

Hilton Seheris da Silva Santos

**Sintonia Online de Controladores PID
Adaptativo-Ótimo via Redes Neurais
Artificiais**

São Luís

2017

Hilton Seheris da Silva Santos

Sintonia Online de Controladores PID Adaptativo-Ótimo via Redes Neurais Artificiais

Dissertação apresentada ao Programa de Pós Graduação em Engenharia de Eletricidade da UFMA como parte dos requisitos necessários para a obtenção do grau de Mestre em Engenharia de Eletricidade. Área de concentração: Automação e Controle.

Universidade Federal do Maranhão

Centro de Ciências Exatas e Tecnologia

Programa de Pós Graduação em Engenharia de Eletricidade

Orientador: Prof. Dr. João Viana da Fonseca Neto

São Luís

2017

Santos, Hilton Seheris da Silva.
Sintonia Online de Controladores PID Adaptativo-Ótimo via Redes Neurais Artificiais/
Hilton Seheris da Silva Santos. – São Luís, 2017-
101 p.
Orientador: João Viana da Fonseca Neto.
Dissertação (Mestrado) - Programa de Pós-graduação em Engenharia de Eletricidade/ccet,
Universidade Federal do Maranhão, São Luís, 2017.
1. Controlador PID. 2. Controle adaptativo. 3. Controle preditivo. 4. Sintonia *online*. 5.
Redes neurais artificiais. 6. Painel fotovoltaico.

Hilton Seheris da Silva Santos

Sintonia Online de Controladores PID Adaptativo-Ótimo via Redes Neurais Artificiais

Dissertação apresentada ao Programa de Pós Graduação em Engenharia de Eletricidade da UFMA como parte dos requisitos necessários para a obtenção do grau de Mestre em Engenharia de Eletricidade. Área de concentração: Automação e Controle.

Trabalho aprovado. São Luís, 26 de junho de 2017:

Prof. Dr. João Viana da Fonseca Neto
(Orientador)

**Prof. Dr. Francisco das Chagas de
Souza**
(Membro da Banca Examinadora)

**Prof. Dr. Raimundo Carlos Silvério
Freire**
(Membro da Banca Examinadora)

São Luís
2017

*Este trabalho é dedicado às pessoas amantes da ciência,
que acreditam em mundo de valorização do conhecimento.*

Agradecimentos

Primeiramente a Deus, pelo dom da vida e pela chance que me foi concedida.

Ao professor Prof. Dr. João Viana da Fonseca Neto, pela sua orientação, amizade e disponibilidade durante todo este tempo. Agradeço pela oportunidade de trabalhar e aprender com este grupo.

A todas as pessoas que por motivo de esquecimento não foram citadas anteriormente, vou deixando neste espaço minhas sinceras desculpas.

*“(...) No mundo inteligível, a ideia do bem é a última a ser apreendida, e com dificuldade, mas não se pode apreendê-la sem concluir que ela é a causa de tudo o que de reto e belo existe em todas as coisas; no mundo visível, ela engendrou a luz; no mundo inteligível, é ela que é soberana e dispensa a verdade e a inteligência; e é preciso vê-la para se comportar com sabedoria na vida particular e na vida pública.
(A República, Mito da caverna, diálogo de Sócrates com Glauco.)*

Resumo

O surgimento de novas plantas industriais com grande complexidade e a necessidade de melhorar a operação das plantas já existentes tem fomentado o desenvolvimento de sistemas de controle de alto desempenho, estes sistemas devem atender não só as especificações de projeto, tal como: figuras de mérito, mas também devem operar com um custo mínimo e sem causar impactos desastrosos para o meio ambiente. Motivados por esta demanda, apresenta-se nesta dissertação o desenvolvimento de métodos para sintonia *online* dos parâmetros dos sistemas de controle, ie, apresenta-se uma metodologia para a sintonia *online* de controladores PID adaptativo e ótimo via Redes Neurais Artificiais (RNAs). A abordagem desenvolvida nesta dissertação tem base as ações dos controladores PID de três termos, redes neurais artificiais com funções de base radial e Controle preditivo baseado em modelo (MPC - *Model Predictive Control*), a partir da união destas abordagens elabora-se a formulação geral do controlador PID Adaptativo-Ótimo via redes neurais artificiais, com sintonia *online*. A metodologia de ajuste *online* dos parâmetros da RNA está no contexto do MPC para predição de saída da planta. Para o caso do controlador PID, tem-se a modificação da estrutura padrão com o objetivo de adaptação em função do erro. O ajuste dos termos do controlador PID e da predição da saída na planta, de forma ótima, é realizada pelo ajustes dos pesos da RNA-RBF. Além disso, apresenta-se a implementação *indoor* do sistema de controle desenvolvido para o posicionamento de um painel fotovoltaico. As avaliações de desempenho do sistema proposto são obtidos de resultados de experimentos computacionais que são baseados em modelos matemáticos e experimentos em *hardware* que são obtidos de um modelo reduzido de um painel fotovoltaico. Por fim, comparando o PID clássico com o controlador desenvolvido constatou-se que este último apresenta mais flexibilidade para inserir novas métricas de desempenho e os resultados atingidos são melhores do que os parâmetros obtidos por meio da sintonia do PID clássica, tais como: métodos de Ziegler-Nichols ou tentativa e erro.

