Samuel Lourenço Nogueira

**Controladores Adaptativos Não-Lineares com Critério $\mathcal{H}_\infty$
Aplicados a Manipuladores com Restrições de Força e
Posição**

Dissertação apresentada à Escola de Engenharia de São Carlos
da Universidade de São Paulo, como parte dos requisitos para
obtenção do título de Mestre em Engenharia Elétrica

Área de Concentração: Sistemas Dinâmicos
Orientador: Prof. Dr. Marco Henrique Terra
Co-orientador: Prof. Dr. Adriano A. G. Siqueira

São Carlos
2010

AUTORIZO A REPRODUÇÃO E DIVULGAÇÃO TOTAL OU PARCIAL DESTE TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Ficha catalográfica preparada pela Seção de Tratamento
da Informação do Serviço de Biblioteca – EESC/USP

N778c

Nogueira, Samuel Lourenço

Controladores adaptativos não-lineares com critério H^∞ aplicados a manipuladores com restrições de força e posição / Samuel Lourenço Nogueira ; orientador Marco Henrique Terra, co-orientador Adriano A. G. Siqueira. -- São Carlos, 2009.

Dissertação (Mestrado-Programa de Pós-Graduação em Engenharia Elétrica e Área de Concentração em Sistemas Dinâmicos) -- Escola de Engenharia de São Carlos da Universidade de São Paulo, 2009.

1. Manipuladores. 2. Manipuladores restritos.
3. Controlador H^∞ . 4. Redes neurais. 5. Sistemas *fuzzy*.
6. Controle por estrutura variável. I. Título..

FOLHA DE JULGAMENTO

Candidato: Engenheiro SAMUEL LOURENÇO NOGUEIRA.

Dissertação defendida e julgada em 04/12/2009 perante a Comissão Julgadora:

Prof. Associado **MARCO HENRIQUE TERRA (Orientador)**
(Escola de Engenharia de São Carlos/USP)

APROVADO

Prof. Dr. **FERNANDO CESAR LIZARRALDE**
(Universidade Federal do Rio de Janeiro/UFRJ)

APROVADO

Prof. Dr. **GUILHERME AUGUSTO SILVA PEREIRA**
(Universidade Federal de Minas Gerais/UFGM)

APROVADO

Prof. Titular **GERALDO ROBERTO MARTINS DA COSTA**
Coordenador do Programa de Pós-Graduação em Engenharia Elétrica e
Presidente da Comissão de Pós-Graduação

Sumário

Resumo	vii
Abstract	ix
Publicações	xi
Lista de Figuras	xiii
Lista de Tabelas	xv
Lista de Abreviaturas e Siglas	xvii
1 Introdução	1
1.1 Motivação	1
1.2 Sensores de Força/Momento Multi-eixos	2
1.3 Controle de Força em Manipuladores Robóticos	4
1.4 Objetivos Fundamentais	6
1.5 Disposição dos Capítulos	6
2 Sensor para medição de força/momento em três eixos ortogonais	7
2.1 Funcionamento Mecânico	7
2.2 Funcionamento Eletrônico	13
2.3 Implementação	15
3 Conceitos Preliminares	17
3.1 Controle de Força para Manipuladores Robóticos	20
3.1.1 Controle de Rigidez	21
3.1.2 Controle Híbrido de Posição e Força	21
4 Controladores Adaptativos para Manipuladores com Restrição	27
4.1 Modelo do Manipulador com Restrição	28

4.2	Formulação do Problema	30
4.3	Estimadores Baseados em Sistemas Inteligentes	32
4.3.1	Estimativa das Incertezas Paramétricas Baseada em Redes Neurais - RNIP	33
4.3.2	Estimativa do Modelo Completo Baseada em Redes Neurais - RNMC . .	34
4.3.3	Estimativa das Incertezas Paramétricas Baseada no Modelo Fuzzy Takagi-Sugeno - TSIP	35
4.3.4	Estimativa do Modelo Completo Baseada no Modelo Fuzzy Takagi-Sugeno - TSMC	37
4.3.5	Considerações	37
4.4	Controle Adaptativo $\mathcal{H}_\infty$ Não Linear	38
5	Implementação e resultados	45
5.1	Underactuated Arm II (UArmII)	46
5.2	Ambiente de Simulação e Controle	46
5.3	Trajetórias Desejadas e Índices de Desempenho	48
5.4	Experimentos	49
5.4.1	Controlador via Redes Neurais	52
5.4.2	Controlador via Lógica Fuzzy	55
5.5	Resultados	59
5.5.1	Análise Gráfica	61
5.5.2	Análise Quantitativa	63
	Conclusão	71
	Referências Bibliográficas	73

A meus pais Carlos e Adelina,

A minha tia Alice,

A meus irmãos Daniel e Gabriel,

Com amor e gratidão.

Agradecimentos

Aos meus pais Carlos Alberto Nogueira e Adelina Lourenço Nogueira com amor, admiração e gratidão por sua compreensão, carinho, presença e incansável apoio ao longo do período deste mestrado.

A minha tia Alice Adelina Lourenço de Oliveira que tanto me ajudou em minha permanência em São Carlos.

Ao Prof Dr. Marco Henrique Terra pela confiança, orientação, paciência e pelo tempo dedicado a este trabalho.

Ao Prof. Dr. Adriano Almeida Gonçalves Siqueira pela atenção, apoio e contribuições na realização deste trabalho.

Aos amigos da pós-graduação e do LASI: Aline, Amanda, Gildson, João Paulo, Rafael, Tatiane, Darby, pela amizade, paciência, companheirismo e colaborações durante a realização das disciplinas e deste trabalho.

Em especial agradeço a Tatiana, Roberto e Tubota pela paciência e grande coloboração nesta dissertação.

Aos professores e funcionários do Departamento de Engenharia Elétrica da Escola de Engenharia de São Carlos, pelas contribuições durante o mestrado.

A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão da bolsa de mestrado.

Resumo

NOGUEIRA, S. L. (2009). *Controladores Adaptativos Não-Lineares com Critério $\mathcal{H}_\infty$ Aplicados a Manipuladores com Restrições de Força e Posição*. Dissertação (Mestrado), Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.

Neste trabalho é apresentado um estudo comparativo entre quatro controladores $\mathcal{H}_\infty$ não lineares aplicados a um manipulador robótico com restrições de força e posição. Para estudar o comportamento de cada controlador as seguintes estratégias foram adotadas: (1) o modelo nominal do robô é considerado conhecido e são utilizadas técnicas inteligentes para estimar incertezas paramétricas, dinâmicas não modeladas e distúrbios externos; (2) O modelo do sistema é considerado completamente desconhecido e as técnicas inteligentes são utilizadas para estimar o modelo completo. As técnicas inteligentes utilizadas são baseadas em redes neurais e lógica fuzzy. Resultados experimentais baseados em um manipulador planar de três juntas rotacionais são apresentados, sendo que as restrições de posicionamento e força são referentes ao movimento sobre uma linha reta. Ainda neste projeto é desenvolvido um sensor para medição de forças e momentos em três eixos ortogonais, sendo este sensor o dispositivo utilizado para fornecer informações necessárias para o controle do manipulador robótico com restrições.

Palavras-chave: Manipuladores restritos, controlador $\mathcal{H}_\infty$, redes neurais, sistemas fuzzy, controle por estrutura variável.

Abstract

NOGUEIRA, S. L. (2006). Adaptive Nonlinear $\mathcal{H}_\infty$ Controllers Applied to Constrained Manipulators. *Dissertation (Master), Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.*

In this work, we present a comparative study among four $\mathcal{H}_\infty$ nonlinear controllers applied to a manipulator subject to position and force constraints. In order to study the behavior of each controller the following strategies have been adopted: (1) the nominal model of the robot is considered known and intelligent techniques are used to estimate parametric uncertainties, nonmodeled dynamics and external disturbances; (2) the system model is considered completely unknown and intelligent techniques are used to estimate the complete model. The intelligent techniques considered are based on neural networks and fuzzy logic. Experimental results based on a planar manipulator with three rotational joints are presented where position and force constraints refer to a movement on a straight line. To perform these experiments we developed a sensor to measure forces and moments in three orthogonal axes.

Keywords: *Constrained manipulators, $\mathcal{H}_\infty$ control, neural networks, fuzzy systems, variable structure control.*

Publicações

1. S. L. Nogueira, T. F. P. A. T. Pazelli , A. A. G. Siqueira e M. H. Terra (2008). Adaptive fuzzy nonlinear $\mathcal{H}_\infty$ tracking control design of a constrained robot system. In: *Mediterranean Conference on Control and Automation*, 16th, Ajaccio, France, p. 362-367, June 25-27, 2008.

Lista de Figuras

1.1	Imagem retirada de [15].	2
1.2	Imagem retirada de [16].	3
1.3	Imagem retirada de [28].	3
2.1	Descrição detalhada do sensor de força.	8
2.2	Parte superior do sensor.	8
2.3	Parte inferior do sensor.	9
2.4	Corpo de transmissão de forças (4) e sensores para medição de forças momentos normais ao plano da base(3).	10
2.5	Desenho esquemático de funcionamento do sensor.	10
2.6	Corpo de fixação dos sensores de força, vista frontal.	12
2.7	Corpo de fixação dos sensores para medição de forças e momentos paralelos ao plano da base, vista inferior.	12
2.8	Esquema elétrico resumido da placa de condicionamento dos sinais.	14
2.9	Componentes estruturais.	15
2.10	Fase intermediária da montagem.	15
2.11	Sensor montado.	16
3.1	Corpos rígidos.	17
3.2	Modelo massa mola.	21
3.3	Robô cartesiano.	22

5.1	Underactuated Arm II	46
5.2	Ambiente de Simulação e Controle de Manipuladores Restritos.	47
5.3	Modelo esquemático do manipulador e régua de restrição.	50
5.4	Efetuator e régua de restrição.	50
5.5	Rede neural.	52
5.6	Conjuntos fuzzy $A_1(\tilde{q}_1)$ e $A_2(\dot{\tilde{q}}_1)$	55
5.7	Diagrama fuzzy.	57
5.8	Perturbação de torque.	60
5.9	Acompanhamento de trajetória.	64
5.10	Torque nas juntas.	65
5.11	Posição X e Y do efetuator	66
5.12	Força e momento no efetuator.	67
5.13	Ângulo de acompanhamento das juntas.	68
5.14	Orientação do efetuator.	69
5.15	Velocidade de acompanhamento das juntas.	70

Lista de Tabelas

5.1	Parâmetros do UArmII	47
5.2	Ganhos dos controladores.	60
5.3	Índice de desempenho.	63

Lista de Abreviaturas e Siglas

ASCM-R	Ambiente de Simulação e Controle de Manipuladores Restritos
NOM	Controlador Nominal sem Estimação de Incertezas
RNIP	Redes Neurais Estimando Incertezas Paramétricas
RNMC	Redes Neurais Estimando Modelo Completo
TSIP	Modelo Fuzzy Takagi-Sugeno Estimando Incertezas Paramétricas
TSMC	Modelo Fuzzy Takagi-Sugeno Estimando Modelo Completo
UArmII	Underactuated Arm II
VSC	Controle por Estrutura Variável (<i>Variable Structure Control</i>)

Capítulo 1

Introdução

1.1 Motivação

Esta dissertação trata do controle de força e posicionamento de robôs manipuladores. Neste tipo de problema existem muitas variáveis que podem deteriorar a representatividade do modelo nominal, como por exemplo: incertezas paramétricas, dinâmicas não modeladas e distúrbios externos são algumas dessas variáveis. É sempre necessário conhecer as forças e momentos de interação entre o efetuator robótico e o meio onde ele está atuando. Dispositivos para medir tais variáveis são conhecidos como células de carga multi-eixos ou sensores de força e torque multi-eixos.

Há diversos exemplos de aplicação onde os manipuladores robóticos devem realizar tarefas sujeitas a restrições de força e movimento, como por exemplo:

- No processo de fresamento de uma peça onde os ângulos de incidência, os percursos e as forças e momentos exercidos pela broca no material fresado devem ser precisos.
- Em linhas de montagem industriais onde objetos devem ser encaixados ao longo de determinados percursos com forças e momentos pré-determinados.
- No corte de chapas metálicas onde os ângulos de corte, os percursos e as forças exercidas no material são importantes.
- No polimento de superfícies onde o disco de polimento deve ficar sempre perpendicular à superfície a ser polida e exercendo uma força pré-determinada.

O transdutor de carga desenvolvido em [16] mede as forças lineares em três eixos e momentos em dois de seus eixos. O transdutor tem encapsulamentos internos e externos conectados por braços sensíveis à carga. A parte externa de cada braço é conectada na estrutura externa por ligamentos rígidos quando o encapsulamento externo é carregado ao longo de um eixo perpen-

De forma a encontrar uma alternativa a esses sensores, propomos um sensor para medição de forças e momentos dinâmicos em três eixos ortogonais, que utiliza sensores de força unidirecionais piezoelétricos como unidade base de medida.

A principal diferença entre sensores piezoelétricos e *strain gages* é que o sinal elétrico gerado pelos piezoelétricos decaem no tempo. Essa característica torna tais sensores não aconselháveis para medição de forças ou pressões estáticas, mas são os mais aconselhados para medições dinâmicas, tais como impactos e acelerações.

1.3 Controle de Força em Manipuladores Robóticos

Os primeiros manipuladores robóticos foram desenvolvidos com o objetivo de executar tarefas de posicionamento, por exemplo na pintura de uma superfície por pulverização utilizando um spray. Para esse fim, eles foram desenvolvidos para serem robustos o suficiente para que não fossem afetados por distúrbios externos que pudessem influenciá-los. Essa característica marcante da robustez física dos manipuladores permitiu aos pesquisadores de sistemas robóticos obterem uma boa precisão de posicionamento utilizando apenas leis simples de controle.

Algumas décadas mais tarde, a popularização da robótica no ambiente industrial despertou um grande interesse dos pesquisadores no sentido de criar uma gama muito maior de aplicações de manipuladores robóticos nos mais diversos ambientes. Assim, surgiram conceitos de controle para o posicionamento e para a força do efetuator robótico de robôs mais leves e flexíveis, veja por exemplo a referência [13] para maiores detalhes.

Em [23], foi introduzido o conceito de controle de rigidez, que leva em consideração a resistência do corpo no qual o efetuator robótico está aplicando uma determinada força. Nessa referência esse problema é modelado como um sistema massa-mola. Através deste conceito tornou-se possível o controle simultâneo de posicionamento pontual e força exercida pelo efetuator. Entretanto, essas primeiras propostas que apareceram na literatura consideravam que o posicionamento e a força exercidos pelo efetuator no meio deveriam ser constantes. Em muitas aplicações robóticas, tais como no fresamento de uma peça, o efetuator deve seguir uma trajetória de posicionamento ao longo da superfície de um objeto enquanto aplica uma força desejada, que não é necessariamente constante, sobre essa mesma superfície. Neste tipo de aplicação, o controle de rigidez não funciona adequadamente.

Em [23] e [22], foram utilizados sistemas de coordenadas relacionados com o espaço cartesiano, sendo o problema de controle particionado em duas subtarefas: uma para o controle da trajetória de posicionamento e outra para o controle da força desejada. Este tipo de abordagem foi uma evolução do controlador proposto em [20], e se tornou a base conceitual dos controles

híbridos de trajetória de posição e da força desejada encontrados atualmente na literatura.

Em [14] foi mostrado que quando um manipulador está em contato com uma superfície, os graus de liberdade de posição são reduzidos e a restrição de força é adicionada às equações do movimento, das coordenadas não restritas das juntas, através de multiplicadores de Lagrange. As equações dinâmicas do manipulador são desenvolvidas de maneira a reduzir a ordem do vetor de estados.

Vencido o passo de se controlar sistemas robóticos com restrição de posicionamento e força, pesquisadores começaram a preocupar-se com as variáveis que pudessem degradar a estabilidade dos modelos propostos até então. Incertezas relacionadas com a carga no efetuador, que pode variar enquanto o manipulador realiza diferentes tarefas, atritos e incertezas paramétricas são exemplos de problemas que têm demandado muito esforço de pesquisa. Veja [18], [26], [27] e [29] para maiores detalhes. No entanto, somente alguns estudos têm tratado do controle adaptativo e do controle robusto de sistemas robóticos com restrição ([2], [10], [19], [30] e [34]). Vale destacar a referência [7] onde foram desenvolvidos controladores adaptativos robustos com critério de desempenho $\mathcal{H}_\infty$ para sistemas robóticos com restrição de posicionamento e força. Tais controladores podem ser considerados como uma continuidade dos trabalhos feitos em [22] e [14].

Paralelamente ao desenvolvimento de controladores para sistemas sujeitos a restrição, Chang e Chen desenvolveram um controle adaptativo baseado em redes neurais, com critério de desempenho $\mathcal{H}_\infty$, destinado a sistemas robóticos não restritos com incertezas na planta e distúrbios externos, [6]. Eles apresentam uma resposta suave e são implementados de maneira razoavelmente simples e computacionalmente eficiente. Não é necessário ter conhecimento matemático do modelo ou que o modelo seja linearmente parametrizável.

Em [4] é apresentada uma formulação complementar à estratégia proposta em [6]. Trata-se de um controlador adaptativo $\mathcal{H}_\infty$ baseado em redes neurais e em controle por estrutura variável (VSC - *Variable Structure Control*). O uso do VSC se justifica pelo fato de que o erro de estimativa não precisa ser necessariamente integrável, basta que seja limitado por uma função dependente de estado. Essa é uma vantagem considerável em comparação com os controladores mencionados anteriormente.

