo pode ser visto na figura 6, com a linha amarela sendo o sinal de excitação e a linha em verde o sinal de saída. Nota-se neste caso que, além do comportamento dinâmico, o sistema apresenta uma nítida tendência de subida do sinal.



Figura 6 – Resposta de um sistema com o tempo entre cada mudança de estado muito baixo, gerando tendência.

Assim, o ajuste do tempo entre cada bit de troca de estado se dá de forma empírica com a técnica de tentativa e erro até que se obtenha um tempo entre bits adequado para o sistema.

4 RESULTADOS

Para efetuar os experimentos, o *raspberry PI* foi alimentado por uma fonte externa, ligado à um conjunto de monitor, teclado e mouse, assim como foi utilizado um cartão de memória USB tipo *pendrive* para exportar os dados gerados.

O *arduino* foi alimentado via porta USB diretamente dos circuitos reguladores de tensão do *raspberry PI*. Um osciloscópio foi ligado para verificar a geração do sinal de excitação (canal 1) e sinal coletado (canal 2).




Figura 7 – Montagem do sistema para coleta dos dados.

Na figura 7 pode-se verificar a bancada de teste montada com o *raspberry PI* (1), o *arduino* (2), o osciloscópio utilizado na conferência do sinal gerado e amostrado (3) e o sistema a ser identificado montado na *protoboard* (4).

4.1 COMPARAÇÃO DAS TOPOLOGIAS DO ALGORITMO DE GERAÇÃO DO PRBS

Executando-se o algoritmo de geração do PRBS com 4 bits e repetindo-se essa geração por 3 ciclos, totalizando 45 amostras totais, utilizando-se a porta XOR e XNOR como porta geradora, calculando-se a autocorrelação dos sinais obtidos como mostrado nas figuras 8 e 9.




Figura 8 – Autocorrelação do PRBS gerado com porta XOR.

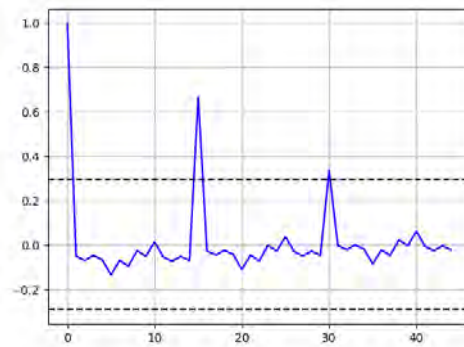


Figura 9 – Autocorrelação do PRBS gerado com porta XNOR.

Para que o sinal PRBS seja de fato pseudo aleatório, este deve possuir autocorrelação não nula para o atraso 0 e para os atrasos múltiplos do período do algoritmo de geração do sinal PRBS.

Pode-se verificar nas figuras 8 e 9 que a característica da autocorrelação é atendida em ambas situações, tanto no caso do PRBS ser gerado com porta XOR quanto para o caso de ser gerado por porta XNOR.

Como ambos os geradores apresentam igual característica, sem nenhuma particularidade tanto de implementação quando de execução, de forma arbitrária, foi escolhido utilizar a topologia com porta XNOR no atual projeto.

4.2 DETERMINAÇÃO DA INDUTÂNCIA POR MEIO DO CIRCUITO TANQUE

Foi determinada a indutância dos dois *taps* do primário do transformador por meio do circuito tanque. Assim obteve-se os valores de $303H_z$ na medição entre o terminal preto e o amarelo do transformador e $170H_z$ entre o terminal preto e o vermelho.

Aplicando-se a equação 3.2, determinou-se que a indutância entre os terminais preto e amarelo é de $2,75H$ e, entre os terminais preto e vermelho é de $8,75H$. A determinação destes valores será de fundamental importância no teste dos sistemas RLC para determinar o valor dos demais componentes de forma a montar as topologias desejadas (subamortecido e superamortecido).

Por meio desta indutância então, determinou-se que o circuito RLC poderia utilizar um resistor de $10k\Omega$ com um capacitor de $4,7\mu F$ em conjunto ao *tap* de $8,75H$ do indutor para apresentar um comportamento superamortecido e um resistor de 180Ω e um capacitor de $4,7\mu F$ no *tap* de $2,75H$ para apresentar um comportamento subamortecido.