Palavras-chave: Sintonia *online*, redes neurais artificiais, controlador PID, controle adaptativo, painel fotovoltaico e controle preditivo.

Abstract

The emergence of new industrial plants with great complexity and the need to improve the operation of existing plants has fostered the development of high performance control systems, these systems must not only meet the design specifications, such as merit figures, but also operate at minimal cost and impacts at environment. Motivated by this demand, it is presented in this dissertation the development of methods for on-line tuning of control system parameters, ie, a methodology is presented for the on-line tuning of adaptive and optimal PID controllers via Artificial Neural Networks(ANNs). The approach developed in this dissertation is based on three PID controllers parameters. [Artificial neural networks with radial base functions and Model Predictive Control (MPC). From the union of these approaches a general formulation of an Adaptive-optimal PID controller via artificial neural networks with on-line tuning was presented. The on-line tuning methodology for the ANN parameters is presented in the context of MPC, predicting plant output. For the PID controller, we proposed a modification of the standard structure in order to adapt the error function. The adjustment of the PID controller parameters and the prediction of the optimally plant output, are performed by the ANN-RBF weights adjustments. In addition, an indoor implementation of the control system were proposed for the positioning of a photovoltaic panel. The performance evaluations of the proposed system were obtained from computational experiments results that were based on mathematical models and hardware experiments, that were obtained from a reduced model of a photovoltaic panel. Finally, a comparison between the proposed methodology with the classical PID controller were performed and the proposed methodology presented to be more flexible to the insertion of new performance metrics and the results achieved from the ANN, were better than the ones obtained by the classical PID tuning, such as: Ziegler-Nichols or trial and error.

Keywords: Online tuning, artificial neural networks, PID controller, adaptive control, photovoltaic panel and Controle predictivo.

Lista de ilustrações

Figura 1 – Arquitetura do Sistema de Controle de Alto Desempenho.	16
Figura 2 – Esquema para projeto de controle.	22
Figura 3 – Configuração de um sistema de controle adaptativo.	36
Figura 4 – Esquema de controle adaptativo indireto	37
Figura 5 – Esquema para a estimação de parâmetros <i>online</i>	38
Figura 6 – Esquema de um controlador linear em ambiente determinístico	39
Figura 7 – Estrutura básica do MPC.	40
Figura 8 – Estratégia do MPC.	41
Figura 9 – Respostas ao impulso e degrau.	42
Figura 10 – Representação de sinais em resposta livre e forçada	43
Figura 11 – Estrutura de uma rede <i>RBF</i>	45
Figura 12 – Representação de resposta livre e forçada	51
Figura 13 – Blocos para construção de preditores: (a) deformador, (b) adicionador, (c) multiplicador	52
Figura 14 – Sequência de tarefas envolvidas na aplicação genérica de sistema MPC.	53
Figura 15 – MPC direto baseado em RNAs com de otimização iterativo.	56
Figura 16 – Esquema do mecanismo de predição baseado na RNA - RBF.	57
Figura 17 – Esquema do controlador PID Neural RBF	60
Figura 18 – Sistema de rastreamento.	64
Figura 19 – Modelagem matemática do painel solar	66
Figura 20 – Estrutura da Neural RBF Preditiva	67
Figura 21 – Arquitetura em malha fechado do <i>SC-Tracker</i> MPC	69
Figura 22 – Representação dos Polos e Zeros	71
Figura 23 – Resposta ao degrau com sistema sem controle.	72
Figura 24 – Resposta ao degrau com PID.	73
Figura 25 – Sinal de predição do sistema de rastreamento.	74
Figura 26 – Resposta ao degrau unitário - sistema simulado.	75
Figura 27 – Resposta ao degrau unitário - sistema real.	76
Figura 28 – Processo dinâmico com entrada u e saída y	86
Figura 29 – Sistema de controle em malha fechada.	88
Figura 30 – Sistema de típico de controle industrial.	88
Figura 31 – Sistema de controle com PID em s	89
Figura 32 – Principais componentes de uma célula nervosa.	91
Figura 33 – Conexão sináptica entre neurônios.	92
Figura 34 – Modelo não-linear de um neurônio.	93
Figura 35 – Modelo não-linear de um neurônio.	94