Baseado nos trabalhos [6], [7] e [4], em [8] foi deduzido um controlador adaptativo $\mathcal{H}_\infty$ baseado em lógica fuzzy e VSC, para sistemas com restrição de posicionamento e força. Outros controladores baseados em sistemas inteligentes podem ser vistos em [1], [5], [25], [31] e [32].

Vale ressaltar que todas essas abordagens de controle inteligente não levam em consideração o modelo matemático dos manipuladores.

1.4 Objetivos Fundamentais

Este trabalho propõe o desenvolvimento de controladores $\mathcal{H}_\infty$ não-lineares adaptativos baseados em sistemas inteligentes (modelo Takagi-Sugeno e Redes Neurais) para manipuladores com restrição de posicionamento e força, com o objetivo de atenuar os efeitos das incertezas paramétricas, dinâmicas não modeladas e distúrbios externos.

Diferente de [1], [8], [5], as estratégias propostas neste trabalho estimam somente incertezas paramétricas e atenuam os efeitos das dinâmicas não modeladas e distúrbios externos, atuando como complemento do modelo matemático do robô. Um estudo comparativo mostra as vantagens dessa abordagem com relação aos controladores propostos em [8]. Também, um dos objetivos desse trabalho é desenvolver um sensor para medição de forças e momentos em três eixos ortogonais.

Os resultados experimentais desse projeto foram obtidos através de um manipulador robótico planar com três juntas rotacionais denominado Underactuated Arm II (UArmII).

1.5 Disposição dos Capítulos

A sequência dessa dissertação está organizada em quatro capítulos. No Capítulo 2 é apresentado o funcionamento mecânico e eletrônico do sensor desenvolvido. No Capítulo 3 é feita uma breve introdução ao controle de manipuladores de base fixa, controle de rigidez e controle híbrido de posição e força. O Capítulo 4 apresenta os controladores inteligentes utilizados nesta dissertação. Finalmente, no Capítulo 5 é feita a implementação dos controladores no ambiente de simulação e controle de manipuladores restritos (ASCM-R), e também é apresentada uma análise comparativa dos controladores propostos.

Capítulo 2

Sensor para medição de força/momento em três eixos ortogonais

Neste capítulo será descrito o funcionamento do sensor desenvolvido. Na primeira seção a parte mecânica é detalhada e na segunda seção o funcionamento eletrônico do sensor é analisado.

2.1 Funcionamento Mecânico

A Figura 2.1 é composta de duas partes, sendo a primeira formada pela parte móvel do sensor e a segunda pela parte fixa. A primeira parte (1) é representada pela Figura 2.2; esta se subdivide em base de atuação (3), corpo de transmissão de forças e momentos (4) normais ao plano da base (3) e pinos de transmissão de forças e momentos (5A-5C) paralelos ao plano da base (3). A utilização da base (3) teve o intuito apenas de facilitar a transmissão das forças ao corpo de transmissão (4), sendo assim a substituição de (3) por qualquer outra forma de fixação fica a critério das especificidades de cada utilização.

A segunda parte (2) é apresentada na Figura 2.3; internamente há sensores de força unidirecionais, sendo o conjunto inferior (9A,9B-11A,11B), responsável pela medição de forças e momentos paralelos ao plano da base e o conjunto superior (16A,16B-18A,18B), responsável pela medição de forças e momentos normais ao plano da base. Estes são respectivamente tencionados pelos pinos de transmissão de forças e momentos (5A-5C), e pelo corpo de transmissão

Figura 2.1: Descrição detalhada do sensor de força.

Figura 2.2: Parte superior do sensor.

de forças e momentos (4), de forma proporcional às forças aplicadas na base (3) ou a qualquer objeto fixo a (4). A parte inferior (2) do sensor se subdivide em corpo (6) responsável por fixar os sensores (16A-18A), anel de espaçamento (7) entre (6) e (8), e corpo de fixação (8) para os sensores (9A,9B-11A,11B) e (16B-18B).

Figura 2.3: Parte inferior do sensor.

Através das figuras 2.4 e 2.5 pode-se verificar a forma como as forças normais são obtidas. A Figura 2.4 foi dividida em duas vistas (a) e (b), isto foi feito somente para facilitar a visualização da mesma. Na Figura 2.4 há seis sensores (16A,16B-18A,18B) de força posicionados em pares, de forma simétrica e distribuídos em 120 graus. Os sensores foram organizados em pares, por medirem força em apenas um sentido, logo a composição de dois sensores torna possível a medição de força na direção desejada. Como pode ser observado, cada par de sensores é tencionado de forma proporcional ao movimento realizado pelo corpo de transmissão de forças e momentos (4). Com isso a composição das forças nos três pontos medidos pelos pares de sensores torna possível a cálculo das forças e momentos normais ao plano da base. Esses três pontos podem ser facilmente visualizados na Figura 2.5, se referem às três circunferências externas.

Esses pares de sensores são organizados de forma esquemática na Figura 2.5, sendo F_{1A} e F_{1B} o primeiro par de sensores (16A,16B), F_{2A} e F_{2B} o segundo par (18A,18B), F_{3A} e F_{3B} o terceiro par (17A,17B). Com isso as forças resultantes nesses três pontos podem ser expressas como:

$$F_1 = F_{1A} - F_{1B},$$

Figura 2.4: Corpo de transmissão de forças (4) e sensores para medição de forças momentos normais ao plano da base(3).

Figura 2.5: Desenho esquemático de funcionamento do sensor.

$$F_2 = F_{2A} - F_{2B},$$

$$F_3 = F_{3A} - F_{3B}.$$

Como pode ser observado F_1 , F_2 e F_3 formam um triângulo equilátero, sendo d_2 o lado deste. Em [9], é demonstrado que se três células de carga, com medição de força em uma direção, estiverem organizadas triangularmente e estas forem os vértices desse triângulo com direção de medição normais ao plano formado pelo triângulo, então as seguintes grandezas físicas podem ser calculas:

$$F_x = F_1 + F_2 + F_3,$$

$$M_y = d_2 \frac{F_1 - F_2 - (F_3 - F_1)}{2\sqrt{3}},$$

$$M_z = \frac{d_2(F_3 - F_2)}{2},$$

sendo F_x , M_y e M_z a força ao longo do eixo x e os momentos ao longo dos respectivos eixos y e z.

Já nas Figuras 2.5, 2.6 e 2.7 a explanação será referente ao cálculo das forças paralelas ao plano da base. Nas Figuras 2.6 e 2.7 há seis sensores (9A,9B-11A,11B) de força posicionados em pares, de forma simétrica e distribuídos em 120 graus uns dos outros. Cada par de sensores é tencionado de forma proporcional ao movimento realizado pelos pinos de transmissão de forças e momentos (5A-5C). Com isso a composição das forças nos três pontos medidos pelos pares de sensores torna possível a medição das forças e momentos paralelos ao plano da base. Esses três pontos podem ser facilmente visualizados na Figura 2.5, onde os mesmos equivalem às três circunferências destacadas em vermelho.

Esses pares de sensores são organizados de forma esquemática na Figura 2.5, sendo F_{4A} e F_{4B} o primeiro par de sensores (9A,9B), F_{5A} e F_{5B} o segundo par (10A,10B), F_{6A} e F_{6B} o terceiro par (11A,11B). Com isso as forças resultantes nesses três pontos podem ser expressas como:

$$F_4 = F_{4A} - F_{4B},$$

$$F_5 = F_{5A} - F_{5B},$$

$$F_6 = F_{6A} - F_{6B}.$$

Como pode ser observado F_4 , F_5 e F_6 formam um triângulo equilátero, sendo d_1 a dimensão

Figura 2.6: Corpo de fixação dos sensores de força, vista frontal.

Figura 2.7: Corpo de fixação dos sensores para medição de forças e momentos paralelos ao plano da base, vista inferior.

de cada lado. Em [9], é demonstrado que se três células de carga, com medição de força em uma direção, estiverem organizadas triangularmente e se forem os vértices desse triângulo com direção de medição tangente aos vértices do triângulo, então as seguintes grandezas físicas podem ser calculadas:

$$F_y = \frac{F_5 - F_4 - (F_4 - F_6)}{2},$$

$$F_z = \frac{\sqrt{3}(F_5 - F_6)}{2},$$

$$M_x = \frac{-d_1(F_4 + F_5 + F_6)}{2\sqrt{3}},$$

sendo F_y , F_z e M_x as forças ao longo dos respectivos eixos y e z, e o momento ao longo do eixo x.

2.2 Funcionamento Eletrônico

A descrição do circuito eletrônico do sensor se baseia na Figura 2.8. Nos blocos 1 e 2 da Figura 2.8 é exibido o esquema elétrico resumido da placa de condicionamento dos sinais elétricos provenientes dos sensores de força. No Bloco 1 encontram-se dois grupos de sensores de força unidirecionais, estes representam os 12 sensores, (9A-11A, 16A-18A) e (9B-11B, 16B-18B), utilizados na montagem proposta. Tais sensores são alimentados por uma tensão diferencial (+Vcc e -Vcc), os sinais de saída provenientes deles também são diferenciais, possibilitando utilizar o INA na configuração de coletor em modo comum: para o primeiro grupo de sensores (F_{IAx} e F_{IAy}) e para o segundo grupo de sensores (F_{IBAx} e F_{IBy}).

O dispositivo semicondutor juntamente com sua forma de polarização apresentado no Bloco 2 da Figura 2.8 é um amplificador operacional de instrumentação (INA), neste caso utilizou-se o INA-2141u, que pode ser facilmente substituído por qualquer outro similar. A placa do circuito impresso é composta por seis INA. Cada INA é responsável por condicionar o sinais das saídas de cada par de sensores de força unidirecionais. Com isso, torna-se possível a medição diferencial das forças aplicadas.

No Bloco 3 da Figura 2.8, são apresentadas duas notações, sendo:

- I uma variável que vai de 1 até 6,

Figura 2.8: Esquema elétrico resumido da placa de condicionamento dos sinais.

- $F_I = k(F_{IAy} - F_{IAx}) - k(F_{IBy} - F_{IBx})$, onde k é o ganho adotado no INA.

Como $(F_{IAy} - F_{IAx})$ é igual a F_{IA} , e $(F_{IBy} - F_{IBx})$ é igual a F_{IB} , então:

$$F_I = k(F_{IA}) - k(F_{IB})$$

A polarização adotada faz com que as saídas (F_I) dos amplificadores sejam as subtrações entre os sinais captados dos dois pares de sensores de força unidirecionais (F_{IA} e F_{IB}). Portanto, caso o esforço no primeiro conjunto de sensores (F_{IA}) seja maior que no segundo conjunto (F_{IB}), então os sinais (F_I) serão positivos; caso contrário negativos.

Com isso conclui-se que os esforços aplicados a base (3) são medidos pelos sensores de força normais (16A,16B - 18A,18B) e planares (9A,9B - 11A,11B). Os sinais provenientes de tais sensores são condicionados por vários INA, e finalmente entregues a uma placa de aquisição de sinais, ou mesmo entregues a qualquer *hardware* que tenha capacidade de processar tais saídas.

2.3 Implementação

Esta seção apresenta as fotos da montagem do sensor.

Na Figura 2.9 são mostrados todos os componentes estruturais que compõe o sensor. Já na Figura 2.10, é demonstrado o processo de montagem, e por fim na Figura 2.11 exibe-se uma foto do Sensor.

Figura 2.9: Componentes estruturais.

Figura 2.10: Fase intermediária da montagem.

Figura 2.11: Sensor montado.

Capítulo 3

Conceitos Preliminares

Robôs manipuladores podem ser representados por um conjunto de corpos rígidos conectados, [33], como na Figura 3.1. Podemos classificar os movimentos dos manipuladores robóticos como não restritos, quando não houver contato entre o efetuador e o meio, e restritos, quando aparecerem forças de contato entre o efetuador e o ambiente de trabalho.

Figura 3.1: Corpos rígidos.

Os conceitos de cinemática e dinâmica de um manipulador são fundamentais para o projeto do sistema de controle. Detalhes desses conceitos podem ser vistos em [13], [24] e [17].

A análise cinemática de um manipulador robótico, consiste em descrever o movimento do manipulador com respeito a uma referência fixa. Nessa análise ignoram-se as forças e momentos

que originam o movimento. A cinemática descreve a relação entre a posição das juntas e a posição/orientação do efetuador robótico. Cinemática pode ser formulada de maneira direta e de maneira inversa. A cinemática direta calcula a posição do efetuador robótico em função das posições das juntas. A cinemática inversa descreve as posições das juntas a partir da posição do efetuador.

Nessa dissertação não utilizaremos controle baseado em cinemática. Os controladores considerados serão baseados no modelo dinâmico do robô. A maioria dos manipuladores robóticos são acionados por energia elétrica, hidráulica, ou pneumática. Tais fontes de energia aplicam torques (ou forças, no caso de atuadores lineares), movimentando as juntas robóticas. Através da análise do modelo dinâmico são fornecidas informações para se calcular as forças e torques necessários para a execução do movimento.

Existem diversos métodos para se deduzir as equações dinâmicas de manipuladores. Todos os métodos geram conjuntos equivalentes de equações. Um dos procedimentos mais utilizados para se deduzir essas equações é o elaborado por Lagrange que é baseado nas seguintes leis físicas:

$$\tau = \frac{d}{dt} \left(\frac{\partial L}{\partial \dot{q}} \right) - \left(\frac{\partial L}{\partial q} \right), \quad (3.1)$$

sendo que $\tau \in \mathbb{R}^n$ é o vetor de forças generalizadas exercidas sobre as juntas robóticas. Tais juntas são representadas de forma generalizada no vetor q , e $L(q, \dot{q})$ é o Lagrangiano do sistema, sendo definido por

$$L(q, \dot{q}) =: K(q, \dot{q}) - U(q), \quad (3.2)$$

com $K(q, \dot{q})$ sendo a energia cinética do sistema e $U(q)$ a energia potencial.

Para sistemas robóticos rígidos, a energia cinética é dada por:

$$K(q, \dot{q}) =: \sum_{i=1}^n \left(\frac{1}{2} m_i v_i^T v_i + \frac{1}{2} \omega_i^T R_i^0 I_i R_i^{0T} \omega_i \right), \quad (3.3)$$

sendo m_i a massa, v_i e ω_i respectivamente as velocidades linear e angular do centro de massa, I_i o tensor de inércia do i -ésimo elo do manipulador, R_i^0 a matriz de rotação do eixo de coordenadas sobre o centro de massa do i -ésimo elo (Eixo i) em relação ao eixo de coordenadas inercial (Eixo 0).

A Equação (3.3) é uma função quadrática do vetor $\dot{q}$ na forma

$$K(q, \dot{q}) = \frac{1}{2} \dot{q}^T \sum_{i=1}^n \left(m_i J_{v_i}^T(q) J_{v_i}(q) + J_{\omega_i^0}^T(q) R_i^0 I_i R_i^{0T} J_{\omega_i^0}(q) \right) \dot{q} = \frac{1}{2} \dot{q}^T M(q) \dot{q}, \quad (3.4)$$

sendo J_{v_i} a Jacobiana que relaciona as velocidades das coordenadas das juntas com a velocidade do centro de massa do elo i e $J_{\omega_i^0}$ a Jacobiana que relaciona as velocidades das coordenadas das juntas com a velocidade angular do elo i , ou seja,

$$\begin{bmatrix} v_i \\ \omega_i \end{bmatrix} = \begin{bmatrix} J_{v_i}(q) \\ J_{\omega_i^0}(q) \end{bmatrix} \dot{q} = J_i(q) \dot{q}. \quad (3.5)$$

Portanto, as equações de movimento são desenvolvidas a partir de (3.1),

$$\begin{aligned} \tau &= \frac{d}{dt} \frac{\partial}{\partial \dot{q}} (K(q, \dot{q}) - U(q)) - \frac{\partial}{\partial q} (K(q, \dot{q}) - U(q)) \\ &= \frac{d}{dt} \left(\frac{\partial K(q, \dot{q})}{\partial \dot{q}} \right) - \frac{\partial K(q, \dot{q})}{\partial q} + \frac{\partial U(q)}{\partial q} \\ &= \frac{d}{dt} \frac{\partial}{\partial \dot{q}} \left(\frac{1}{2} \dot{q}^T M(q) \dot{q} \right) - \frac{\partial}{\partial q} \left(\frac{1}{2} \dot{q}^T M(q) \dot{q} \right) + \frac{\partial U(q)}{\partial q} \\ &= [M(q) \ddot{q}] + \left[\dot{M}(q) \dot{q} - \frac{1}{2} \frac{\partial (\dot{q}^T M(q) \dot{q})}{\partial q} \right] + \left[\frac{\partial U(q)}{\partial q} \right] \\ \tau &= M(q) \ddot{q} + h(q, \dot{q}) + G(q), \end{aligned} \quad (3.6)$$

com

$$\begin{aligned} h(q, \dot{q}) &= \left[\dot{M}(q) \dot{q} - \frac{1}{2} \frac{\partial (\dot{q}^T M(q) \dot{q})}{\partial q} \right], \\ G(q) &= \left[\frac{\partial U(q)}{\partial q} \right]. \end{aligned}$$

A matriz de inércia $M(q) \in \mathbb{R}^{n \times n}$ é simétrica e definida positiva. O vetor $h(q, \dot{q}) \in \mathbb{R}^n$ é composto pelas forças de Coriolis e centrípetas e o vetor $G(q) \in \mathbb{R}^n$ expressa as forças gravitacionais. As juntas robóticas, q_i , podem ser expressas por θ_i no caso de juntas rotacionais e por d_i no caso de junta prismáticas. O vetor de forças generalizadas, τ_i , é composto por torques e forças aplicados às juntas.