4.3 CIRCUITO RC

A montagem do circuito RC se deu com a figura 11, onde pode-se verificar o *arduino* (1), o capacitor de filtro na saída da excitação (2) e o circuito RC (3) dado pela topologia do diagrama 10.




Figura 10 – Diagrama do circuito de RC.




Figura 11 – Montagem do circuito de RC.

Com esta topologia, o circuito foi excitado por um sinal PRBS composto de 300 pontos amostrais com intervalo de $12ms$ entre cada bit de estado. Assim, os primeiros instantes de sinal gerado e amostrado pelo equipamento de identificação e pelo osciloscópio foram, respectivamente 12 e 13.

Pode-se verificar que existiu uma pequena divergência, de aproximadamente $0,5V$ entre os sinais gerado e amostrado quando observado pelo osciloscópio e pelo equipamento de identificação projetado.




Figura 12 – Primeiros pontos amostrados pelo equipamento de identificação.




Figura 13 – Primeiros pontos amostrados pelo osciloscópio.

Aplicando-se a técnica da taxa de redução de erro, seguindo pela aplicação do critério de informação de Bayes (BIC), obteve-se o gráfico da figura 14.




Figura 14 – Critério de informação de Bayes do modelo do sistema RC.

Assim, obteve-se o modelo com 2 regressores dado por 4.1 resultando em uma simulação livre mostrado no gráfico da figura 15 obtendo assim um RRSE de 0,0268. A análise estatística dos resíduos de predição pode ser vista nos gráficos das figuras 16 e 17.

A diferença apresentada entre a tensão medida pelo osciloscópio e o sinal amostrado não significou perda de qualidade do modelo, como evidenciado pelo baixo RRSE, indicando que a identificação ocorreu de forma adequada.

$$y(k) = (3,7887 \cdot 10^{-1})y(k-1) + (9,2096 \cdot 10^{-3})u(k-1)^3 \quad (4.1)$$




Figura 15 – Simulação livre do modelo do sistema RC.




Figura 16 – Autocorrelação dos resíduos de predição do sistema RC.




Figura 17 – Correlação cruzada dos resíduos de predição com a entrada do sistema RC.

No caso da análise estatística, a autocorrelação dos resíduos apresentou resultado não nulo para valores próximos ao atraso zero, significando assim que o resíduo de predição deste modelo apresenta comportamento aproximadamente branco, mas já apresenta uma pequena tendência a ter uma distribuição não normal.

Cruzando esta análise com a correlação cruzada do resíduo de predição com a entrada, percebe-se que existe uma pequena tendência do resíduo ser explicado pela entrada, indicando que existe uma tendência do modelo estar levemente sobreajustado, dessa forma, o modelo tenderá a perder qualidade ao se afastar da janela de dados que foi utilizada para gerar o modelo.

Este efeito pode ser explicado por limitações das técnicas da taxa de redução de erro e o critério de informação, que utilizam a simulação um passo à frente, enquanto a utilização do modelo exige a simulação livre, mas também pode ser consequência de um pequeno *oversampling*, o que pode possibilitar o modelo representar mais o ruído.

4.4 CIRCUITO RLC SUPERAMORTECIDO

A montagem do circuito RLC superamortecido se deu com a topologia mostrada na figura 18 que foi montada, de forma análoga ao circuito RC, como mostra a figura 19 com o *arduino* (1), o capacitor de filtro da saída de excitação (2) e o circuito RLC (3).




Figura 18 – Diagrama do circuito de RLC superamortecido.




Figura 19 – Montagem do circuito de RLC superamortecido.

Com esta topologia, o circuito foi excitado por um sinal PRBS composto de 300 pontos amostrais com intervalo de $15ms$ entre cada mudança de estado. Assim, os primeiros instantes de sinal gerado e amostrado pelo equipamento de identificação e pelo osciloscópio foram, respectivamente 20 e 21.

Aplicando-se a técnica da taxa de redução de erro, seguindo pela aplicação do critério de informação de Bayes (BIC), obteve-se o gráfico da figura 22.

Dessa forma obteve-se o modelo com 3 regressores dado por 4.2 resultando em uma simulação livre mostrado no gráfico da figura 23 obtendo assim um RRSE de 0,0089. A análise estatística dos resíduos de predição pode ser vista nos gráficos das figuras 24 e 25.