Figura 36 – Função limiar.	95
Figura 37 – Função logística para variar o parâmetro de inclinação a	96
Figura 38 – Rede <i>feedforward</i> de Camada Simples	97
Figura 39 – Rede <i>feedforward</i> de Camadas Múltiplas	97
Figura 40 – Redes Recorrentes ou realimentada	98
Figura 41 – Esquema da rede Perceptron	98
Figura 42 – Estrutura perceptrons de múltiplas camadas	101

Lista de tabelas

Tabela 1 – Comportamento do sistema em relação ao ID	72
Tabela 2 – Valores dos parâmetros do controlador PID	73
Tabela 3 – Comportamento do sistema em relação aos IDs com controle	73

Lista de abreviaturas e siglas

MPC	Model Predictive Control
RBF	Radial Basis Function
RNA	Rede Neural Artificial
MIMO	Multiple Input – Multiple Output
FDP	Função Densidade de Probabilidade
MRAC	Model Reference Adaptive Control
MRAS	Model Reference Adaptive Systems
FIR	Finite impulse response
IIR	Infinite impulse response
MMSE	Minimum Mean Square Error
PSO	Particle swarm optimization
DE	Differential Evolution
RS	Radiação Solar
EDO	Equação Diferencial Ordinária
GMV	Generalized Minimum Variance
GPC	Generalized Predictive Control

Sumário

1	INTRODUÇÃO	16
1.1	Objetivos	18
1.1.1	Objetivo Geral	18
1.1.2	Objetivo Específicos	18
1.2	Motivação	19
1.3	Organização da dissertação	19
2	PROBLEMA DA SINTONIA E ESTADO DA ARTE	21
2.1	O Problema da Sintonia de Controladores PID	21
2.1.1	Métodos de sintonia do controlador PID	22
2.1.2	Modelos para Controle Digital	22
2.1.2.1	Modelo Matemáticos de Sistemas em tempo discreto	23
2.1.2.2	Controlador PID Discreto	24
2.1.3	Controlador PID discretizado com modificação	26
2.2	Estado da Arte	27
2.2.1	Controlador PID	27
2.2.2	Controle Adaptativo	28
2.2.3	Controle preditivo via rede neural	29
2.3	Solução Proposta	31
2.4	Comentários	31
3	CONTROLE ADAPTATIVO E RNA	32
3.1	Controle Adaptativo	32
3.1.1	Otimalidade	33
3.1.2	CrITÉrios de Otimalidade	33
3.1.3	Estrutura do Controle adaptativo	36
3.1.4	Controle Adaptativo Indireto	37
3.1.5	Controle Adaptativo Direto	38
3.2	Sistema de Controle Preditivo	39
3.2.1	Controle Preditivo Baseado em Modelo - MPC	39
3.2.2	Função Objetivo do MPC	43
3.3	Redes Neurais Artificiais para Controle	44
3.3.1	Modelagem Neural	45
3.3.2	Redes Neurais Artificiais de Função de Base Radial RNA - RBF	45
3.4	Comentários	49