Pode-se escrever o vetor das forças de Coriolis na forma

$$h(q, \dot{q}) = C(q, \dot{q})\dot{q}, \quad (3.7)$$

tal que a matriz

$$N(q, \dot{q}) = \dot{M}(q) - 2C(q, \dot{q}) \quad (3.8)$$

seja anti-simétrica, [11].

Uma característica interessante para o controle de manipuladores é a propriedade de parametrização linear da equação dinâmica, ou seja, é possível encontrar uma matriz $Y(q, \dot{q}, \ddot{q}) \in \mathbb{R}^{n \times m}$, chamada matriz de regressão, tal que:

$$M(q)\ddot{q} + h(q, \dot{q}) + G(q) = Y(q, \dot{q}, \ddot{q})\theta, \quad (3.9)$$

sendo $\theta \in \mathbb{R}^m$ um vetor de parâmetros do manipulador.

3.1 Controle de Força para Manipuladores Robóticos

Em aplicações robóticas tais como montagens, polimento, entre outras, o efetuador robótico entra em contato com o ambiente. Isto faz com que apareçam forças de contato entre o efetuador e o ambiente de trabalho. Se tais forças não forem controladas, os manipuladores poderão exercer forças suficientes para danificar as ferramentas de trabalho ou o próprio objeto que o mesmo esteja manipulando.

Portanto, nesses sistemas, tanto a posição do efetuador quanto a força por ele exercida ao meio devem seguir uma trajetória pré-definida.

Para demonstrar melhor o problema de controle híbrido de posição/força, considere a situação onde temos que controlar um manipulador para escrever em uma lousa. Para desenhar as letras no quadro precisamos controlar a posição do giz. Mas a força também deve ser controlada, pois caso o manipulador exerça pouca força as letras ficarão ilegíveis, e caso este exerça mais força do que o necessário provavelmente quebrará o giz. Portanto, nesta e em muitas outras aplicações robóticas o controlador deverá seguir tanto trajetória de posição quanto de força, [13].

Utilizando a mesma metodologia do equacionamento de Lagrange, temos que a equação dinâmica para um manipulador sujeito a restrição de uma superfície de contato pode ser expresso

por (3.6) acrescida pela força exercida pelo efetuador:

$$M(q)\ddot{q} + h(q, \dot{q}) + G(q) = \tau + f.$$

3.1.1 Controle de Rigidez

As aplicações industriais de robôs manipuladores amplamente utilizadas nas primeiras gerações dessa classe de robôs não entravam em contato físico com os objetos (por exemplo, pintura pulverizada) ou, quando entravam, a força de contato não importava para conclusão da tarefa (por exemplo em transporte de peças pesadas), uma vez que somente a posição do efetuador importava. Com isso, os manipuladores foram desenvolvidos de forma bem rígida permitindo um preciso posicionamento através de leis de controle relativamente simples. Aplicações envolvendo controle de força acrescentam um grau de dificuldade considerável no sistema de controle do robô.

O controle dito de rigidez de robôs manipuladores pode ser projetado a partir de um modelo massa-mola, como apresentado na Figura 3.2, onde τ é o torque aplicado pelo manipulador, k_e é a constante de rigidez, x_e a posição estática do efetuador, x a posição atingida e x_d a posição desejada. Neste exemplo as forças gravitacionais e de atrito foram desconsideradas, a expressão do torque é dada por

$$\tau = m\ddot{x} + k_e(x - x_e). \quad (3.10)$$

Figura 3.2: Modelo massa mola.

3.1.2 Controle Híbrido de Posição e Força

A grande desvantagem do controle de rigidez apresentado na seção 3.1.1 é que ele pode controlar somente pontos direcionados, ou seja, a posição desejada do efetuador robótico e a força exercida por ele no ambiente devem ser constantes. Em muitas aplicações robóticas, tais como em fresamento e polimento, o efetuador deverá seguir uma trajetória de posição ao longo

da superfície de um objeto enquanto exerce uma força sobre a superfície do mesmo. Nestes tipos de aplicações o controle de rigidez não é adequado.

O chamado controlador híbrido de posição e força ([3] e [22]), é utilizado para acompanhamento de trajetória de posição e força simultaneamente. O conceito básico deste tipo de controlador está no desacoplamento do controle de posição e de força. Tornando possível determinar quais componentes da posição e da força devem ser controladas.

Considere o exemplo da Figura 3.3, onde há um manipulador contendo duas juntas prismáticas. Nesta aplicação a posição percorrida ao longo da superfície e a força normal a esta deverão ser controladas.

Figura 3.3: Robô cartesiano.

O desenvolvimento deste tipo de controlador inicia-se por transformar as coordenadas do espaço das juntas no espaço cartesiano. Para facilitar, neste exemplo o espaço das juntas coincide com o espaço cartesiano, portanto temos:

$$x = \begin{bmatrix} u \\ v \end{bmatrix} = h(q) = \begin{bmatrix} q_1 \\ q_2 \end{bmatrix}, \quad (3.11)$$

sendo que x representa as coordenadas generalizadas no espaço da tarefa, u e v representam respectivamente a direção da força normal e a direção da trajetória de posição a serem controladas, $h(q)$ uma função que leva do espaço das juntas para o espaço da tarefa.

A matriz Jacobiana no espaço cartesiano é dada por,

$$J = \frac{\partial h(q)}{\partial q} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}.$$

Com isso a equação dinâmica para este caso é dada por:

$$\tau = M(q)\ddot{q} + G(q) + f, \quad (3.12)$$

sendo τ o torque aplicado, M a matriz de inércia, G o vetor de forças gravitacionais, f o vetor da restrição de forças. As duas equações dinâmicas dadas na forma de matriz representada por (3.12) são

$$\tau_1 = m_1\ddot{q}_1 + f_1 \quad (3.13)$$

e

$$\tau_2 = (m_1 + m_2)\ddot{q}_2 + (m_1 + m_2)g + f_2. \quad (3.14)$$

As Equações (3.13) e (3.14) podem ser rescritas como:

$$\tau_1 = m_1 a_n + f_1 \quad (3.15)$$

e

$$\tau_2 = (m_1 + m_2)a_t + (m_1 + m_2)g + f_2. \quad (3.16)$$

sendo: $a_n = \ddot{q}_1$ e $a_t = \ddot{q}_2$.

Na formulação de controladores híbridos para posicionamento e força, desenvolve-se controladores distintos para as equações dinâmicas (3.13) e (3.14). Como mostrado nas equações (3.15) e (3.16), os termos a_n e a_t correspondem aos controladores responsáveis por manter a trajetória desejada de posicionamento de q_2 ao longo da superfície de contato, e por controlar a força normal desejada a esta superfície.

O exemplo do manipulador prismático de duas juntas, pode ser facilmente estendido para um manipulador de n-elos. Para isso o desenvolvedor deve inicialmente escolher a formulação no espaço da tarefa para o manipulador, com o objetivo de que o movimento normal e o tangente

a superfície de contato sejam decompostos, como discutido acima. Portanto, tem-se:

$$x = h(q). \quad (3.17)$$

Então deve-se escrever a equação dinâmica do movimento (3.12) em função da aceleração no espaço da tarefa, portanto derivando duas vezes a equação (3.17), tem-se:

$$\begin{aligned} \dot{x} &= \frac{\partial h(q)}{\partial q} \frac{dq}{dt} = J\dot{q}, \\ \ddot{x} &= J\ddot{q} + \dot{J}\dot{q}, \end{aligned} \quad (3.18)$$

sendo J a Jacobiana no espaço Cartesiano. Isolando o $\ddot{q}$ na equação (3.18), tem-se

$$\ddot{q} = J^{-1}(q)(\ddot{x} - \dot{J}(q)\dot{q}), \quad (3.19)$$

e substituindo (3.19) em (3.12), temos a equação dinâmica do movimento no espaço cartesiano:

$$\tau = M(q)J^{-1}(q)(\ddot{x} - \dot{J}(q)\dot{q}) + G(q) + f. \quad (3.20)$$

Da mesma forma como feito no exemplo anterior, reescreve-se a equação (3.20) como:

$$\tau = M(q)J^{-1}(q)(a - \dot{J}(q)\dot{q}) + G(q) + f, \quad (3.21)$$

sendo $a = \ddot{x}$. Como o problema de controle deve ser dividido em tarefas, divide-se então o espaço das componentes tangentes de x como x_{T_i} , sendo que T é a notação para tangente e i corresponde a i -ésima componente de x_T , a qual é responsável por controlar o posicionamento do efetuador ao longo da superfície de contato. Portanto:

$$\ddot{x}_{T_i} = a_{T_i}. \quad (3.22)$$

Para o controle de força, define-se o espaço das componentes normais de x como x_{N_j} , sendo que N é a notação para normal e j corresponde a j -ézima componete de x_N , a qual é responsável por controlar a força normal à superfície de contato. Portanto:

$$\ddot{x}_{N_i} = a_{N_i}. \quad (3.23)$$

Portanto neste capítulo foram resumidamente apresentados os conceitos básicos necessários para que o leitor não familiarizado consiga entender as próximas seções. Com isso, no próximo capítulo serão apresentadas as formulações matemáticas para os controladores desenvolvidos.

Capítulo 4

Controladores Adaptativos para Manipuladores com Restrição

Neste capítulo será apresentada a formulação do problema de controle de robôs manipuladores sujeitos a restrições nos efetadores. Também, serão apresentadas estratégias de controle baseadas em sistemas inteligentes (Fuzzy e Redes Neurais) com desempenho $\mathcal{H}_\infty$. Os itens tratados neste capítulo são:

- Modelo do Manipulador com Restrição
- Formulação do Problema
- Estimadores Baseados em Sistemas Inteligentes
 - Estimador Baseado em Redes Neurais estimando Incertezas Paramétricas
 - Estimador Baseado em Redes Neurais estimando Modelo Completo
 - Estimador baseado no Modelo Fuzzy Takagi-Sugeno estimando Incertezas Paramétricas
 - Estimador baseado no Modelo Fuzzy Takagi-Sugeno estimando Modelo Completo
- Controle Adaptativo $\mathcal{H}_\infty$ Não Linear

4.1 Modelo do Manipulador com Restrição

Considere um manipulador robótico sujeito a restrições holonômicas em seu efetuador. A equação para as m restrições é dada da seguinte forma

$$\phi(q) = 0, \quad (4.1)$$

sendo $q \in \mathbb{R}^n$ são as posições das juntas e $\phi(q) : \mathbb{R}^n \rightarrow \mathbb{R}^m$ é uma função amortecida. A equação dinâmica da restrição robótica é dada pela teoria de Lagrange como

$$M(q)\ddot{q} + C(q, \dot{q})\dot{q} + G(q) = \tau + J^T(q)\lambda + d, \quad (4.2)$$

sendo $M(q) \in \mathbb{R}^{n \times n}$ a matriz de inércia simétrica e positiva, $C(q, \dot{q}) \in \mathbb{R}^{n \times n}$ a matriz de Coriolis e termos centrífugos, $G(q) \in \mathbb{R}^n$ os torques devido a força gravitacional, $\tau \in \mathbb{R}^n$ os torques aplicados, $\lambda \in \mathbb{R}^m$ o vetor dos multiplicadores generalizados de Lagrange associados com as restrições, $J(q) = (\partial\phi/\partial q) \in \mathbb{R}^{m \times n}$ a matriz Jacobiana que relaciona os multiplicadores Lagrangianos no espaço da restrição para o espaço das juntas, e $d \in \mathbb{R}^n$ representa os distúrbios externos e dinâmicas não modeladas do sistema.

Se a restrição holonômica for considerada independente, então a matriz Jacobiana $J(q)$ terá posto linha pleno de ordem m para todo $q \in \mathbb{R}^n$, portanto o vetor q pode ser particionado como,

$$q = \begin{bmatrix} q^1 \\ q^2 \end{bmatrix}, \quad (4.3)$$

sendo que $q^1 = [q_1^1 \dots q_{n-m}^1]^T$ descreve a restrição do movimento do manipulador e $q^2 = [q_1^2 \dots q_m^2]^T$ representa as demais juntas do manipulador.

Pode-se entender q^1 como sendo as variáveis linearmente independentes e q^2 as variáveis linearmente dependentes deste sistema. Com isso, pelo teorema da função implícita podemos escrever que:

$$q^2 = \sigma(q^1),$$

sendo $\sigma : \Omega_c \rightarrow \mathbb{R}^m$ tal que $\phi(q^1, \sigma(q^1)) = 0$ e $\Omega_c \subseteq \mathbb{R}^{n-m}$ um conjunto aberto.

Portanto, desde que o sistema esteja sujeito a m restrições, este perderá m graus de liberdade em seu movimento, e conseqüentemente (4.2) poderá ser reescrito na forma reduzida como em

[8, 21]. Os passos para isso são demonstrados abaixo: Deriva-se o vetor $q = [(q^1)^T \ (q^2)^T]^T$,

$$\dot{q} = \begin{bmatrix} \dot{q}^1 \\ \dot{q}^2 \end{bmatrix} = \begin{bmatrix} \dot{q}^1 \\ \frac{\partial \sigma(q^1)}{\partial q^1} \frac{dq^1}{dt} \end{bmatrix} = \begin{bmatrix} I_{n-m} \\ \frac{\partial \sigma(q^1)}{\partial q^1} \end{bmatrix} \dot{q}^1.$$

Definem-se

$$L(q^1) = \begin{bmatrix} I_{n-m} \\ \frac{\partial \sigma(q^1)}{\partial q^1} \end{bmatrix} \quad \text{e} \quad \dot{q} = L(q^1) \dot{q}^1. \quad (4.4)$$

Deriva-se $\dot{q}$,

$$\ddot{q} = \dot{L}(q^1) \dot{q}^1 + L(q^1) \ddot{q}^1.$$

Substituindo $\ddot{q}$ e $\dot{q}$ em (4.2), temos:

$$\begin{aligned} M(q^1) \left[\dot{L}(q^1) \dot{q}^1 + L(q^1) \ddot{q}^1 \right] + C(q^1, \dot{q}^1) L(q^1) \dot{q}^1 + G(q^1) &= \tau + J^T(q^1) \lambda + d \\ M(q^1) L(q^1) \ddot{q}^1 + M(q^1) \dot{L}(q^1) \dot{q}^1 + C(q^1, \dot{q}^1) L(q^1) \dot{q}^1 + G(q^1) &= \tau + J^T(q^1) \lambda + d. \end{aligned}$$

Portanto a Equação (4.2) na forma reduzida pode ser escrita como:

$$M(q^1) L(q^1) \ddot{q}^1 + C_L(q^1, \dot{q}^1) \dot{q}^1 + G(q^1) = \tau + J^T(q^1) \lambda + d, \quad (4.5)$$

onde

$$C_L(q^1, \dot{q}^1) \dot{q}^1 = M(q^1) \dot{L}(q^1) \dot{q}^1 + C(q^1, \dot{q}^1) L(q^1) \dot{q}^1.$$

A Equação (4.5) tem as seguintes propriedades, [30]:

P1: A matriz $A_L(q^1) = L^T(q^1) M(q^1) L(q^1)$ é simétrica e positiva definida. Seja λ_{a_l} o mínimo autovalor de $A_L(q^1)$, para todo $q^1 \in \Omega$. Então $\lambda_{a_l} I \leq A_L(q^1)$.

P2: A matriz $\dot{A}_L(q^1) - 2L^T(q^1) C_L(q^1, \dot{q}^1)$ é anti-simétrica.

P3: $J(q^1) L(q^1) = L^T(q^1) J^T(q^1) = 0$.