Neste caso, pode-se observar a mesma diferença existente no sistema RC de diferença entre a tensão do sinal amostrado pelo equipamento e pelo osciloscópio, e da mesma forma que




Figura 20 – Primeiros pontos amostrados pelo equipamento de identificação.



Figura 21 – Primeiros pontos amostrados pelo osciloscópio.




Figura 22 – Critério de informação de Bayes do modelo do sistema RLC superamortecido.

o sistema anterior, não houve perda de qualidade neste modelo.

$$y(k) = (7,1524 \cdot 10^{-1})y(k-1) + (4,8375 \cdot 10^{-2})u(k-1)^2 + (2,9853 \cdot 10^{-2})u(k-2) \quad (4.2)$$

Analisando-se o RRSE deste modelo e cruzando-se esta análise com os gráficos de autocorrelação dos resíduos e da correlação cruzada dos resíduos com a entrada, pode-se perceber que este sistema foi identificado de forma bastante precisa e criteriosa, já que o resíduo de predição apresenta autocorrelação não nula apenas no atraso zero e em raros pontos subsequentes.




Figura 23 – Simulação livre do modelo do sistema RLC superamortecido.




Figura 24 – Autocorrelação dos resíduos de predição do sistema RLC superamortecido.




Figura 25 – Correlação cruzada dos resíduos de predição com a entrada do sistema RLC superamortecido.

A correlação cruzada, neste caso, também apresenta apenas pequenos raros pontos de correlação não nula. Desta forma, este modelo não apresenta efeito de sobreajuste e foi amostrado de forma adequada.

4.5 CIRCUITO RLC SUBAMORTECIDO

A montagem do circuito RLC subamortecido se deu com a topologia mostrada na figura 26 que foi montada como mostra a figura 27, onde pode-se verificar o *arduino* (1), o capacitor de filtro da excitação (2) e o circuito RLC (3).

Com esta topologia, o circuito foi excitado por um sinal PRBS composto de 300 pontos amostrais com intervalo de $10ms$ entre cada mudança de estado. Assim, os primeiros instantes




Figura 26 – Diagrama do circuito de RLC subamortecido.




Figura 27 – Montagem do circuito de RLC subamortecido.

de sinal gerado e amostrado pelo equipamento de identificação e pelo osciloscópio foram, respectivamente 28 e 29.




Figura 28 – Primeiros pontos amostrados pelo equipamento de identificação.



Figura 29 – Primeiros pontos amostrados pelo osciloscópio.

Nestes gráficos, pode-se verificar que o sinal amostrado saturou o ADC do *arduino* e, assim, os picos de tensão maiores que 4,5V e inferiores a 0V não foram amostrados, como visto no marcador (1). Esta saturação causou nítida perda de informação do sistema. Outro comportamento observado foi que, componentes de alta frequência existem e não puderam ser amostrados pelo *arduino*, como pode-se observar no marcador (2).

Aplicando-se a técnica da taxa de redução de erro, seguindo pela aplicação do critério de informação de Bayes (BIC), obteve-se o gráfico da figura 30.

Assim, obteve-se o modelo com 4 regressores dado por 4.3 resultando em uma simulação




Figura 30 – Critério de informação de Bayes do modelo do sistema RLC subamortecido.

livre mostrado no gráfico da figura 31 obtendo assim um RRSE de 0,0686. A análise estatística dos resíduos de predição pode ser vista nos gráficos das figuras 32 e 33.

$$\begin{aligned}
 y(k) = & (7,2095 \cdot 10^{-1})u(k-1) + (1,0275 \cdot 10^{-1})u(k-2)^2 \\
 & + (1,2654 \cdot 10^{-2})u(k-4)y(k-3) + (7,3821 \cdot 10^{-2})
 \end{aligned}
 \tag{4.3}$$

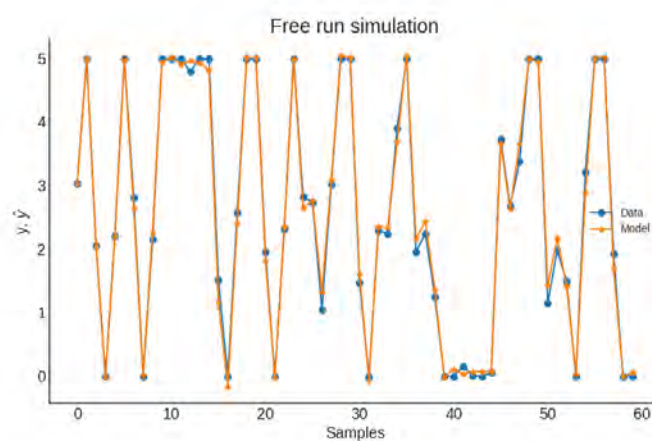


Figura 31 – Simulação livre do modelo do sistema RLC subamortecido.