4	SINTONIA RNA-PREDITIVA DE CONTROLADORES PID	50
4.1	Arquitetura do Sistema de Predição	50
4.2	Controle Preditivo e RNA	53
4.2.1	MPC direto baseado em RNAs	54
4.2.2	Preditor recursivo <i>d-Step</i> à frente	55
4.2.2.1	Preditor não recursivo <i>d-Step</i> à frente	55
4.3	Predição de Sistemas e RNA-RBF	56
4.4	Sintonia RNA-RBF de Controlador PID	59
4.4.1	Estrutura do controlador PID-RBF neural	60
4.4.2	Atualização dos parâmetros da rede	61
4.5	Comentários	62
5	O SISTEMA EMBARCADO <i>SC-TRACKER</i>	63
5.1	O Problema do Alvo Móvel	63
5.2	Modelagem do <i>SC-Tracker</i>	64
5.2.1	Descrição do Sistema Planta/Controle	64
5.2.2	Modelo da Planta	65
5.2.3	Modelo do Controle Adaptativo Ótimo	66
5.3	Sintonia RNA-RBF proposta	68
5.4	Sistema Embarcado de Controle para Rastreamento	68
5.4.1	Algoritmos do Sistema Embarcado	69
5.5	Experimentos Computacionais e Hardware	71
5.5.1	Experimentos Computacionais	71
5.5.2	Experimentos em Hardware	75
5.6	Comentários	75
6	CONCLUSÃO	77
6.1	Conclusões Gerais	77
6.2	Contribuições	77
6.3	Trabalhos Futuros	78
	Referências	79
A	CONCEITOS DE MODELAGEM E CONTROLADORES PID	85
A.1	Modelagem de Sistemas Dinâmicos	85
A.1.1	Modelo matemáticos de sistemas em tempo contínuo	86
A.1.2	Sistemas de controle por malha fechada	87
A.2	Ações do Controlador PID	88
A.2.1	Ação proporcional (P) do controlador PID	89
A.2.2	Ação integrativa (I) do controlador PID	89

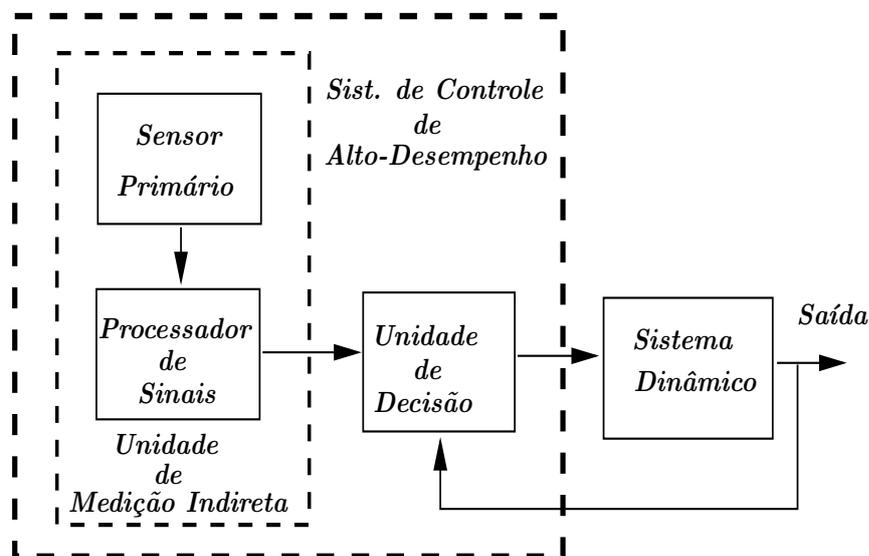
A.2.3	Ação derivativa (D) do controlador PID	90
B	CONCEITOS DE REDES NEURAIS ARTIFICIAIS	91
B.1	Fisiologia Neural	91
B.1.1	Junção Sináptica	92
B.1.2	Unidade Neural	93
B.1.3	Função de ativação	94
B.1.4	Topologia das Redes Neurais Artificiais - RNAs	96
B.1.5	Perceptrons de Múltiplas Camadas	100
B.1.6	Algoritmo <i>Backpropagation</i>	101

1 Introdução

A humanidade tem sempre procurado a melhor solução de problemas no ambiente que a cerca. Conforme a situação, essas soluções podem ser de várias maneiras possíveis. Citam-se os problemas de engenharia com um menor custo possível sem perder a qualidade. Os sistemas de controle de alto desempenho contribuem para atender esta necessidade premente do mundo contemporâneo.