P4: A dinâmica do manipulador pode ser parametrizada linearmente:

$$M(q^1) L(q^1) \dot{s} + C_L(q^1, \dot{q}^1) s + G(q^1) = Y(q^1, \dot{q}^1, s, \dot{s}) \Theta^*, \forall s \in R^{n-m}.$$

4.2 Formulação do Problema

Pré-multiplicando ambos os lados de (4.5) por $L^T(q^1)$, temos

$$L^T(q^1)M(q^1)L(q^1)\ddot{q}^1 + L^T(q^1)C_L\dot{q}^1 + L^T(q^1)G(q^1) = L^T(q^1)\tau + L^T(q^1)J^T(q)\lambda + L^T(q^1)d.$$

Pela propriedade P3 temos $L^T(q^1)J^T(q) = 0$, portanto,

$$L^T(q^1)M(q^1)L(q^1)\ddot{q}^1 + L^T(q^1)C_L(q^1, \dot{q}^1)\dot{q}^1 + L^T(q^1)G(q^1) = L^T(q^1)(\tau + d)$$

ou, equivalentemente pela propriedade P1,

$$A_L(q^1)\ddot{q}^1 + L^T(q^1)C_L(q^1, \dot{q}^1)\dot{q}^1 + L^T(q^1)G(q^1) = L^T(q^1)(\tau + d). \quad (4.6)$$

Os erros de acompanhamento de trajetória $\bar{x}_1(t)$ e $\bar{x}_2(t)$ são definidos como ([8] e [21]),

$$\bar{x}(t) \doteq \begin{bmatrix} \bar{x}_1 \\ \bar{x}_2 \end{bmatrix} = \begin{bmatrix} q^1(t) - q_d^1(t) \\ \dot{q}^1(t) - \dot{q}_d^1(t) + p(q^1(t) - q_d^1(t)) \end{bmatrix}, \quad (4.7)$$

para uma constante $p > 0$. A trajetória de referência $q_d^1(t)$ e sua derivada de segunda ordem são assumidas como sendo limitadas, e pertencentes a um conjunto compacto Ω_d . Para se obter a equação dinâmica modificada do erro, deriva-se $\bar{x}_1(t)$ em relação ao tempo

$$\dot{\bar{x}}_1 = \dot{q}^1 - \dot{q}_d^1,$$

soma-se e subtrai o termo $p\bar{x}_1$ da equação acima,

$$\begin{aligned} \dot{\bar{x}}_1 &= \dot{q}^1 - \dot{q}_d^1 + p\bar{x}_1 - p\bar{x}_1 \\ \dot{\bar{x}}_1 &= \bar{x}_2 - p\bar{x}_1, \end{aligned} \quad (4.8)$$

deriva-se $\bar{x}_2(t)$, em relação ao tempo

$$\dot{\bar{x}}_2 = \ddot{q}^1 - \ddot{q}_d^1 + p(\dot{q}^1 - \dot{q}_d^1),$$

prémultiplicam-se ambos os lados por $A_L(q^1)$,

$$A_L(q^1)\dot{\bar{x}}_2 = A_L(q^1)\dot{q}^1 - A_L(q^1)\ddot{q}_d^1 + A_L(q^1)p(\dot{q}^1 - \dot{q}_d^1) \quad (4.9)$$

isola-se $A_L(q^1)\ddot{q}^1$ na equação (4.6),

$$A_L(q^1)\ddot{q}^1 = -L^T(q^1)C_L(q^1, \dot{q}^1)\dot{q}^1 - L^T(q^1)G(q^1) + L^T(q^1)(\tau + d),$$

substitui-se $A_L(q^1)\dot{q}^1$ na equação (4.9),

$$\begin{aligned} A_L(q^1)\dot{\bar{x}}_2 &= -L^T(q^1)C_L(q^1, \dot{q}^1)\dot{q}^1 - L^T(q^1)G(q^1) + L^T(q^1)(\tau + d) \\ &\quad - A_L(q^1)\ddot{q}_d^1 + A_L(q^1)p(\dot{q}^1 - \dot{q}_d^1) \end{aligned} \quad (4.10)$$

isola-se $\dot{q}^1$ na segunda linha da equação (4.7),

$$\dot{q}^1 = \bar{x}_2 + \dot{q}_d^1 - p(q^1 - q_d^1)$$

substitui-se $\dot{q}^1$ na equação (4.10) e considera-se $\dot{q}^1 - \dot{q}_d^1 = \dot{\bar{x}}_1$

$$\begin{aligned} A_L(q^1)\dot{\bar{x}}_2 &= -L^T(q^1) \{ M(q^1)L(q^1) (\ddot{q}_d^1 - p\dot{\bar{x}}_1) + C_L (\dot{q}_d^1 - p\bar{x}_1) + G(q^1) \} \\ &\quad - L^T(q^1)C_L(q^1, \dot{q}^1)\bar{x}_2 + L^T(q^1)(\tau + d) \\ A_L(q^1)\dot{\bar{x}}_2 &= -L^T(q^1)C_L(q^1, \dot{q}^1)\bar{x}_2 + L^T(q^1)(-F(x_e) + \tau + d) \end{aligned} \quad (4.11)$$

sendo,

$$\begin{aligned} F(x_e) &= M(q^1)L(q^1) (\ddot{q}_d^1 - p\dot{\bar{x}}_1) + C_L (\dot{q}_d^1 - p\bar{x}_1) + G(q^1) \\ x_e &\doteq [(q^1)^T \quad (\dot{q}^1)^T \quad (q_d^1)^T \quad (\dot{q}_d^1)^T \quad (\ddot{q}_d^1)^T]^T. \end{aligned}$$

O termo $F(x_e)$ consiste do modelo nominal do sistema. Este pode ser visto como o modelo matemático conhecido para um manipulador robótico planar de n elos. De acordo com a propriedade de parametrização linear P4 vista acima, o termo $F(x_e)$ pode ser escrito com:

$$F(q^1, \dot{q}^1, q_d^1, \dot{q}_d^1, \ddot{q}_d^1) = Y(q^1, \dot{q}^1, \dot{q}_d^1 - p\bar{x}_1, \ddot{q}_d^1 - p\dot{\bar{x}}_1)\Theta^*, \quad (4.12)$$

sendo Y uma matriz de regressão, e o vetor Θ^* o vetor de ajuste. Portanto as equações dinâmicas modificadas do erro que foram obtidas são:

$$\dot{\bar{x}}_1 = \bar{x}_2 - p\bar{x}_1 \quad (4.13)$$

$$A_L(q^1)\dot{\bar{x}}_2 = -L^T(q^1)C_L(q^1, \dot{q}^1)\bar{x}_2 + L^T(q^1)(-F(x_e) + \tau + d). \quad (4.14)$$

Incertezas paramétricas podem ser inseridas em (4.2), dividindo-se as matrizes paramétricas $M(q)$, $C(q, \dot{q})$ e $G(q)$ em uma parte nominal e uma com perturbação:

$$M(q) = M_0(q) + \Delta M(q)$$

$$C(q, \dot{q}) = C_0(q, \dot{q}) + \Delta C(q, \dot{q})$$

$$G(q) = G_0(q) + \Delta G(q)$$

sendo $M_0(q)$, $C_0(q, \dot{q})$, e $G_0(q)$ matrizes nominais e $\Delta M(q)$, $\Delta C(q, \dot{q})$, e $\Delta G(q)$ as incertezas paramétricas. Então, $F(x_e)$ pode ser expressado como

$$F(x_e) = F_0(x_e) + \Delta F(x_e), \quad (4.15)$$

sendo $F_0(x_e)$ a parte nominal de $F(x_e)$ calculada com $M_0(q)$, $C_0(q, \dot{q})$, e $G_0(q)$; $\Delta F(x_e)$ a parte incerta calculada com $\Delta M(q)$, $\Delta C(q, \dot{q})$, e $\Delta G(q)$. Portanto a equação dinâmica do erro modificada pode ser reescrita como,

$$A_L(q^1)\dot{\bar{x}}_2 = -L^T(q^1)C_L(q^1, \dot{q}^1)\bar{x}_2 + L^T(q^1)(-F_0(x_e) - \Delta F(x_e) + \tau + d). \quad (4.16)$$

4.3 Estimadores Baseados em Sistemas Inteligentes

O controlador adaptativo $\mathcal{H}_\infty$ não linear proposto neste trabalho é baseado na combinação de duas abordagens: uma baseada no modelo matemático nominal do manipulador e outra baseada sistemas inteligentes para estimar as incertezas do manipulador. Vamos descrever a seguir, quatro procedimentos de projeto baseados em redes neurais e em lógica fuzzy.

4.3.1 Estimativa das Incertezas Paramétricas Baseada em Redes Neurais - RNIP

Redes neurais podem ser utilizadas para estimar o termo desconhecido $\Delta F(x_e)$ em (4.16), parametrizado como em (4.12). Utiliza-se para isto uma rede neural adaptativa, $\Delta F(x_e, \Theta)$, seguindo a linha proposta em [6] e [4]. Definem-se n redes $\Delta F_k(x_e, \Theta_k)$, $k = 1, \dots, n$. Tais redes são compostas de neurônios não lineares nas camadas intermediárias (ou escondidas), e de neurônios lineares nas camadas de entrada e saída. A camada de saída contém pesos ajustáveis Θ_k . A forma de cada rede da camada de saída é mostrada a seguir,

$$\begin{aligned} \Delta F_k(x_e, \Theta_k) &= \sum_{i=1}^{p_k} H \left(\sum_{j=1}^{5n} w_{ij}^k x_{ej} + m_i^k \right) \Theta_{ki} \\ &= \xi_k^T \Theta_k \end{aligned} \quad (4.17)$$

com

$$\xi_k = \begin{bmatrix} H \left(\sum_{j=1}^{5n} w_{1j}^k x_{ej} + m_1^k \right) \\ \vdots \\ H \left(\sum_{j=1}^{5n} w_{p_k j}^k x_{ej} + m_{p_k}^k \right) \end{bmatrix}$$

e

$$\Theta_k = \begin{bmatrix} \Theta_{k1} \\ \vdots \\ \Theta_{kp_k} \end{bmatrix},$$

sendo p_k o número de neurônios nas camadas escondidas, w_{ij}^k os pesos e m_i^k o *bias* dos neurônios para $1 \leq i \leq p_k$, $1 \leq j \leq 5n$ e $1 \leq k \leq n$ assumidas como constantes e especificadas pelo projetista, e $H(\cdot)$ é uma função de ativação das saídas dos neurônios definida como

$$H(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}. \quad (4.18)$$

Para simplificar a notação, a rede neural completa pode ser escrita como,

$$\Delta F(x_e, \Theta) = \begin{bmatrix} \Delta F_1(x_e, \Theta_1) \\ \vdots \\ \Delta F_n(x_e, \Theta_n) \end{bmatrix} = \begin{bmatrix} \xi_1^T \Theta_1 \\ \vdots \\ \xi_n^T \Theta_n \end{bmatrix} = \begin{bmatrix} \xi_1^T & 0 & \dots & 0 \\ 0 & \xi_2^T & \vdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \xi_n^T \end{bmatrix} \begin{bmatrix} \Theta_1 \\ \Theta_2 \\ \vdots \\ \Theta_n \end{bmatrix} \doteq \Xi \Theta. \quad (4.19)$$

4.3.2 Estimativa do Modelo Completo Baseada em Redes Neurais - RNMC

As redes neurais também podem ser utilizadas para estimar o modelo completo do sistema (4.15). Portanto da mesma forma como desenvolvido na subseção anterior, utiliza-se então uma rede neural adaptativa, $F(x_e, \Theta)$, para estimar o termo $F_0(x_e) + \Delta F(x_e)$. Definem-se n redes $F_k(x_e, \Theta_k)$, $k = 1, \dots, n$ com pesos ajustáveis Θ_k . Sendo cada rede da camada de saída,

$$\begin{aligned} F_k(x_e, \Theta_k) &= \sum_{i=1}^{p_k} H \left(\sum_{j=1}^{5n} w_{ij}^k x_{ej} + m_i^k \right) \Theta_{ki} \\ &= \xi_k^T \Theta_k \end{aligned} \quad (4.20)$$

com

$$\xi_k = \begin{bmatrix} H \left(\sum_{j=1}^{5n} w_{1j}^k x_{ej} + m_1^k \right) \\ \vdots \\ H \left(\sum_{j=1}^{5n} w_{p_k j}^k x_{ej} + m_{p_k}^k \right) \end{bmatrix}$$

e

$$\Theta_k = \begin{bmatrix} \Theta_{k1} \\ \vdots \\ \Theta_{kp_k} \end{bmatrix},$$

sendo p_k o número de neurônios nas camadas escondidas, w_{ij}^k os pesos e m_i^k o *bias* dos neurônios para $1 \leq i \leq p_k$, $1 \leq j \leq 5n$ e $1 \leq k \leq n$ assumidas como constantes e especificadas pelo projetista, e $H(\cdot)$ é uma função de ativação das saídas dos neurônios definida como

$$H(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}. \quad (4.21)$$

Para simplificar a notação, a rede neural completa pode ser escrita como,

$$\begin{aligned}
 F(x_e, \Theta) &= \begin{bmatrix} F_1(x_e, \Theta_1) \\ \vdots \\ F_n(x_e, \Theta_n) \end{bmatrix} = \begin{bmatrix} \xi_1^T \Theta_1 \\ \vdots \\ \xi_n^T \Theta_n \end{bmatrix} \\
 &= \begin{bmatrix} \xi_1^T & 0 & \dots & 0 \\ 0 & \xi_2^T & \vdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \xi_n^T \end{bmatrix} \begin{bmatrix} \Theta_1 \\ \Theta_2 \\ \vdots \\ \Theta_n \end{bmatrix} \\
 &\doteq \Xi \Theta.
 \end{aligned} \tag{4.22}$$

4.3.3 Estimativa das Incertezas Paramétricas Baseada no Modelo Fuzzy Takagi-Sugeno - TSIP

Da mesma forma como na Seção 4.3.1, um estimador baseado em lógica fuzzy é proposto para estimar o termo desconhecido $\Delta F(x_e)$ em (4.16), sendo este parametrizado de acordo com (4.12). Os sistemas fuzzy geralmente são formados por quatro partes: um fuzzificador, uma base de regras, um procedimento de inferência e um defuzzificador. O fuzzificador é um mapeamento do universo de discurso de entrada $U \subset \mathbb{R}^r$ aos conjuntos fuzzy definidos em U . Dois fatores determinam a interface de fuzzificação: (i) o número de conjuntos fuzzy definidos no universo de discurso de entrada e (ii) as funções de pertinência relacionadas com esses conjuntos. A base de regras é formada por um conjunto de proposições lingüísticas do tipo,

SE premissas são satisfeitas

ENTÃO conseqüências são inferidas.

O procedimento de inferência é a lógica da tomada de decisão que aplica a base de regras fuzzy para determinar a saída correspondente às entradas fuzzificadas.

Considere o modelo fuzzy T-S, [31], caracterizado por um conjunto de proposições lingüísticas do tipo:

SE u_1 é A_{11} e u_2 é A_{12} ... e u_r é A_{1r} ,

ENTÃO $y_1 = \theta_{10} + \theta_{11}u_1 + \theta_{12}u_2 + \dots + \theta_{1r}u_r$.

$\vdots$

SE u_1 é A_{k1} e u_2 é A_{k2} ... e u_r é A_{kr} ,

ENTÃO $y_k = \theta_{k0} + \theta_{k1}u_1 + \theta_{k2}u_2 + \dots + \theta_{kr}u_r$.

onde A_{ij} , $j = 1, \dots, r$ e $i = 1, \dots, k$, são variáveis lingüísticas relacionadas ao conjunto fuzzy definido no espaço de entrada $U_1, U_2, \dots, U_r$; $u_1, u_2, \dots, u_r$ são os valores das variáveis de entrada, k é o número de regras fuzzy e θ_i são os parâmetros ajustados pela lógica fuzzy.

A saída de inferência do método T-S é *crisp* (portanto não necessita de um defuzzificador). Esta é definida como uma média ponderada das saídas y_i de cada subsistema linear

$$\begin{aligned} y &= \frac{\sum_{i=1}^k \mu_i y_i}{\sum_{i=1}^k \mu_i} \\ &= \frac{\sum_{i=1}^k \mu_i (\theta_{i0} + \theta_{i1} u_1 + \theta_{i2} u_2 + \dots + \theta_{ir} u_r)}{\sum_{i=1}^k \mu_i}, \end{aligned} \quad (4.23)$$

onde μ_i é o grau de pertinência da i -th regra, definido como o mínimo entre os graus de pertinência associados às entradas dos conjuntos fuzzy ativados pela i -th regra

$$\mu_i = A_{i1}(u_1) \wedge A_{i2}(u_2) \wedge \dots \wedge A_{ir}(u_r). \quad (4.24)$$

Define-se $x_e \doteq \begin{bmatrix} \tilde{q}^T & \dot{\tilde{q}}^T \end{bmatrix}^T = \begin{bmatrix} q^T - q_d^T & \dot{q}^T - \dot{q}_d^T \end{bmatrix}^T$ como a entrada fuzzy, e $A(x_e) = \begin{bmatrix} A_1(\tilde{q}) & A_2(\dot{\tilde{q}}) \end{bmatrix}$ como os conjuntos fuzzy das entradas fuzzificadas. Então propõe-se um sistema fuzzy para estimação do termo $\Delta F(x_e)$ baseado no método de T-S, definido como

$$\begin{aligned} \Delta F(x_e, \Theta) &\doteq \begin{bmatrix} \Delta F_1(x_e^1, \Theta_1) \\ \vdots \\ \Delta F_n(x_e^n, \Theta_n) \end{bmatrix} = \begin{bmatrix} \xi_1 \Theta_1 \\ \vdots \\ \xi_n \Theta_n \end{bmatrix} \\ &= \begin{bmatrix} \xi_1 & 0 & \dots & 0 \\ 0 & \xi_2 & \vdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \xi_n \end{bmatrix} \begin{bmatrix} \Theta_1 \\ \Theta_2 \\ \vdots \\ \Theta_n \end{bmatrix} \\ &= \Xi \Theta, \end{aligned} \quad (4.25)$$

com

$$\xi_j = \frac{1}{\sum_{i=1}^k \mu_i^j} \begin{bmatrix} \mu_1^j & \dots & \mu_k^j & \mu_1^j x_e^{jT} & \dots & \mu_k^j x_e^{jT} \end{bmatrix}$$

e

$$\Theta_i = \begin{bmatrix} \theta_{i0}^i & \dots & \theta_{1r}^i & \dots & \theta_{k0}^i & \dots & \theta_{kr}^i \end{bmatrix}^T.$$

4.3.4 Estimativa do Modelo Completo Baseada no Modelo Fuzzy Takagi-Sugeno - TSMC

O Modelo Fuzzy de Takagi-Sugeno também pode ser utilizado para estimar o modelo completo do sistema (4.15), portanto da mesma forma como desenvolvido na subseção anterior, utiliza-se então um sistema fuzzy adaptativo, $F(x_e, \Theta)$, para estimar o termo $F_0(x_e) + \Delta F(x_e)$. Então propõe-se um sistema fuzzy para estimação do modelo completo baseado no método de T-S, definido como

$$\begin{aligned}
 F(x_e, \Theta) &\doteq \begin{bmatrix} F_1(x_e^1, \Theta_1) \\ \vdots \\ F_n(x_e^n, \Theta_n) \end{bmatrix} = \begin{bmatrix} \xi_1 \Theta_1 \\ \vdots \\ \xi_n \Theta_n \end{bmatrix} \\
 &= \begin{bmatrix} \xi_1 & 0 & \dots & 0 \\ 0 & \xi_2 & \vdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \xi_n \end{bmatrix} \begin{bmatrix} \Theta_1 \\ \Theta_2 \\ \vdots \\ \Theta_n \end{bmatrix} \\
 &= \Xi \Theta,
 \end{aligned} \tag{4.26}$$

com

$$\xi_j = \frac{1}{\sum_{i=1}^k \mu_i^j} \begin{bmatrix} \mu_1^j & \dots & \mu_k^j & \mu_1^j x_e^{jT} & \dots & \mu_k^j x_e^{jT} \end{bmatrix}$$

e

$$\Theta_i = \begin{bmatrix} \theta_{i0}^i & \dots & \theta_{1r}^i & \dots & \theta_{k0}^i & \dots & \theta_{kr}^i \end{bmatrix}^T.$$

4.3.5 Considerações

De forma a garantir a estabilidade da lei de controle que será desenvolvida na próxima seção, considere as seguintes afirmações feitas em [4]:

1. Existe um valor para o parâmetro $\Theta^* \in \Omega_\theta$, conhecido como valor ótimo de aproximação, tal que os valores de $\Delta F(x_e, \Theta^*)$ e $F(x_e, \Theta^*)$ aproximam-se de $\Delta F(x_e)$ e $F(x_e)$ tanto quanto possível, onde Ω_θ é uma região de restrição definida como,

$$\Omega_\theta \doteq \{\Theta \mid \Theta^T \Theta \leq M_\theta, \quad M_\theta > 0\},$$

sendo M_θ uma constante positiva especificada pelo projetista.