Da mesma forma como nos casos anteriores, este sistema também apresentou a mesma divergência entre os dados amostrados pelo equipamento e pelo osciloscópio, porém, neste caso, além da divergência de amplitude já observada, houve também distorção na forma de onda. Este efeito ocorreu pela saturação do ADC, que não teve capacidade de efetuar medições acima de

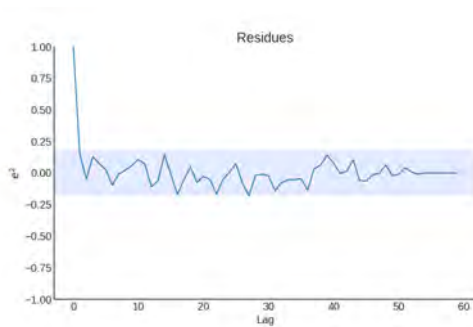


Figura 32 – Autocorrelação dos resíduos de predição do sistema RLC subamortecido.




Figura 33 – Correlação cruzada dos resíduos de predição com a entrada do sistema RLC subamortecido.

4,5V, ceifando-se assim o topo e os vales das ondas nos casos que a tensão positiva superou os 4,5V e a negativa os 0V.

Outra dificuldade encontrada pelo equipamento na modelagem foi a perda de informação devido à elementos de frequências mais altas e que não puderam ser amostradas. Esta perda ocorreu pois a taxa de amostragem é vinculada à taxa de mudança de bits da excitação. Desta forma, não foi possível amostrar dados referentes aos comportamentos do sistema, mesmo que o PRBS tenha sido bem dimensionado.

O modelo obtido teve um RRSE próximo a zero e, de acordo com a análise estatística dos resíduos de predição, este modelo apresentou qualidade comparável ao RLC superamortecido, com pequena perda na correlação cruzada do resíduo com a entrada, mas mesmo assim não indicando que o modelo tenha de fato sofrido efeito de sobreajuste. Porém, mesmo que o modelo represente de forma bastante satisfatória os dados coletados, este modelo não representará o sistema pois parte de seu comportamento não foi modelado devido à perda da informação durante a coleta dos dados.

Mesmo representando de forma satisfatória os dados coletados, a perda de informação foi perceptível também nas métricas, já que este modelo apresentou o valor de RRSE mais alto dentre os modelos e, mesmo de forma visual pelo gráfico da figura 31, é possível verificar que existem pequenas divergências entre o modelo e os dados, diferenças estas que não eram perceptíveis nos sistemas anteriores.

5 CONCLUSÃO

Pela análise dos sistemas testados, pode-se perceber que o equipamento tem capacidade de identificar sistemas de primeira e segunda ordem, porém, como as técnicas aplicadas são válidas para sistemas arbitrários, é possível levantar a hipótese de que este equipamento também possa ser aplicado a sistemas arbitrários. Hipótese esta que poderá ser verificada em trabalhos futuros.

Nos sistemas identificados, comparando-se os valores coletados com os valores obtidos no osciloscópio, pode-se perceber que a queda de tensão interna do *arduino* de, em média 0,5V criando uma divergência entre o sinal amostrado pelo equipamento projetado e pelo osciloscópio. Esta diferença, contudo, não representou queda de qualidade no processo de identificação.

Além deste problema detectado nas análises dos dados gerados, percebeu-se também, no projeto, a limitação do equipamento possuir a mesma referência de tensão tanto na geração do sinal de excitação quanto na amostragem do sinal de resposta do sistema. Esta limitação restringe muito as aplicações nas quais este equipamento pode ser utilizado.