Desta forma, percebe-se a demanda por novas arquiteturas que superem ou agreguem valor ao projeto de sistema de controle em malha fechada. Estes novos sistemas devem satisfazer a incerteza da operação (erros humanos), redução de custos na produção do produto final e variações do processo. A Figura 1 representa uma arquitetura do sistema de controle de alto desempenho proposto nesta dissertação para atender e agregar as qualidades de alto desempenho nos sistemas de controle.

Figura 1 – Arquitetura do Sistema de Controle de Alto Desempenho.



Fonte: Elaborado pelo autor

Os sistemas de controle inteligente apresentam propriedades de adaptabilidade, predição e aprendizado que são associadas à abordagem de inteligência computacional. As metodologias clássicas de estimação paramétrica tem a finalidade de obter a sintonia dos ganhos da função de transferência da malha de controle adaptativo e ótimo. A união destas abordagens tem-se mostrado uma alternativa atraente para sintonia *online* dos parâmetros dos estimadores e controladores em sistemas do mundo real. No contexto de

sistemas de controle de alto desempenho, modelos e algoritmos propostos baseados em Redes Neurais Artificiais (RNA) são desenvolvidos e avaliados para realização da sintonia *online* em arquiteturas de controle adaptativo.

Observa-se na Figura 1 que o sistema de controle de alto desempenho é constituído dos blocos das unidades de decisão e de medição indireta. A unidade de decisão realiza a arquitetura de controle adaptativo com seus estimadores, modelos de referência e leis de controle com propriedades de otimalidade e robustez. A unidade de medição indireta processa os sinais capturados (processador de sinais) pelo sensor primário, por meios de algoritmos baseado em RNA que envia a unidade de decisão comparando o sinal de saída do sistema dinâmico.

Os resultados de uma pesquisa para o projeto *online* de controladores de alto desempenho são apresentados nesta dissertação. Estes controladores, além de atender as especificações de projeto, estão comprometidos em promover melhorias de baixo custo operacional. Para atingir as mencionadas qualidades de alto desempenho, mostra-se o desenvolvimento de um sistema de controle adaptativo-ótimo baseado em redes neurais e mecanismo de predição. Esse mecanismo é tratado no contexto de controladores baseados em MPC (*Model Predictive control*).

A inserção de novos métodos que contribuem para atender novas demandas tecnológicas de alto desempenho operacional vem crescendo ao longo deste milênio. Para tanto, as abordagens de adaptabilidade representada pelo controle adaptativo e de otimalidade representada pelo controle ótimo. Essas abordagens fornecem a base teórica para o desenvolvimento da metodologia proposta para o projeto *online* de sistemas de controle.

Durante o projeto deve-se estar atento para problemas relacionados com a teoria do controle ótimo e com aplicações *online* que podem surgir durante a fase de desenvolvimento e implementação, tais como:

a) Teoria do controle ótimo.

A teoria do controle ótimo fornece o suporte para resolver problemas de automação em processos elétricos, mecânicos e industriais. Muitas vezes, a natureza física destes processos introduzem atrasos de tempo. Em sistemas de engenharia, os atrasos são, muitas vezes, presentes devido às defasagens de medição, transmissão e transporte, operações computacionais, ou comportamento dinâmico não modelado de componentes do sistema (VINTER, 2010). Em sistemas de controle, sabe-se que os atrasos de tempo podem prejudicar o desempenho do sistema e até mesmo causar a instabilidade (BEVRANI, 2009). A presença de atrasos de tempo, muitas vezes, coloca vários desafios, em ralação a uma solução ótima.

b) Aplicações *online*

As aplicações *online* apresentam gargalos que requerem uma investigação na im-

plementação para não comprometerem os projetos de controle em tempo real. Por exemplo, os métodos de otimização necessitam de grandes esforços computacionais que muitas vezes tendem a falhar com a complexidade do sistema dinâmico.

Nesta dissertação é apresentado o desenvolvimento e implementação de modelos para projeto de controladores PID via sintonia *online* e características de adaptabilidade e otimalidade. O desempenho do método para sintonia de controladores PID adaptativo-ótimo é avaliado em um sistema de controle de posição de um painel fotovoltaico. Especificamente para fins de avaliação da metodologia, apresenta-se o procedimento para implementação do controle PID, aplicando um método de sintonia clássico e em sequência verifica-se o desempenho do sistema de controle. Por fim, em relação ao índice de desempenho dos controladores, compara-se o desempenho do PID adaptativo-ótimo via RNA proposto com o controlador PID clássico. As implementações são associadas aos algoritmos *online* que são desenvolvidos para ajustes dos parâmetros em sistemas de controle com arquitetura PID e adaptativo-ótimo. Em termos de *hardware*, o desempenho do sistema desenvolvido é avaliado *indoor* no controle de posição de um painel fotovoltaico.