2. Define-se $\delta F(x_e) = \Delta F(x_e, \Theta^*) - \Delta F(x_e)$, e sem perda de generalidade assume-se que exista uma função $k(x_e) > 0$ tal que $|(\delta F(x_e))_i| \leq k(x_e)$, para todo $1 \leq i \leq n$.

De acordo com as considerações acima, a equação dinâmica modificada do erro (4.16) pode ser reescrita como,

$$\begin{aligned} A_L \dot{\bar{x}}_2 &= -L^T C_L \bar{x}_2 + L^T (-F_0(x_e) - \Delta F(x_e) + \tau + d) \\ &= -L^T C_L \bar{x}_2 + L^T (-F_0(x_e) - \Delta F(x_e, \Theta^*) + \delta F(x_e) + \tau + d) \\ &= -L^T C_L \bar{x}_2 + L^T u + L^T d, \end{aligned} \tag{4.27}$$

definindo

$$u \doteq -F_0(x_e) - \Delta F(x_e, \Theta^*) + \delta F(x_e) + \tau,$$

então, os torques aplicados podem ser calculados como

$$\tau = F_0(x_e) + \Xi \Theta + \bar{u}, \tag{4.28}$$

sendo $\bar{u}$ a lei de controle determinada pelo controlador $\mathcal{H}_\infty$ não linear.

4.4 Controle Adaptativo $\mathcal{H}_\infty$ Não Linear

Baseado nos sistemas inteligentes apresentados, um controlador adaptativo é aplicado ao problema para garantir que os efeitos dos erros de estimativa e distúrbios externos sejam atenuados. A seguir é proposto no Teorema 4.4.1 um controlador adaptativo $\mathcal{H}_\infty$, que é uma variação dos teoremas apresentados em [7], [4] e [8].

Teorema 4.4.1 *Considere o modelo reduzido (4.5) com incertezas na planta e distúrbios externos. Para as seguintes trajetórias de referências $q_d(t)$ e $\lambda_d(t)$, temos o seguinte controlador adaptativo baseado em sistemas inteligentes*

$$\dot{\Theta} = \begin{cases} -\rho \Xi^T L \bar{x}_2 & \text{if } \|\Theta\| < M_\theta \text{ or} \\ & (\|\Theta\| = M_\theta \text{ and } \bar{x}_2^T L^T \Xi \Theta \geq 0) \\ -\rho \Xi^T L \bar{x}_2 + \rho \frac{\bar{x}_2^T L^T \Xi \Theta}{\|\Theta\|^2} \Theta & \text{if } \|\Theta\| = M_\theta \\ & \text{and } \bar{x}_2^T L^T \Xi \Theta < 0 \end{cases} \quad (4.29)$$

$$\tau = F_0(x_e) + \Xi \Theta - k_0 E \bar{x}_2 + k(x_e) \operatorname{sgn}(L \bar{x}_2) - J^T \lambda_c. \quad (4.30)$$

Sendo

$$\lambda_c \doteq \lambda_d - k_\lambda \int_0^T (\lambda - \lambda_d) dt \quad e \quad E \doteq \begin{bmatrix} I_{(n-m) \times (n-m)} \\ 0_{m \times (n-m)} \end{bmatrix}, \quad (4.31)$$

para alguma constante $k_\lambda > 0$, onde $\lambda_d(t)$ é o multiplicador lagrangiano desejado relacionado com a restrição de força desejada $f_d(t)$, onde $f_d(t) = J^T(q_d(t))\lambda_d(t)$. A restrição de força desejada $f_d(t)$ é então assumida como sendo limitada, [8].

Então, para condições iniciais limitadas e $\rho > 0$, existe uma escolha adequada da constante k_0 tal que o seguinte critério de desempenho $\mathcal{H}_\infty$ é garantido, [8], portanto os seguintes itens são assegurados:

1. $\Theta(t) \in \Omega_\theta$ e todas as variáveis $q(t), \dot{q}(t)$ e $\tau(t)$ são limitadas para todo $t \geq 0$.
2. O seguinte índice de desempenho $\mathcal{H}_\infty$ é mantido

$$\int_0^T \|\bar{x}(t)\|_Q^2 \leq V(0) + \gamma^2 \int_0^T \|d(t)\|^2, \quad \forall T \geq 0, \quad (4.32)$$

com $\omega(t) \in L_2[0, \infty)$, onde Q é uma matriz de ponderação, $V(0)$ é a função candidata a Lyapunov quando $t=0$ e γ é o nível de atenuação pré-determinado.

3. Se $\omega(t) \in L_2[0, \infty) \cap L_\infty[0, \infty)$, então pode-se concluir que $\lim_{t \rightarrow \infty} (q^1(t) - q_d^1(t)) = 0$ e $\lim_{t \rightarrow \infty} (\dot{q}^1(t) - \dot{q}_d^1(t)) = 0$.

Prova

A prova deste teorema é baseada no fato de que a condição 1. é satisfeita, ou seja as variáveis do sistema são limitadas para todo $t \geq 0$.

Prova do item 2.

Escolhe-se a seguinte função candidata a Lyapunov,

$$V(t, \bar{x}, \tilde{\Theta}) = \frac{\alpha}{2} \bar{x}_1^T \bar{x}_1 + \frac{1}{2} \bar{x}_2^T A_L \bar{x}_2 + \frac{1}{2\rho} \tilde{\Theta}^T \tilde{\Theta}, \quad (4.33)$$

para $\alpha > 0$, onde $\rho > 0$ é o ganho adaptativo e $\tilde{\Theta} \doteq \Theta - \Theta^*$. A derivada de V no tempo é dada por

$$\begin{aligned} \dot{V} &= \frac{\alpha}{2} \dot{\bar{x}}_1^T \bar{x}_1 + \frac{\alpha}{2} \bar{x}_1^T \dot{\bar{x}}_1 + \frac{1}{2} \dot{\bar{x}}_2^T A_L \bar{x}_2 + \frac{1}{2} \bar{x}_2^T \frac{\partial(A_L \bar{x}_2)}{\partial t} + \\ &\quad \frac{1}{2\gamma} \dot{\tilde{\Theta}}^T \tilde{\Theta} + \frac{1}{2\gamma} \tilde{\Theta}^T \dot{\tilde{\Theta}} \\ \dot{V} &= \frac{\alpha}{2} (\dot{\bar{x}}_1^T \bar{x}_1 + \bar{x}_1^T \dot{\bar{x}}_1) + \frac{1}{2} (\dot{\bar{x}}_2^T A_L \bar{x}_2 + \bar{x}_2^T \dot{A}_L \bar{x}_2 + \bar{x}_2^T A_L \dot{\bar{x}}_2) + \\ &\quad \frac{1}{2\gamma} (\dot{\tilde{\Theta}}^T \tilde{\Theta} + \tilde{\Theta}^T \dot{\tilde{\Theta}}) \\ \dot{V} &= \alpha (\bar{x}_1^T \dot{\bar{x}}_1) + \frac{1}{2} (2\bar{x}_2^T A_L \dot{\bar{x}}_2 + \bar{x}_2^T \dot{A}_L \bar{x}_2) + \frac{1}{\gamma} (\tilde{\Theta}^T \dot{\tilde{\Theta}}) \end{aligned} \quad (4.34)$$

Substituindo $\dot{\bar{x}}_1$ (4.13) e $A_L \dot{\bar{x}}_2$ (4.27) na equação (4.34)

$$\begin{aligned} \dot{V} &= \alpha \bar{x}_1^T (\bar{x}_2 - p\bar{x}_1) + \bar{x}_2^T [-L^T C_L \bar{x}_2 + L^T (-F_0(x_e) - \Delta F(x_e, \Theta^*) + \delta F(x_e) + \tau + d)] + \\ &\quad + \frac{1}{2} \bar{x}_2^T \dot{A}_L \bar{x}_2 + \frac{1}{\gamma} \tilde{\Theta}_1^T \dot{\tilde{\Theta}}_1 \end{aligned}$$

$$\Delta F(x_e, \Theta^*) = \Xi \Theta^*. \quad (4.35)$$

Portanto tem-se que,

$$\begin{aligned} \dot{V} &= \alpha \bar{x}_1^T (\bar{x}_2 - p\bar{x}_1) - \bar{x}_2^T L^T C_L \bar{x}_2 + \bar{x}_2^T L^T [-F_0(x_e) - \Xi \Theta^* + \delta F(x_e) + \tau + d] + \\ &\quad + \frac{1}{2} \bar{x}_2^T \dot{A}_L \bar{x}_2 + \frac{1}{\gamma} \tilde{\Theta}^T \dot{\tilde{\Theta}}. \end{aligned} \quad (4.36)$$

Substituindo-se (4.30) na equação (4.36),

$$\begin{aligned}
\dot{V} &= -\alpha p \bar{x}_1^T \bar{x}_1 + \alpha \bar{x}_1^T \bar{x}_2 - \bar{x}_2^T L^T C_L \bar{x}_2 + \frac{1}{2} \bar{x}_2^T \dot{A}_L \bar{x}_2 + \frac{1}{\gamma} \tilde{\Theta}^T \dot{\tilde{\Theta}} \\
&\quad + \bar{x}_2^T L^T [-F_0(x_e) - \Xi \Theta^* + \delta F(x_e) + F_0(x_e) + \Xi \Theta - k_0 E \bar{x}_2 - k(x_e) \operatorname{sgn}(L \bar{x}_2) - J^T \lambda_c + d] \\
\dot{V} &= -\alpha p \bar{x}_1^T \bar{x}_1 + \alpha \bar{x}_1^T \bar{x}_2 + \frac{1}{2} \bar{x}_2^T (\tilde{A}_L - 2L^T C_L) \bar{x}_2 + \frac{1}{\gamma} \tilde{\Theta}^T \dot{\tilde{\Theta}} \\
&\quad + \bar{x}_2^T L^T [-\Xi \Theta^* + \delta F(x_e) + \Xi \Theta - k_0 E \bar{x}_2 - k(x_e) \operatorname{sgn}(L \bar{x}_2) - J^T \lambda_c + d] \\
\dot{V} &= -\alpha p \bar{x}_1^T \bar{x}_1 + \alpha \bar{x}_1^T \bar{x}_2 + \frac{1}{2} \bar{x}_2^T (\tilde{A}_L - 2L^T C_L) \bar{x}_2 - k_0 \bar{x}_2^T L^T E \bar{x}_2 - \bar{x}_2^T L^T J^T \lambda_c \\
&\quad + \bar{x}_2^T L^T [-\Xi \Theta^* + \delta F(x_e) + \Xi \Theta - k(x_e) \operatorname{sgn}(L \bar{x}_2) + d] + \frac{1}{\gamma} \tilde{\Theta}^T \dot{\tilde{\Theta}}.
\end{aligned}$$

Pela propriedade P3, Seção 4.1, temos que,

$$\begin{aligned}
\bar{x}_2^T L^T J^T \lambda_c &= 0 \\
\mathbb{L}^T E &= I_{n-m}.
\end{aligned}$$

Com isso,

$$\begin{aligned}
\dot{V} &= -\alpha p \bar{x}_1^T \bar{x}_1 + \alpha \bar{x}_1^T \bar{x}_2 + \frac{1}{2} \bar{x}_2^T (\tilde{A}_L - 2L^T C_L) \bar{x}_2 - k_0 \bar{x}_2^T \bar{x}_2 \\
&\quad + \bar{x}_2^T L^T [-\Xi \Theta^* + \delta F(x_e) + \Xi \Theta - k(x_e) \operatorname{sgn}(L \bar{x}_2) + d] + \frac{1}{\gamma} \tilde{\Theta}^T \dot{\tilde{\Theta}}.
\end{aligned}$$

Sabe-se que $\tilde{\Theta} = \hat{\Theta} - \Theta^*$,

$$\begin{aligned}
\dot{V} &= -\alpha p \bar{x}_1^T \bar{x}_1 + \alpha \bar{x}_1^T \bar{x}_2 + \frac{1}{2} \bar{x}_2^T (\tilde{A}_L - 2L^T C_L) \bar{x}_2 - k_0 \bar{x}_2^T \bar{x}_2 \\
&\quad + \bar{x}_2^T L^T [\Xi (\Theta - \Theta^*) + \delta F(x_e) - k(x_e) \operatorname{sgn}(L \bar{x}_2) + d] + \frac{1}{\gamma} \tilde{\Theta}^T \dot{\tilde{\Theta}} \\
\dot{V} &= -\alpha p \bar{x}_1^T \bar{x}_1 + \alpha \bar{x}_1^T \bar{x}_2 + \frac{1}{2} \bar{x}_2^T (\tilde{A}_L - 2L^T C_L) \bar{x}_2 - k_0 \bar{x}_2^T \bar{x}_2 \\
&\quad + \bar{x}_2^T L^T \left[\Xi \tilde{\Theta} + \delta F(x_e) - k(x_e) \operatorname{sgn}(L \bar{x}_2) + d \right] + \frac{1}{\gamma} \tilde{\Theta}^T \dot{\tilde{\Theta}} \\
\dot{V} &= -\alpha p \bar{x}_1^T \bar{x}_1 + \alpha \bar{x}_1^T \bar{x}_2 + \frac{1}{2} \bar{x}_2^T (\tilde{A}_L - 2L^T C_L) \bar{x}_2 - k_0 \bar{x}_2^T \bar{x}_2 \\
&\quad + \bar{x}_2^T L^T [\delta F(x_e) - k(x_e) \operatorname{sgn}(L \bar{x}_2) + d] + \left(\bar{x}_2^T L^T \Xi + \frac{1}{\gamma} \dot{\tilde{\Theta}}^T \right) \tilde{\Theta}.
\end{aligned}$$

Como a matriz $\tilde{A}_L - 2L^T C_L$ é anti-simétrica, então:

$$\bar{x}_2^T (\tilde{A}_L - 2L^T C_L) \bar{x}_2 = 0.$$

Com isso,

$$\begin{aligned}\dot{V} = & -\alpha p \bar{x}_1^T \bar{x}_1 + \alpha \bar{x}_1^T \bar{x}_2 - k_0 \bar{x}_2^T \bar{x}_2 \\ & + \bar{x}_2^T L^T [\delta F(x_e) - k(x_e) \operatorname{sgn}(L \bar{x}_2) + d] + \left(\bar{x}_2^T L^T \Xi + \frac{1}{\gamma} \dot{\tilde{\Theta}}^T \right) \tilde{\Theta}.\end{aligned}\quad (4.37)$$

A equação acima (4.37) é diferente da apresentada em [7], pois uma matriz Ξ da rede neural é utilizada no lugar da matriz de regressão linear Y e um termo VSC ($-k(x_e) \operatorname{sgn}(L \bar{x}_2)$) é adicionado a lei de controle para eliminar a limitação da aproximação do erro, discutida em [4]. Através da equação de atualização da lei de controle (4.29), a qual é na realidade um algoritmo de projeção, [12], pode-se concluir que $\left[\bar{x}_2^T L^T \Xi + \frac{1}{\gamma} \dot{\tilde{\Theta}}^T \right] \tilde{\Theta} \leq 0$, e $\Theta(t) \in \Omega_\Theta$ para todo $t \geq 0$ se $\Theta(0) \in \Omega_\Theta$. Então a igualdade (4.37) pode ser reduzida,

$$\dot{V} \leq -\alpha p \bar{x}_1^T \bar{x}_1 + \alpha \bar{x}_1^T \bar{x}_2 - k_0 \bar{x}_2^T \bar{x}_2 + \bar{x}_2^T L^T d + \bar{x}_2^T L^T [\delta F(x_e) - k(x_e) \operatorname{sgn}(L \bar{x}_2)]. \quad (4.38)$$