Além desta limitação, também foi possível verificar que a utilização do *arduino* como gerador de sinal para excitação do sistema diretamente forçou a utilização de um capacitor para filtrar ruídos provenientes do sistema identificado, que forçava o *arduino* a reiniciar durante o processo de coleta de dados. A inclusão deste capacitor, contudo, representou um fator de erro adicional ao processo, visto que sinais de alta frequência eram filtrados. Assim, caso o sistema estudado oferecesse alguma resposta nestas faixas, esta resposta não seria estimulada.

Outra limitação importante é o fato do ADC ter uma faixa de leitura de 0V a 4,5V, dessa forma, ao efetuar a leitura da resposta de um sistema que ultrapasse estes valores, o ADC do *arduino* satura e as informações dos comportamentos do sistema fora desta faixa são perdidos.

Para solucionar estas limitações, a criação de um *driver* que faça a interface do gerador de sinais com o sistema, assim como, que faça a interface do sistema com o ADC, particularmente tornando a referência de tensão independente entre geração de sinal de excitação e coleta dos dados, aumentaria bastante o escopo de aplicação do equipamento.

Este *driver* pode também isolar o gerador de sinal de excitação do sistema, prevenindo assim que o *arduino* reinicie de forma indesejada durante a amostragem dos dados e também

permite que sinais arbitrários sejam condicionados dentro da faixa de leitura do ADC, evitando assim a perda de informação durante a coleta de dados.

Outro fator limitante no projeto é a escolha do *arduino* como gerador do sinal de excitação e coleta do sinal de resposta. A limitação de frequência de amostragem do ADC, junto ao fato da mudança de estado da porta de excitação e da amostragem pelo ADC ocorrer de forma serial, e não paralela, limita muito a frequência máxima dos sistemas possíveis de serem identificados com o equipamento desenvolvido. Além destes fatores referentes ao *arduino*, a baixa quantidade de memória também limita muito a quantidade de amostras possíveis de serem tomadas, podendo, dependendo do sistema a ser identificado, gerar problema de falta de dados suficientes para identificar de forma adequada.

Para solucionar estes problemas, o desenvolvimento de uma interface mais robusta poderia ampliar consideravelmente a aplicabilidade deste equipamento que, mesmo com tantas limitações, se mostrou eficiente para a tarefa.

6 PROPOSTAS DE TRABALHOS FUTUROS

O atual trabalho se mostrou como uma prova de conceito, mostrando que não somente é possível como é viável o desenvolvimento de um equipamento especializado em identificação de sistemas. Mesmo com as diversas limitações, ele conseguiu exercer de forma bastante satisfatória a tarefa na qual foi desenvolvido. Porém, diversas limitações podem ser corrigidas em trabalhos futuros.

- Desenvolver um *driver* para separar a tensão de referência do gerador do sinal de excitação do ADC, responsável pela amostragem do sinal de saída. Além de isolar o circuito de excitação do sistema analisado, dispensando o uso do capacitor filtro;
- O desenvolvimento de um hardware capaz de, em paralelo, excitar e coletar os dados do sistema externo aumentando assim a frequência máxima do sistema analisado além de possibilitar efetuar a coleta dos dados em uma frequência diferente da excitação do sistema;
- Verificar formas de aumentar a memória do hardware de excitação e amostragem dos dados, a fim de aumentar a resolução do equipamento e, também, possibilitar a aplicação em sistemas mais complexos, que dependam de grandes volumes de dados para serem identificados;
- Implementar outros algoritmos de seleção de estrutura, como as técnicas meta-heurísticas, a fim de retirar a dependência das técnicas das simulações um passo à frente;
- Desenvolver uma interface homem máquina mais adequada para a utilização do equipamento;
- Verificar a possibilidade de tornar o equipamento independente da unidade de processamento de dados, criando uma interface com dispositivos móveis comuns como *notebooks* ou telefones celular ou mesmo integrando a interface com o sistema físico à unidade de processamento;
- Verificar a capacidade do equipamento ao identificar sistemas arbitrários e/ou muito complexos;