1.1 Objetivos

Os objetivos deste trabalho são classificados em gerais e específicos. Desta forma, distinguem-se os pontos abrangentes a serem alcançados para que sejam logrados os fins essenciais.

1.1.1 Objetivo Geral

O objetivo geral da dissertação é apresentar o desenvolvimento de uma metodologia para o projeto online de controladores PID adaptativo e PID adaptativo-ótimo. Como também, implementar e avaliar o método proposto de sintonia em um sistema de posicionamento de painel fotovoltaico.

1.1.2 Objetivo Específicos

1. Desenvolver uma rede neural para previsão da saída do comportamento do sistema dinâmico em malha-fechada;
2. Desenvolver algoritmos *online* para ajustes de parâmetros em sistemas de controle com arquitetura PID e adaptativo-ótimo;
3. Avaliar (*indoor*) o desempenho do método de sintonia dos parâmetros em modelos reduzidos de plantas do mundo real, tais como: controle de posição angular;

4. Desenvolver um sistema embarcado para o controle de posição de um painel fotovoltaico;

1.2 Motivação

A má regulação dos sistemas de controladores industriais é a principal motivação para o desenvolvimento desta pesquisa. De forma que os métodos de sintonia têm a vantagem de facilitar o cálculo dos parâmetros do controlador (quando comparados com métodos de concepção analíticos). Por outro lado, o uso de regras de sintonia é uma boa alternativa para o ajuste por tentativa e erro. É claro que as várias regras de sintonia de controlador propostas na literatura não tem um impacto industrial na prática. Uma razão é que as regras de sintonia não são acessíveis, estando espalhadas por toda a literatura de controle. Além disso, a notação utilizada não é unificada.

Pode-se verificar a importância crescente em relação à sintonia *online* de controladores PI e PID em uma referência de O'Dwyer (2009), da primeira edição de 2002 até a de 2009 que foram computados e resumidas as regras de sintonia para esses controladores de processos com uma única entrada e saída (*Single Input, Single Output* - SISO) e com atraso de tempo. De forma que na edição de 2009, observa-se um total de 1731 regras de sintonia. Das quais 60% foram especificadas para sintonia *online*.

A motivação em relação a utilização de RNA para a adaptação do sistema de controle vem das técnicas de aprendizagem empregadas que têm sido baseadas em estruturas de funções de base radial (*Radial Basis Function* - RBF). Uma das suas vantagens é que requerem recursos computacionais e de armazenamento mínimos, o que os torna ideais para agentes móveis (PAPAIOANNOU; ROUSSAKI; ANAGNOSTOU, 2006) (NARENDRA; ANNASWAMY, 2012).

1.3 Organização da dissertação

A dissertação está organizada em capítulos que apresentam, inicialmente, a formulação e solução do problema e apêndices com fundamentos de controladores PID e de Redes Neurais Artificiais (RNA). No decorrer do desenvolvimento do projeto *online*, o estado da arte é associado aos modelos e algoritmos da metodologia proposta.

O problema da sintonia e o estado da arte são apresentados no Capítulo 2. Apresenta-se o modelo matemático de sistemas em tempo discreto que tem suas origens nos modelos de tempo contínuo, os referidos modelos são apresentados no Apêndice A. Ainda, aborda-se o modelo discretizado de controladores PID com estrutura modificada.

No Capítulo 3 é apresentada a formulação do sistema de controle adaptativo via RNA com aplicação do método de sintonia *online* do controlador PID. Aborda-se o

mecanismo de controle adaptativo e sua relação de otimalidade no algoritmo de controle proposto. Como também discute-se as situações de variações paramétricas do sistema que mudam imprevisivelmente ao longo tempo. Neste capítulo, tem-se a estruturação do mecanismo de controle adaptativo direto e indireto.