Considerando a Afirmação 2, feita na seção 4.3.5, isto garantirá que,

$$\bar{x}_2^T L^T (-k(x_e) \operatorname{sgn}(L \bar{x}_2) + \delta F(x_e)) \leq -k(x_e) \sum_{i=1}^n |(L \bar{x}_2)_i| + \sum_{i=1}^n |(\delta F(x_e))_i| |(L \bar{x}_2)_i| \leq 0.$$

Portanto a Equação (4.38) pode ser novamente reduzida para

$$\dot{V} \leq -\alpha p \bar{x}_1^T \bar{x}_1 + \alpha \bar{x}_1^T \bar{x}_2 - k_0 \bar{x}_2^T \bar{x}_2 + \bar{x}_2^T L^T d. \quad (4.39)$$

Completando quadrados escolhe-se,

$$\begin{aligned}\alpha p & > a + \lambda_Q \\ k_0 & > \frac{\alpha^2}{4a} + \frac{\lambda_L}{4\rho^2} + \lambda_Q,\end{aligned}$$

para $a > 0$, onde λ_Q e λ_L são os máximos auto-valores de Q e $L^T L$, respectivamente.

$$\begin{aligned}\dot{V} & \leq -(a + \lambda_Q) \|\bar{x}_1\|^2 - \left(\frac{\alpha^2}{4a} + \frac{\lambda_L}{4\rho^2} + \lambda_Q \right) \|\bar{x}_2\|^2 + \alpha \|\bar{x}_1\| \|\bar{x}_2\| + \|\bar{x}_2\| \|L\| \|d\| \\ \dot{V} & \leq -a \|\bar{x}_1\|^2 - \lambda_Q \|\bar{x}_1\|^2 - \frac{\alpha^2}{4a} \|\bar{x}_2\|^2 - \frac{\lambda_L}{4\rho^2} \|\bar{x}_2\|^2 - \lambda_Q \|\bar{x}_2\|^2 + \alpha \|\bar{x}_1\| \|\bar{x}_2\| + \|\bar{x}_2\| \|L\| \|d\| \\ \dot{V} & \leq -\left(\sqrt{a} \|\bar{x}_1\| - \frac{\alpha}{2\sqrt{a}} \|\bar{x}_2\| \right)^2 - \lambda_Q \left(\|\bar{x}_1\|^2 + \|\bar{x}_2\|^2 \right) - \frac{\lambda_L \|\bar{x}_2\|^2}{4\rho^2} + \|\bar{x}_2\| \|L\| \|d\|. \quad (4.40)\end{aligned}$$

Sabe-se que, $\|L\| = \sqrt{\lambda_L}$, portanto $\|L\|^2 = \lambda_L$. Sendo $\|\bar{x}\|^2 = \|\bar{x}_1\|^2 + \|\bar{x}_2\|^2$, e somando e subtraindo o termo $\rho^2 \|d\|^2$ a Equação (4.40),

$$\begin{aligned}\dot{V} &\leq -\left(\sqrt{a}\|\bar{x}_1\| - \frac{\alpha}{2\sqrt{a}}\|\bar{x}_2\|\right)^2 - \lambda_Q \|\bar{x}\|^2 - \frac{\|L\|^2 \|\bar{x}_2\|^2}{4\rho^2} + \|\bar{x}_2\| \|L\| \|d\| \\ &\quad - \rho^2 \|d\|^2 + \rho^2 \|d\|^2 \\ \dot{V} &\leq -\left(\sqrt{a}\|\bar{x}_1\| - \frac{\alpha}{2\sqrt{a}}\|\bar{x}_2\|\right)^2 - \lambda_Q \|\bar{x}\|^2 - \left(\frac{\|L\| \|\bar{x}_2\|}{2\rho} - \rho \|d\|\right)^2 + \rho^2 \|d\|^2. \quad (4.41)\end{aligned}$$

Pelo Teorema de Rayleigh-Ritz, temos que,

$$\lambda_{\max}\{A\} \|x\|^2 \geq x^T A x \geq \lambda_{\min}\{A\} \|x\|^2.$$

Portanto o termo $-\lambda_Q \|\bar{x}\|^2$ pode ser substituído por $-\bar{x}^T Q \bar{x}$, sem alterar a desigualdade,

$$\dot{V} \leq -\left(\sqrt{a}\|\bar{x}_1\| - \frac{\alpha}{2\sqrt{a}}\|\bar{x}_2\|\right)^2 - \left(\frac{\|L\| \|\bar{x}_2\|}{2\rho} - \rho \|d\|\right)^2 - \bar{x}^T Q \bar{x} + \rho^2 \|d\|^2. \quad (4.42)$$

Os termos $\left(\sqrt{a}\|\bar{x}_1\| - \frac{\alpha}{2\sqrt{a}}\|\bar{x}_2\|\right)^2$ e $\left(\frac{\|L\| \|\bar{x}_2\|}{2\rho} - \rho \|d\|\right)^2$ são números reais positivos, portanto somando-os ao lado direito da Equação (4.42), a desigualdade será mantida,

$$\dot{V} \leq -\bar{x}^T Q \bar{x} + \rho^2 \|d\|^2.$$

O termo $-\bar{x}^T Q \bar{x}$ pode ser escrito como $\|\bar{x}\|_Q^2$,

$$\dot{V} \leq -\|\bar{x}\|_Q^2 + \rho^2 \|d\|^2. \quad (4.43)$$

Integrando a Equação (4.43), no intervalo de $[0, T]$,

$$V(\bar{x}(T), \tilde{\theta}(T), T) - V(\bar{x}(0), \tilde{\theta}(0), 0) \leq -\int_0^T \|\bar{x}\|_Q^2 dt + \rho^2 \int_0^T \|d\|^2 dt. \quad (4.44)$$

Como o termo $-V\left(\bar{x}(T), \tilde{\theta}(T), T\right) \leq 0$, se somar-mos este ao lado esquerdo da equação (4.44) isto não alterará a desigualdade,

$$\begin{aligned} -V\left(\bar{x}(0), \tilde{\theta}(0), 0\right) &\leq -\int_0^T \|x\|_Q^2 dt + \rho^2 \int_0^T \|d\|^2 dt \\ \int_0^T \|x\|_Q^2 dt &\leq V\left(x(0), \tilde{\theta}(0), 0\right) + \rho^2 \int_0^T \|d\|^2 dt. \end{aligned} \quad (4.45)$$

Portanto o critério de desempenho $\mathcal{H}_\infty$ é mantido.

Com isso, conclui-se o desenvolvimento matemático dos controladores desenvolvidos neste trabalho. No próximo capítulo serão feitas implementações de tais controladores. No qual resultados práticos são apresentados para demonstrar sua eficiência.

Capítulo 5

Implementação e resultados

Neste capítulo apresentaremos os resultados de implementação dos controladores adaptativos que estamos considerando neste trabalho. Faremos uma breve introdução dos recursos utilizados, do manipulador robótico *Underactuated Arm II* (UArmII), do sensor para medição de forças/momentos em três eixos ortogonais e do ambiente de Simulação e Controle de Manipuladores Restritos (ASCM-R). Também será apresentada a maneira como as trajetórias desejadas do manipulador foram geradas e os índices utilizados para comparar os desempenhos dos controladores propostos. Na Seção 5.4 serão documentados os detalhes de implementação para os seguintes experimentos propostos:

- Controladores via Redes Neurais (RNIP e RNMC), sub-seção 5.4.1,
- Controladores via Sistemas Fuzzy (TSIP e TSMC), sub-seção 5.4.2.

Os quatro controladores (RNIP, RNMC, TSIP e TSMC) podem ser reagrupados da seguinte forma:

1. (RNIP e TSIP), estimam somente as incertezas (incertezas paramétricas, dinâmicas não modeladas e distúrbios externos),
2. (RNMC e TSMC), estimam o modelo completo, ou seja, considera que todo modelo nominal não é conhecido.

Em ambos os casos são utilizados sistemas inteligentes, sendo que (RNIP e RNMC) utilizam Redes Neurais e (TSIP e TSMC) Sistemas Fuzzy baseado no modelo de Takagi-Sugeno.

5.1 Underactuated Arm II (UArmII)

O ambiente de simulação desenvolvido neste trabalho permite não só projetar os controladores como também controlar o robô em tempo real. O manipulador que estamos considerando em nossos experimentos é planar e possui três elos em série conectados por juntas rotacionais. As juntas são compostas por um motor DC *brushless*, um freio pneumático e um encoder com decodificador de quadratura. As principais vantagens deste sistema robótico são:

- Possibilidade de configuração das juntas como passiva ou atuada, o que permite testes com robôs subatuados;
- Ausência da gravidade, pois trata-se de um robô planar onde existe um sistema de ar comprimido que produz um filme de ar entre a base das juntas e a mesa que permite que o robô flutue;
- Facilidade para adicionar controladores, pois como o software do sistema foi desenvolvido de forma modular, com pequenas alterações pode-se testar facilmente novos controladores.

As juntas e os elos são nomeados de 1 a 3, sendo que a junta 1 e o elo 1 são os mais próximos da base do manipulador, sendo esta fixa a uma mesa de granito na qual as demais juntas do manipulador flutuam, veja a Figura 5.1. Os dados físicos do robô são descritos na Tabela 5.1.

Figura 5.1: Underactuated Arm II

5.2 Ambiente de Simulação e Controle

A interface responsável por fazer a interação entre as técnicas de controle consideradas nas seções anteriores com o modelo do manipulador restrito de base fixa (UArmII) é definida pelo Ambiente de Simulação e Controle de Manipuladores Restritos (ASCM-R). Pela Figura 5.2 nota-se que a interface deste ambiente é basicamente dividida em quatro partes, sendo que a primeira

Tabela 5.1: Parâmetros do UArmII

i	m_i (kg)	I_i (kgm ²)	W_i (m)	l_{c_i} (m)
Junta 1	0.850	0.0075	0.203	0.096
Junta 2	0.850	0.0075	0.203	0.096
Junta 3	1.700	0.09	0.24	0.177

à esquerda é uma área gráfica que mostra o movimento do manipulador em tempo real. A segunda parte, no lado direito superior, consiste em comandos para simulação e acionamento do manipulador. Logo abaixo, a direita, o usuário pode inserir os parâmetros necessários do manipulador. Há um comando que define a restrição na qual o efetuador será submetido e também um *combo box* para plotar os gráficos de acompanhamento de trajetória de posição e velocidade e também os torques nas Juntas.

Figura 5.2: Ambiente de Simulação e Controle de Manipuladores Restritos.

5.3 Trajetórias Desejadas e Índices de Desempenho

As trajetórias desejadas e os índices de desempenho que serão utilizados neste capítulo são demonstrados a seguir. Neste trabalho a trajetória de referência para a junta i , $q_i^d(t)$, é definida como um polinômio de quinto grau:

$$q_i^d(t) = a_0 + a_1(t - t_0) + a_2(t - t_0)^2 + a_3(t - t_0)^3 + a_4(t - t_0)^4 + a_5(t - t_0)^5 \quad (5.1)$$

satisfazendo as condições:

$$\begin{aligned} q_i^d(t_0) &= q_{i_0}, & q_i^d(t_f) &= q_{i_f}, & q_i^d(t_f/2) &= q_{i_f}/2; \\ \dot{q}_i^d(t_0) &= 0, & \dot{q}_i^d(t_f) &= 0; & & \text{(Velocidades inicial e final nulas)} \\ \ddot{q}_i^d(t_0) &= 0, & \ddot{q}_i^d(t_f) &= 0; & & \text{(Acelerações inicial e final nulas)} \end{aligned}$$

sendo t_0 o tempo inicial, t_f o tempo final desejado, q_{i_0} a condição inicial da posição e q_{i_f} o valor final desejado para a posição da junta. De acordo com as restrições impostas, os coeficientes do polinômio foram determinados da seguinte forma:

$$\begin{aligned} a_0 &= q_{i_0} \\ a_1 &= a_2 = 0 \\ a_3 &= 10(q_{i_f} - q_{i_0})/t_f^3 \\ a_4 &= 15(q_{i_0} - q_{i_f})/t_f^4 \\ a_5 &= 6(q_{i_f} - q_{i_0})/t_f^5. \end{aligned}$$

As referências para a velocidade e a aceleração desejadas são dadas pelas derivadas de $q_i^d(t)$ no tempo, $\dot{q}_i^d(t)$ e $\ddot{q}_i^d(t)$ respectivamente.

Para uma comparação quantitativa dos resultados experimentais, os seguintes índices de desempenho foram considerados:

1) Norma $\mathcal{L}_2$ do vetor de estados:

$$\mathcal{L}_2[x] = \left(\frac{1}{(t_r - t_0)} \int_{t_0}^{t_r} \|x(t)\|_2^2 dt \right)^{\frac{1}{2}},$$

sendo t_r o tempo gasto pelo manipulador para alcançar a posição final desejada dentro de uma faixa de tolerância de erro aceitável.

2) Somatório das áreas dos torques:

$$E[\tau] = \sum_{i=1}^3 \left(\int_{t_0}^{t_r} |\tau_i(t)| dt \right),$$

diretamente relacionado com o consumo de energia do manipulador.

3 Somatório das áreas de forças de esmagamento:

$$E[\lambda] = \sum_{i=1}^3 \left(\int_{t_0}^{t_r} |\lambda_i(t)| dt \right),$$

sendo $\lambda_i(t)$ o i -ésimo componente das forças de esmagamento. Como os valores desejados das forças de esmagamento são nulos, quanto menor o valor de $E[\lambda]$, melhor será o controlador com relação ao controle de força de esmagamento.

5.4 Experimentos

Para demonstrar o quão efetivos são os controladores adaptativos propostos, eles serão comparados com um controlador robusto que é projetado apenas com base no modelo nominal do manipulador. O tipo de restrição de superfície utilizado neste trabalho foi uma reta, sendo que o ângulo do efetuador deverá manter-se de forma perpendicular à superfície de restrição, como mostra a Figura 5.3. Espera-se nesses experimentos que o efetuador se mantenha o mais perpendicular à superfície de contato. Isto pode ser visto na Figura 5.4, onde o efetuador robótico está posicionado de maneira perpendicular à régua de restrição. Como podemos notar nesta figura, o efetuador robótico é na realidade o sensor de força/momento apresentado no Capítulo 2.

Portanto, a equação de restrição (4.1) será,

$$\phi(q) = \begin{bmatrix} -y + ax + b \\ q_1 + q_2 + q_3 - c \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}, \quad (5.2)$$

sendo

$$\begin{aligned} x &= l_1 \cos(q_1) + l_2 \cos(q_1 + q_2) + l_3 \cos(q_1 + q_2 + q_3), \\ y &= l_1 \sin(q_1) + l_2 \sin(q_1 + q_2) + l_3 \sin(q_1 + q_2 + q_3), \end{aligned}$$

Figura 5.3: Modelo esquemático do manipulador e régua de restrição.

Figura 5.4: Efetuador e régua de restrição.

e $\phi : \mathcal{R}^3 \rightarrow \mathcal{R}^2$. O vetor q foi particionado como em (4.3), sendo $q^1 = q_1$ e $q^2 = [q_2 \ q_3]^T$.

O termo $L(q^1)$, (4.4), foi obtido da seguinte forma:

— Inicialmente deriva-se a equação $q^2 = \sigma(q^1)$,

$$\dot{q}^2 = \frac{\partial \sigma(q^1)}{\partial q^1} \dot{q}^1. \quad (5.3)$$

— Deriva-se a Equação (5.2) e isola-se $\dot{q}_2$ e $\dot{q}_3$ em função de $\dot{q}_1$,

$$\dot{q}_2 = - \left[\frac{l_1 c_1 + l_2 c_{12} + a l_1 s_1 + a l_2 s_{12}}{l_2 c_{12} + a l_2 s_{12}} \right] \dot{q}_1, \quad (5.4)$$

$$\dot{q}_3 = \left[\frac{l_1 c_1 + l_2 c_{12} + a l_1 s_1 + a l_2 s_{12}}{l_2 c_{12} + a l_2 s_{12}} - 1 \right] \dot{q}_1. \quad (5.5)$$

Como as derivadas de q^1 e q^2 , são:

$$\dot{q}^1 = \dot{q}_1, \\ \dot{q}^2 = \begin{bmatrix} \dot{q}_2 \\ \dot{q}_3 \end{bmatrix},$$

então,

$$\dot{q}^2 = \begin{bmatrix} - \frac{l_1 c_1 + l_2 c_{12} + a l_1 s_1 + a l_2 s_{12}}{l_2 c_{12} + a l_2 s_{12}} \\ \frac{l_1 c_1 + l_2 c_{12} + a l_1 s_1 + a l_2 s_{12}}{l_2 c_{12} + a l_2 s_{12}} - 1 \end{bmatrix} \dot{q}^1$$

e portanto,

$$L(q^1) = \begin{bmatrix} 1 \\ - \frac{l_1 c_1 + l_2 c_{12} + a l_1 s_1 + a l_2 s_{12}}{l_2 c_{12} + a l_2 s_{12}} \\ \frac{l_1 c_1 + l_2 c_{12} + a l_1 s_1 + a l_2 s_{12}}{l_2 c_{12} + a l_2 s_{12}} - 1 \end{bmatrix}. \quad (5.6)$$

A matriz Jacobiana que relaciona a velocidade do manipulador no espaço da restrição para o espaço das juntas foi calculada da seguinte forma:

$$J = \begin{bmatrix} \frac{\partial \phi(q)}{\partial q_1} & \frac{\partial \phi(q)}{\partial q_2} & \frac{\partial \phi(q)}{\partial q_3} \end{bmatrix}, \quad (5.7)$$

e portanto,

$$J = \begin{bmatrix} J_{11} & J_{12} & J_{13} \\ 1 & 1 & 1 \end{bmatrix} \quad (5.8)$$

com,

$$J_{11} = l_1 c_1 + l_2 c_{12} + l_3 c_{123} + a [l_1 s_1 + l_2 s_{12} + l_3 s_{123}]$$

$$J_{12} = l_2 c_{12} + l_3 c_{123} + a [l_2 s_{12} + l_3 s_{123}]$$

$$J_{13} = l_3 c_{123} + a [l_3 s_{123}].$$

5.4.1 Controlador via Redes Neurais

Como o manipulador adotado nesses experimentos possui três juntas rotacionais, escolhe-se então três redes neurais para estimar as incertezas. As entradas de cada rede neural são definidas como:

$$x_e = \left[(q^1)^T \quad (\dot{q}^1)^T \quad (q_d^1)^T \quad (\dot{q}_d^1)^T \quad (\ddot{q}_d^1)^T \right]^T.$$

Na seção (4.3.1) foi visto que o vetor x_e deve ter dimensão igual a $5n$. Como o modelo foi reduzido ficando em função de q^1 tendo este dimensão igual a 1, então o vetor x_e terá dimensão igual a 5. Cada uma das três redes neurais é formada pela topologia mostrada na Figura 5.5.