REFERÊNCIAS

- [Aguirre, 2015] Aguirre, L. A. (2015). *Introdução à identificação de sistemas—Técnicas lineares e não-lineares aplicadas a sistemas reais*. Editora UFMG. Citado 4 vezes nas páginas 5, 6, 8 e 11.
- [Akaike, 1974] Akaike, H. (1974). A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, 19:716–723. Citado na página 10.
- [Akaike, 1998] Akaike, H. (1998). *Information Theory and an Extension of the Maximum Likelihood Principle*. Springer New York. Citado na página 10.
- [Alfke, 1996] Alfke, P. (1996). Efficient shift registers, LFSR counters, and long pseudo-random sequence generators. <https://docs.xilinx.com/v/u/en-US/xapp052>. Citado na página 14.
- [Babuška e Verbruggen, 2003] Babuška, R. e Verbruggen, H. (2003). Neuro-fuzzy methods for nonlinear system identification. *Annual Reviews in Control*, 27:73–85. Citado na página 5.
- [Billings, 2013] Billings, S. A. (2013). *Nonlinear System Identification*. John Wiley Sons, Ltd. Citado 3 vezes nas páginas 6, 8 e 11.
- [Coorporation, 2015] Coorporation, A. (2015). Atmel atmega328p datasheet. *Acessado: Janeiro/2023*, 26:294. Citado na página 12.
- [Golnaraghi, 2009] Golnaraghi, B. C. K. F. (2009). *Automatic control systems*. Wiley, 9th edio. Citado na página 6.
- [Guidotti et al., 2019] Guidotti, R., Monreale, A., Ruggieri, S., Turini, F., Giannotti, F., e Pedreschi, D. (2019). A survey of methods for explaining black box models. *ACM Computing Surveys*, 51:1–42. Citado na página 6.
- [Hannan e Quinn, 1979] Hannan, E. J. e Quinn, B. G. (1979). The determination of the order of an autoregression. Citado na página 10.
- [Juditsky et al., 1995] Juditsky, A., Hjalmarsson, H., Benveniste, A., Delyon, B., Ljung, L., Sjöberg, J., e Zhang, Q. (1995). Nonlinear black-box models in system identification: Mathematical foundations. *Automatica*, 31:1725–1750. Citado na página 5.

- [Korenberg et al., 1988] Korenberg, M., Billings, S. A., Liu, Y. P., e McIlroy, P. J. (1988). Orthogonal parameter estimation algorithm for non-linear stochastic systems. *International Journal of Control*, 48:193–210. Citado 2 vezes nas páginas 9 e 11.
- [Lacerda et al., 2020] Lacerda, W., da Andrade, L., Oliveira, S., e Martins, S. (2020). Sysidentpy: A python package for system identification using narmax models. *Journal of Open Source Software*, 5:2384. Citado na página 16.
- [Mendez e Billings, 2001] Mendez, E. e Billings, S. (2001). An alternative solution to the model structure selection problem. *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, 31:597–608. Citado na página 10.
- [Montestruque e Antsaklis, 2003] Montestruque, L. A. e Antsaklis, P. J. (2003). On the model-based control of networked systems. *Automatica*, 39:1837–1843. Citado na página 5.
- [Polifke, 2014] Polifke, W. (2014). Black-box system identification for reduced order model construction. *Annals of Nuclear Energy*, 67:109–128. Citado na página 6.
- [Satopaa et al., 2011] Satopaa, V., Albrecht, J., Irwin, D., e Raghavan, B. (2011). Finding a "kneedle" in a haystack: Detecting knee points in system behavior. pp. 166–171. IEEE. Citado na página 11.
- [Schwarz, 1978] Schwarz, G. (1978). Estimating the dimension of a model. *The Annals of Statistics*, 6. Citado na página 10.
- [Shannon, 1949] Shannon, C. (1949). Communication in the presence of noise. *Proceedings of the IRE*, 37:10–21. Citado na página 8.
- [Shannon, 2001] Shannon, C. E. (2001). A mathematical theory of communication. *SIGMOBILE Mob. Comput. Commun. Rev.*, 5(1):3–55. Citado na página 8.
- [Souza et al., 2016] Souza, F. A., Araújo, R., e Mendes, J. (2016). Review of soft sensor methods for regression applications. *Chemometrics and Intelligent Laboratory Systems*, 152:69–79. Citado na página 5.
- [Vizer et al., 2013] Vizer, D., Mercere, G., Prot, O., e Ramos, J. (2013). A local approach framework for black-box and gray-box LPV system identification. pp. 1916–1921. IEEE. Citado na página 5.