Figura 5.5: Rede neural.

Definem-se os pesos que multiplicam as entradas como:

$$w_{ij}^k = \begin{bmatrix} 1 & 1 & -1 & -1 & -1 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & 1 & -1 & -1 & -1 \end{bmatrix},$$

sendo $1 \leq i \leq p_k$, $1 \leq j \leq 5$, no qual p_k representa o número de neurônios na camada escondida. Portanto o termo $\sum_{j=1}^{5n} w_{ij}^k x_{ej}$ da Equação (4.20) para este caso será igual a:

$$\Psi = q^1 + \dot{q}^1 - d_d^1 - \dot{q}_d^1 - \ddot{q}_d^1.$$

Note que tais entradas são escolhidas no formato do cálculo do erro de *link* filtrado (4.7), e também é adicionado o valor da aceleração desejada. Define-se cada rede com 7 neurônios na camada escondida:

$$\xi_k = \begin{bmatrix} \xi_{k1} & \xi_{k2} & \xi_{k3} & \xi_{k4} & \xi_{k5} & \xi_{k6} & \xi_{k7} \end{bmatrix},$$

sendo $k = 1, 2$ e 3 . A função de ativação é escolhida como sendo tangente hiperbólica. Portanto, os 7 neurônios na camada escondida de cada rede são da seguinte forma:

$$\begin{aligned} \xi_{k1} &= \frac{e^{\Psi_k-3} - e^{-\Psi_k+3}}{e^{\Psi_k-3} + e^{-\Psi_k+3}} \\ \xi_{k2} &= \frac{e^{\Psi_k-2} - e^{-\Psi_k+2}}{e^{\Psi_k-2} + e^{-\Psi_k+2}} \\ \xi_{k3} &= \frac{e^{\Psi_k-1} - e^{-\Psi_k+1}}{e^{\Psi_k-1} + e^{-\Psi_k+1}} \\ \xi_{k4} &= \frac{e^{\Psi_k} - e^{-\Psi_k}}{e^{\Psi_k} + e^{-\Psi_k}} \\ \xi_{k5} &= \frac{e^{\Psi_k+1} - e^{-\Psi_k-1}}{e^{\Psi_k+1} + e^{-\Psi_k-1}} \\ \xi_{k6} &= \frac{e^{\Psi_k+2} - e^{-\Psi_k-2}}{e^{\Psi_k+2} + e^{-\Psi_k-2}} \\ \xi_{k7} &= \frac{e^{\Psi_k+3} - e^{-\Psi_k-3}}{e^{\Psi_k+3} + e^{-\Psi_k-3}} \end{aligned}$$

sendo $k = 1, 2$, e 3 .

Note que os pesos w_{ij}^k assumem valores iguais a 1 ou -1. Já a referência (ou seja o *bias*) m_i^k assume valores iguais a -3, -2, -1, 0, 1, 2, 3. O vetor dos pesos que multiplicam as saídas dos neurônios da camada escondida são da seguinte forma:

$$\Theta_i = \begin{bmatrix} \Theta_{k1} & \Theta_{k2} & \Theta_{k3} & \Theta_{k4} & \Theta_{k5} & \Theta_{k6} & \Theta_{k7} \end{bmatrix}^T.$$

Portanto a saída de cada rede neural será:

$$\xi_k \Theta_k = \begin{bmatrix} \xi_{k1} & \xi_{k2} & \xi_{k3} & \xi_{k4} & \xi_{k5} & \xi_{k6} & \xi_{k7} \end{bmatrix} \begin{bmatrix} \Theta_{k1} \\ \Theta_{k2} \\ \Theta_{k3} \\ \Theta_{k4} \\ \Theta_{k5} \\ \Theta_{k6} \\ \Theta_{k7} \end{bmatrix}.$$

Com isso podemos definir uma matriz Ξ que contenha os 7 neurônios de cada rede, portanto:

$$\Xi = \begin{bmatrix} \xi_1 & 0 & 0 \\ 0 & \xi_2 & 0 \\ 0 & 0 & \xi_3 \end{bmatrix}$$

com,

$$\begin{aligned} \xi_1 &= [\xi_{11}, \dots, \xi_{17}], \\ \xi_2 &= [\xi_{21}, \dots, \xi_{27}], \\ \xi_3 &= [\xi_{31}, \dots, \xi_{37}]. \end{aligned}$$

E também um vetor de pesos Θ que contenha os pesos das três redes,

$$\Theta = \begin{bmatrix} \Theta_1 \\ \Theta_2 \\ \Theta_3 \end{bmatrix}$$

com

$$\begin{aligned} \Theta_1 &= \begin{bmatrix} \Theta_{11} & \Theta_{12} & \Theta_{13} & \Theta_{14} & \Theta_{15} & \Theta_{16} & \Theta_{17} \end{bmatrix}^T, \\ \Theta_2 &= \begin{bmatrix} \Theta_{21} & \Theta_{22} & \Theta_{23} & \Theta_{24} & \Theta_{25} & \Theta_{26} & \Theta_{27} \end{bmatrix}^T, \\ \Theta_3 &= \begin{bmatrix} \Theta_{31} & \Theta_{32} & \Theta_{33} & \Theta_{34} & \Theta_{35} & \Theta_{36} & \Theta_{37} \end{bmatrix}^T. \end{aligned}$$

Portanto a saída das três juntas podem ser representadas como:

$$\Xi\Theta = \begin{bmatrix} \xi_1 & 0 & 0 \\ 0 & \xi_2 & 0 \\ 0 & 0 & \xi_3 \end{bmatrix} \begin{bmatrix} \Theta_1 \\ \Theta_2 \\ \Theta_3 \end{bmatrix}$$

Os resultados obtidos são apresentados na Seção 5.5.

5.4.2 Controlador via Lógica Fuzzy

Da mesma forma como foi projetado o controlador através de redes neurais, também definem-se três sistemas fuzzy distintos para se estimar as incertezas do manipulador, os quais são baseados nos modelos de Takagi-Sugeno. As entradas de cada sistema fuzzy são definidas como:

$$x_e = \begin{bmatrix} \tilde{q}_1^T & \dot{\tilde{q}}_1^T \end{bmatrix}^T = \begin{bmatrix} (q^1)^T - (q_d^1)^T & (\dot{q}^1)^T - (\dot{q}_d^1)^T \end{bmatrix}^T.$$

Os conjuntos fuzzy são considerados da seguinte forma:

$$A(x_e) = \begin{bmatrix} A_1(\tilde{q}_1) & A_2(\dot{\tilde{q}}_1) \end{bmatrix}$$

que são definidos no universo de discurso dos erros de posição, para $u_1 = \tilde{q}_1 \in U_1$, e no universo de discurso dos erros de velocidade, para $u_2 = \dot{\tilde{q}}_1 \in U_2$, como mostrados na Figura 5.6.

Figura 5.6: Conjuntos fuzzy $A_1(\tilde{q}_1)$ e $A_2(\dot{\tilde{q}}_1)$.

A base de regras fuzzy é dada por:

$$\begin{aligned}
R_1 &: \mathbf{SE}(u_1 \text{ é } A_{11}) \text{ e } (u_2 \text{ é } A_{12}) \mathbf{ENT\tilde{A}O} y_1 \\
R_2 &: \mathbf{SE}(u_1 \text{ é } A_{11}) \text{ e } (u_2 \text{ é } A_{22}) \mathbf{ENT\tilde{A}O} y_2 \\
R_3 &: \mathbf{SE}(u_1 \text{ é } A_{11}) \text{ e } (u_2 \text{ é } A_{32}) \mathbf{ENT\tilde{A}O} y_3 \\
R_4 &: \mathbf{SE}(u_1 \text{ é } A_{21}) \text{ e } (u_2 \text{ é } A_{12}) \mathbf{ENT\tilde{A}O} y_4 \\
R_5 &: \mathbf{SE}(u_1 \text{ é } A_{21}) \text{ e } (u_2 \text{ é } A_{22}) \mathbf{ENT\tilde{A}O} y_5 \\
R_6 &: \mathbf{SE}(u_1 \text{ é } A_{21}) \text{ e } (u_2 \text{ é } A_{32}) \mathbf{ENT\tilde{A}O} y_6 \\
R_7 &: \mathbf{SE}(u_1 \text{ é } A_{31}) \text{ e } (u_2 \text{ é } A_{12}) \mathbf{ENT\tilde{A}O} y_7 \\
R_8 &: \mathbf{SE}(u_1 \text{ é } A_{31}) \text{ e } (u_2 \text{ é } A_{22}) \mathbf{ENT\tilde{A}O} y_8 \\
R_9 &: \mathbf{SE}(u_1 \text{ é } A_{31}) \text{ e } (u_2 \text{ é } A_{32}) \mathbf{ENT\tilde{A}O} y_9.
\end{aligned}$$

O funcionamento do sistema fuzzy pela metodologia de T-S é resumido no diagrama de blocos apresentado na Figura 5.7. Neste diagrama temos as entradas $\tilde{q}_1$ e $\dot{\tilde{q}}_1$ sendo respectivamente os erros de posição e velocidade das juntas. Tais entradas alimentam dois fuzzificadores e um operador de regressão linear. As saídas dos dois blocos de fuzzificação retornam graus de pertinência dos valores de entrada sobre grupos fuzzy. Esses graus de pertinência são submetidos a um operador lógico **E** que retorna o valor mínimo entre as duas entradas fuzzificadas. As saídas μ_k e y_k são relacionadas pela equação de ponderação (4.23),

$$y_k = \frac{\sum_{i=1}^9 \mu_i^k y_i^k}{\sum_{i=1}^9 \mu_i^k}$$

note que os valores μ_i^k são adimensionais. Sendo $\mu_i^k = A_{c_1 1}(\tilde{q}_1^k) \wedge A_{c_2 j 2}(\dot{\tilde{q}}_1^k)$ e $y_i^k = \theta_{i0}^k + \theta_{i1}^k \tilde{q}_1^k + \theta_{i2}^k \dot{\tilde{q}}_1^k$. Para $c_1 = 1,2,3$ e $c_2 = 1,2,3$.

Para simplificar o desenvolvimento das equações abaixo, o índice k que representa cada um dos três sistemas fuzzy será suprimido e inserido novamente no fim do desenvolvimento, no qual teremos a equação de ponderação para cada sistema fuzzy. Portanto, tem-se:

Figura 5.7: Diagrama fuzzy.

$$y = \frac{\sum_{i=1}^9 \mu_i y_i}{\sum_{i=1}^9 \mu_i} = \frac{\sum_{i=1}^9 \mu_i (\theta_{i0} + \theta_{i1} u_1 + \theta_{i2} u_2)}{\sum_{i=1}^9 \mu_i},$$

$$y = \frac{\begin{bmatrix} \mu_1 \dots \mu_9 & \mu_1 x_e^1 \dots \mu_9 x_e^1 & \mu_1 x_e^2 \dots \mu_9 x_e^2 \end{bmatrix}}{\sum_{i=1}^p \mu_i} \begin{bmatrix} (\theta_{10} \dots \theta_{90})^T \\ (\theta_{11} \dots \theta_{91})^T \\ (\theta_{12} \dots \theta_{92})^T \end{bmatrix},$$

$$y_k = \frac{\begin{bmatrix} \mu_{1 \times 9}^k & \mu_{1 \times 9}^k (x_e^1)^k & \mu_{1 \times 9}^k (x_e^2)^k \end{bmatrix}}{\sum_{i=1}^9 \mu_i^k} \begin{bmatrix} \theta_0^k \\ \theta_1^k \\ \theta_2^k \end{bmatrix},$$

$$\text{sendo : } \mu_{1 \times 9}^k = \begin{bmatrix} \mu_1^k & \mu_2^k & \mu_3^k & \mu_4^k & \mu_5^k & \mu_6^k & \mu_7^k & \mu_8^k & \mu_9^k \end{bmatrix},$$

$$\theta_0^k = \begin{bmatrix} \theta_{10}^k & \theta_{20}^k & \theta_{30}^k & \theta_{40}^k & \theta_{50}^k & \theta_{60}^k & \theta_{70}^k & \theta_{80}^k & \theta_{90}^k \end{bmatrix}^T,$$

$$\theta_1^k = \begin{bmatrix} \theta_{11}^k & \theta_{21}^k & \theta_{31}^k & \theta_{41}^k & \theta_{51}^k & \theta_{61}^k & \theta_{71}^k & \theta_{81}^k & \theta_{91}^k \end{bmatrix}^T,$$

$$\theta_2^k = \begin{bmatrix} \theta_{12}^k & \theta_{22}^k & \theta_{32}^k & \theta_{42}^k & \theta_{52}^k & \theta_{62}^k & \theta_{72}^k & \theta_{82}^k & \theta_{92}^k \end{bmatrix}^T,$$

$$(x_e^1)^k = [\tilde{q}_1^T]^T, \quad e (x_e^2)^k = [\tilde{q}_1^T]^T.$$

Define-se o seguinte parâmetro auxiliar,

$$\beta_{1 \times 9} = \frac{\mu_{1 \times 9}^k}{\sum_{i=1}^9 \mu_i^k}.$$

Com isso a saída de cada sistema fuzzy pode ser expressa como:

$$\begin{aligned} y_k = \Delta F_k(x_e^k) &= \begin{bmatrix} \beta_{1 \times 9} & \beta_{1 \times 9}(x_e^1)^k & \beta_{1 \times 9}(x_e^2)^k \end{bmatrix} \begin{bmatrix} \theta_0^k \\ \theta_1^k \\ \theta_2^k \end{bmatrix} \\ &= \xi_k \Theta_k. \end{aligned}$$

Da mesma forma como em redes neurais podemos definir uma matriz Ξ contendo os vetores ξ_k dos três sistemas fuzzy, portanto:

$$\Xi = \begin{bmatrix} \xi_1 & 0 & 0 \\ 0 & \xi_2 & 0 \\ 0 & 0 & \xi_3 \end{bmatrix}$$

com,

$$\begin{aligned} \xi_1 &= [\beta_{1 \times 9} \quad \beta_{1 \times 9}(x_e^1)^1 \quad \beta_{1 \times 9}(x_e^2)^1], \\ \xi_2 &= [\beta_{1 \times 9} \quad \beta_{1 \times 9}(x_e^1)^2 \quad \beta_{1 \times 9}(x_e^2)^2], \\ \xi_3 &= [\beta_{1 \times 9} \quad \beta_{1 \times 9}(x_e^1)^3 \quad \beta_{1 \times 9}(x_e^2)^3]. \end{aligned}$$

E também um vetor de pesos Θ correspondente às constantes das equações de regressão linear y_k dos três sistemas fuzzy,

$$\Theta = \begin{bmatrix} \Theta_1 \\ \Theta_2 \\ \Theta_3 \end{bmatrix}$$

com,

$$\begin{aligned} \Theta_1 &= \begin{bmatrix} \theta_0^1 & \theta_1^1 & \theta_2^1 \end{bmatrix}^T, \\ \Theta_2 &= \begin{bmatrix} \theta_0^2 & \theta_1^2 & \theta_2^2 \end{bmatrix}^T, \\ \Theta_3 &= \begin{bmatrix} \theta_0^3 & \theta_1^3 & \theta_2^3 \end{bmatrix}^T. \end{aligned}$$

Portanto a saída das três juntas podem ser representadas como:

$$\Xi\Theta = \begin{bmatrix} \xi_1 & 0 & 0 \\ 0 & \xi_2 & 0 \\ 0 & 0 & \xi_3 \end{bmatrix} \begin{bmatrix} \Theta_1 \\ \Theta_2 \\ \Theta_3 \end{bmatrix}.$$

Os resultados obtidos são apresentados na próxima seção.

5.5 Resultados

Nesta seção serão apresentados os resultados experimentais obtidos. Serão mostrados os gráficos de acompanhamento de trajetória das juntas, torque nas juntas, posição X e Y de acompanhamento do efetuador, força/momento medidos e orientação do efetuador robótico.

Para que obtivéssemos os resultados esperados, o ajuste dos parâmetros Θ_k dos sistemas inteligentes foi feito utilizando a equação de atualização do controlador $\mathcal{H}_\infty$ (4.29). A cada interação do algoritmo desenvolvido, o valor $\Xi\Theta$ calculado pelo sistema inteligente é adicionado à equação de torque do controlador (4.30) desenvolvido na Seção 4.4. Note que caso o sistema inteligente esteja estimando o modelo completo, o termo $F_0(x_e) + \Xi\Theta$ é o parâmetro que está sendo estimado de fato.

As condições iniciais e finais do movimento são $(x_0, y_0) = (0.46, 0.38)m$ e $(x(T), y(T)) = (0.53, 0.13)m$. Neste caso, temos as seguintes constantes da Equação (5.2): $a = -3.57$, $b = 2.02$ e $c = 15.64^\circ$. A trajetória de referência para as juntas é definida como $q_d(t)$, que é um polinômio de quinto grau com tempo de duração $T = 4s$. É desejável que não haja forças atuando na direção normal à restrição e que também não haja momento atuando em torno do eixo z , com isso, $\lambda_d = [0 \ 0]^T$. Durante o experimento, um distúrbio limitado foi introduzido da seguinte forma:

$$d = \begin{bmatrix} 0,01e^{\frac{-(t-t_d)^2}{2\mu^2}} \sin(3,6\pi t) \\ -0,01e^{\frac{-(t-t_d)^2}{2\mu^2}} \sin(2,7\pi t) \\ 0,01e^{\frac{-(t-t_d)^2}{2\mu^2}} \sin(1,8\pi t) \end{bmatrix}.$$

Se comparamos o torque nominal ao distúrbio d , este será aproximadamente 64% do valor de pico. A Figura 5.8 representa o distúrbio d .

Na Tabela 5.2 são apresentados os ajustes dos ganhos dos controladores que estamos consi-

Figura 5.8: Perturbação de torque.

derando.

Tabela 5.2: Ganhos dos controladores.

	k_0	k_λ	p	E	Θ	ρ	M_θ
Nominal	0.35	2	2.5	$[1 \ 0 \ 0]^T$	—	—	—
RNIP	0.35	2	2.5	$[1 \ 0 \ 0]^T$	θ_{RNIP}	0.3	0.1
RNMC	0.54	0.8	1.0	$[1 \ 0 \ 0]^T$	θ_{RNMC}	0.3	0.1
TSIP	0.30	0.8	1.0	$[1 \ 0 \ 0]^T$	θ_{TSIP}	1.6	0.2
TSMC	0.54	0.8	1.0	$[1 \ 0 \ 0]^T$	θ_{TSMC}	0.3	0.1

5.5.1 Análise Gráfica

Nesta subseção é feita uma análise dos gráficos obtidos com os ajustes de ganhos dos controladores, tais ganhos foram exibidos na Tabela 5.2.

Os gráficos da Figura 5.9 apresentam o acompanhamento de trajetória para cada um dos controladores propostos. Os resultados experimentais mostram um desempenho interessante dos controladores. Pode-se observar que mesmo na presença de distúrbios, os erros de velocidade e posição permanecem pequenos. Nota-se que os controladores que utilizam sistemas inteligentes para estimar as incertezas paramétricas, RNIP e TSIP, possuem maior estabilidade no acompanhamento de trajetória, ou seja, oscilam menos durante o trajeto. No controlador NOM, que não utiliza sistemas inteligentes a atuação do controlador, é mais lenta o que gera um erro maior de acompanhamento dos sinais de referência.

Nos gráficos da Figura 5.10 temos os torques aplicados nas juntas dos manipuladores robóticos. Observa-se que no intervalo correspondente ao distúrbio inserido, os controladores atuam fortemente no sistema, chegando a inverter os sentidos dos torques das juntas 1 e 2 e a intensificar o torque da junta três. Nesta análise verifica-se que os controladores que utilizam redes neurais, RNIP e RNMC, oscilam menos e portanto possuem uma resposta um pouco mais lenta no tempo. Isto também pode ser verificado nas Figuras 5.9(a) e 5.9(b), nas quais a trajetória de acompanhamento demora mais a atingir a trajetória desejada após a inserção do distúrbio nos respectivos torques das juntas.

Os gráficos da Figura 5.11 representam as posições (x, y) do efetuador robótico.

Os gráficos da Figura 5.12 representam as medições de força e momento no efetuador robótico. Tais gráficos são importantes porque mostram o comportamento do efetuador durante as ações do controlador. Como esperado, observa-se que durante o período em que o distúrbio atuou no sistema houve maior intensidade de forças e momentos os quais diminuíram gradativamente, tendendo ao zero, até atingir o tempo final (4s).

Ns gráficos da Figura 5.13 são exibidos os ângulos de acompanhamento das três juntas do manipulador robótico. Novamente nota-se que o maior desvio está no intervalo em que o distúrbio atuou. Mesmo assim o experimento demonstrou um bom acompanhamento das trajetórias desejadas. Novamente pode-se observar que para o controlador sem o sistema inteligente, NOM, a atuação do controle é mais lenta propiciando maior erro de acompanhamento dos sinais de referência.

Os gráficos da Figura 5.14 mostram a orientação do efetuador robótico. Em tese a orientação do efetuador deveria ser constante, devido á restrição imposta ao manipulador; houve um desvio de aproximadamente 3° na orientação do efetuador. Tal desvio pode ser observado em todos os controladores.

Os gráficos da Figura 5.15 mostram as trajetórias de velocidade das juntas. Pode-se verificar suavidade do movimento das juntas no tempo. Como comentado anteriormente em 5.9 e 5.10, pode-se observar que os controladores baseados em redes neurais (RNIP e RNMC) são mais suaves, ou seja, possuem uma resposta mais lenta no tempo se comparados aos controladores baseados em sistemas fuzzy (TSIP e TSMC).

5.5.2 Análise Quantitativa

Para comparar a eficiência dos controladores não lineares $\mathcal{H}_\infty$ desenvolvidos, os três índices de desempenho definidos na subseção 5.3 foram utilizados ($\mathcal{L}_2[\tilde{x}]$, $E[\tau]$ e $E[\lambda]$). Os resultados são apresentados na Tabela 5.3, os quais representam as médias dos valores de cinco experimentos.

Tabela 5.3: Índice de desempenho.

	$\mathcal{L}_2[x]$	$E[\tau]$	$E[\lambda]$
Nominal	0.1031	0.6508	0.1506
RNIP	0.0780	0.6564	0.1435
RNMC	0.1026	0.4318	0.1156
TSIP	0.0759	0.5865	0.1136
TSMC	0.0899	0.5182	0.1061

Da Tabela 5.3 pode-se concluir que o controlador baseado apenas no modelo nominal apresenta maior erro de estado e maiores forças de esmagamento. Apesar dos controladores baseados em lógica fuzzy apresentarem melhores resultados, a diferença de desempenho com relação aos controladores baseados em redes neurais merece um estudo mais detalhado, que será feito em trabalhos futuros.

(a) RNIP

(b) RNMC

(c) TSIP

(d) TSMC

(e) NOM

Figura 5.9: Acompanhamento de trajetória.

(a) RNIP

(b) RNMC

(c) TSIP

(d) TSMC

(e) NOM

Figura 5.10: Torque nas juntas.

(a) RNIP

(b) RNMC

(c) TSIP

(d) TSMC

(e) NOM

Figura 5.11: Posição X e Y do efetuator

(a) RNIP

(b) RNMC

(c) TSIP

(d) TSMC

(e) NOM

Figura 5.12: Força e momento no efetuator.

(a) RNIP

(b) RNMC

(c) TSIP

(d) TSMC

(e) NOM

Figura 5.13: Ângulo de acompanhamento das juntas.

(a) RNIP

(b) RNMC

(c) TSIP

(d) TSMC

(e) NOM

Figura 5.14: Orientação do efetuador.

(a) RNIP

(b) RNMC

(c) TSIP

(d) TSMC

(e) NOM

Figura 5.15: Velocidade de acompanhamento das juntas.

Conclusão

Nesta dissertação, o problema do controle de acompanhamento de trajetória com garantia de desempenho $\mathcal{H}_\infty$ foi considerado para manipuladores com restrição de força e posição. Cinco controladores foram avaliados:

- O primeiro controlador, denominado nominal, considera que o termo $F(x_e)$ é completamente conhecido, ou seja, não leva em conta incertezas paramétricas do modelo.
- O segundo e terceiro controladores possuem estimadores baseados em redes neurais, sendo que o segundo considera conhecido o modelo nominal do manipulador e estima somente incertezas paramétricas, já o terceiro estima o modelo completo.
- O quarto e quinto controladores possuem estimadores baseados em lógica fuzzy e estimam, como no item anterior, incertezas paramétricas apenas e o modelo completo.

A real contribuição desta dissertação consiste no desenvolvimento dos controladores com estimadores para incertezas paramétricas, na comparação dos controladores desenvolvidos com os existentes na literatura (controladores que estimam o modelo total), e no desenvolvimento de um sensor para medição de força e momento em três eixos ortogonais. O sensor de força desenvolvido em nosso laboratório apresenta estrutura e projeto simples, podendo ser uma alternativa econômica em comparação com os sensores de força disponíveis no mercado.

Como pode ser verificado no Capítulo 5, os controladores RNIP e TSIP possuem melhor acompanhamento de trajetória se comparados, respectivamente, com os RNMC e TSMC. Verifica-se também que são mais estáveis por apresentarem menores oscilações após a inserção de distúrbio, sendo que esta característica ocorre tanto para o acompanhamento da trajetória no espaço cartesiano como para o acompanhamento da trajetória dos ângulos das juntas. Comparando-se os resultados dos sistemas inteligentes notou-se que os controladores via redes neurais (RNIP e RNMC) têm uma ação de controle mais suave e, em decorrência disso, apresentam menores

oscilações do que os sistemas fuzzy (TSIP e TSMC), o que pode ser verificado ao se comparar os gráficos de torque (Figura 5.10) e de velocidade (Figura 5.15). Por outro lado, os controladores RNIP e RNMC são mais lentos que os TSIP e TSMC, portanto tendem a ter um erro de acompanhamento maior. Além disso, todos os controladores responderam bem na presença de distúrbio.

Pela análise dos índices de desempenho propostos verificou-se que o erro de estado nos controladores baseados em lógica fuzzy (TSIP e TSMC) tendem a ser menores do que os baseados em redes neurais (RNIP e RNMC). Uma explicação para isto está no fato de que os sistemas fuzzy agiram mais rápido que as redes neurais. Observou-se que a escolha dos valores de k_λ influenciam mais diretamente no ajuste das forças de esmagamento enquanto que os valores de ρ nos erros de acompanhamento das variáveis de estado.

Comparando os gastos de energia dos controladores RNIP e TSIP com NOM, verifica-se que tanto a energia consumida ($E[\tau]$) quanto as forças de esmagamento ($E[\lambda]$) diminuíram, mas os controladores RNMC e TSMC ainda tiveram melhores resultados.

Referências Bibliográficas

- [1] Begovich, O., E. N. Sanchez, e M. Maldonado (2002). Takagi-Sugeno fuzzy scheme for real-time trajectory tracking of an underactuated robot. *IEEE Transactions on Control Systems Technology*, Volume 10(1), pp. 14–20.
- [2] Carelli, R. e R. Kelly (1991). An adaptive impedance/force controller for robot manipulators. *IEEE Transactions on Automatic Control* 36(8), 967–971.
- [3] Chae, A., C. Atkeson, e J. Hollerbach (1988). *Model-Based Control of a Robot Manipulator*. Cambridge: MA: MIT Press.
- [4] Chang, Y. C. (2000). Neural network-based $\mathcal{H}_\infty$ tracking control for robotic systems. *IEEE Proceedings on Control Theory Applications*, Volume 147(3), pp. 303–311.
- [5] Chang, Y. C. (2005). Intelligent robust control for uncertain nonlinear time-varying systems and its application to robotic systems. *IEEE Transactions on Systems, Man and Cybernetics - Part B: Cybernetics*, Volume 35(6), pp. 1108–1119.
- [6] Chang, Y. C. e B. S. Chen (1997). A nonlinear adaptive $\mathcal{H}_\infty$ tracking control design in robotic systems via neural networks. *IEEE Transactions on Control Systems Technology*, Volume 5(1), pp. 13–28.
- [7] Chang, Y. C. e B. S. Chen (1998). Adaptive tracking control design of constrained robot systems. *International Journal of Adaptive Control Signal Processing* Volume. 12(6), pp. 495–526.
- [8] Chang, Y. C. e B. S. Chen (2000). Robust tracking designs for both holonomic and nonholonomic constrained mechanical systems: Adaptive fuzzy approach. *IEEE Transactions on Fuzzy Systems* Volume 8(8), pp. 46–66.
- [9] Doebelin, E. O. (1989). *Measurement Systems Application and Design*. McGraw-Hill Science.

- [10] Jean, J. H. e L. C. Fu (1993). Adaptive hybrid control strategies for constrained robots. *IEEE Transactions Automatic Control* 38(4), pp. 598–603.
- [11] Johansson, R. (1990). Quadratic optimization of motion coordination and control. *IEEE Transactions on Automatic Control, Volume* 35(11), pp. 1197–1208.
- [12] Khalil, H. K. (1996). Adaptive output feedback control of nonlinear systems represented by input-output models. *IEEE Transaction on Automatic Control Volume* 41(2), pp. 177–188.
- [13] Lewis, F. L., C. T. Abdallah, e D. M. Dawson (1993). *Control of Robot Manipulators*. New York: MacMillan Publishing Company.
- [14] McClamroch, N. H. e D. Wang (1988). Feedback stabilization and tracking of constrained robots. *IEEE Transactions on Automatic Control, Volume* 5(33), pp. 419–426.
- [15] Meyer, R. A. e A. E. Lowe (1987). Patente americana us4640138.
- [16] Meyer, R. A. e D. J. Olson (1989). Patente americana us4821582.
- [17] Murray, R. M., Z. Li, e S. S. Sastry (1994). *A Mathematical Introduction to Robotic Manipulation*. University of Colorado: CRC Press.
- [18] Ortega, R. e M. W. Spong (1989). Adaptive motion control of rigid robots: a tutorial. *Automatica* 25(6), 877–888.
- [19] Panteley, E. V. e A. A. Stotsky (1993). Adaptive trajectory/force control scheme for constrained robot manipulators. *International Journal of Adaptive Control Signal Processing* 7(6), 489–496.
- [20] Paul, R. e B. Shimano (1976). Compliance and control. *Joint Automatic Control Conference*, pp. 694–699.
- [21] Petronilho, A., A. A. G. Siqueira, e M. H. Terra (2005). Adaptive $\mathcal{H}_\infty$ control design via neural networks of a constrained robot system. In *IEEE Conference on Decision and Control (CDC)*, Volume 44, Seville, Spain, pp. 5528–5533.
- [22] Raibert, M. e J. Craig (1981). Hybrid position/force control of manipulators. *ASME Journal of Dynamics Systems, Measurement, and Control, Volume* 102(102), pp. 126–133.
- [23] Salisbury, J. e J. Craig (1980). Active stiffness control of manipulators. In *ASME Journal of Dynamics Systems*, Volume 19, pp. 95–100.

-
- [24] Sciavicco, L. e B. Siciliano (1996). *Modeling and Control of Robot Manipulators*. University of Naples, Naples, Italy: McGraw-Hill International Editions.
- [25] Shaoceng, T., T. Jiantao, e W. Tao (2000). Fuzzy adaptive control of multivariable nonlinear systems. *Fuzzy Sets and Systems, Volume 111*(2), pp. 153–167.
- [26] Slotine, J. J. E. e W. Li (1989). Composite adaptive control of robot manipulators. *Automatica* 25(4), pp. 509–519.
- [27] Slotine, J. J. E. e W. Li (1991). *Applied Nonlinear Control*. Englewoods Cliffs.
- [28] Sommerfeld, J. L., R. A. Meyer, B. A. Larson, e D. J. Olson (1999). Patente americana us5969268.
- [29] Spong, M. W. e M. Vidyasagar (1989). *Robot Dynamics and Control*. New York.
- [30] Su, C. Y., Y. Stepanenko, e T. P. Leung (1995). Combined adaptive and variable structure control for constrained robots. *Automatica* 31(3), pp. 483–488.
- [31] Takagi, T. e M. Sugeno (1985). Fuzzy identification of systems and its applications to modeling and control. *IEEE Transactions on Systems, Man and Cybernetics, Volume 15*, pp. 116–132.
- [32] Tseng, C. S. e B. S. Chen (2000). Fuzzy tracking control design for nonlinear discrete-time dynamic systems via T-S fuzzy model. In *IEEE International Conference of Fuzzy Systems*, Volume 1, San Antonio, TX, USA, pp. 405–410.
- [33] Vafa, Z. e S. Dubowsky (1990). The kinematics and dynamics of space manipulators: The virtual manipulator approach. *Intenational Journal of Robotics Research, Volume 9*(4), pp. 3–21. MIT Press.
- [34] Y., S. C., T. P. Leung, e Q. J. Zhou (1992). Force/motion control of constrained robots using sliding mode. *IEEE Transaction on Automatic Control* 37(5), pp. 668–672.