O método e algoritmo para sintonia *online* do controlador PID RNA-Preditivo é apresentado no Capítulo 4. No início apresenta-se as arquiteturas de predição tradicional e de predição via RNA-RBF. Aborda-se o método de sintonia do controlador PID via rede neural artificial. Para finalizar o capítulo tem-se a estrutura de sintonia dos controladores, com a apresentação do mecanismo de atualização dos pesos da RNA.

No Capítulo 5 mostra-se o sistema de rastreamento solar desenvolvido na dissertação (Controlador PID-Adaptativo via rede neural RBF). Apresenta-se os elementos constituintes da estrutura física de maneira detalhada, descrevendo-se a modelagem do sistema de rastreamento e o mecanismo de sintonia do sistema de controle de posição do PID-Adaptativo via RNA-RBF. O capítulo é finalizado com os experimentos computacionais.

Finalmente, no Capítulo 6 é apresentado a conclusão e os trabalhos futuros. No que concerne aos conceitos básicos de controle e RNA.

Os Apêndices A e B apresentam os conteúdos que são utilizados para uma melhor compreensão do desenvolvimento da proposta do projeto *online*. No Apêndice A, apresenta-se os principais conceitos de modelagem de sistemas dinâmicos, de controle em malha fechada (*feedback*) e malha aberta (*feedforward*). No Apêndice B descreve-se os conceitos neurofisiologia, destacando-se a junção sináptica, unidade neural e funções de ativação. Dando sequência, tem-se a topologia das redes neurais em relação à representação do conhecimento, abordagem do perceptron de múltiplas camadas (*multilayer perceptron - MLP*) com o algoritmo de aprendizado *Backpropagation*.

2 Problema da Sintonia e Estado da Arte

O problema da sintonia de controladores associado com o projeto online são apresentados neste capítulo. Especificamente, discute-se estado da arte, mostrando as evoluções dos controladores adaptativos via redes neurais artificiais e uma abordagem com sistemas de controle fundamentado em MPC. No final do capítulo é dada uma visão geral da solução proposta e comentários finais.

Tópicos concernentes à definição do problema da sintonia e estado da arte, como também, a metodologia aplicada em controle adaptativo e controladores PID são apresentados e comentados neste capítulo. O problema da sintonia do controlador PID, métodos de discretização e modificações em sua estrutura são amplamente apresentados no contexto de projeto online. No estado da arte aborda-se a evolução do desenvolvimento e discussões à respeito de controladores PID, sistemas adaptativos e controle preditivo via RNAs. Aborda-se também, a associação da teoria de ajustes dos parâmetros de sistemas de controle para viabilizar o projeto da sintonia online do controlador de alto desempenho, conforme discutido no Capítulo 1 .

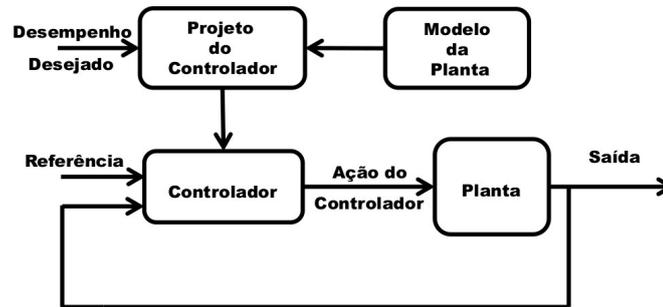
2.1 O Problema da Sintonia de Controladores PID

O controlador PID é usado por várias razões, dentre as principais são rejeitar as incertezas dos modelos de processo, resistir os efeitos das perturbações, melhorar o desempenho da planta e controlar as variáveis do sistema. Este controlador é amplamente utilizado em sistemas de controle industriais.

Em relação à sintonia do controlador PID, sua estrutura não depende, em geral, dos valores particulares dos parâmetros do modelo da planta. Por este motivo, tem-se a necessidade de uma esquematização para um projeto de controle adequado que leve em consideração o ajuste *online* dos seus parâmetros. A associação do sistema de controle como um esquema de projeto está representado na Figura 2 que pode ser desenvolvido nas formas *online* ou *offline*.

Ainda, a Figura 2 está representando o funcionamento de um sistema de controle, considerando uma visão geral de concepção da sintonia para um projeto de controle. Para o projeto e ajuste dos parâmetros ou ganhos de um *bom controlador*, é necessário conhecimentos básicos que são abordados ao longo desse capítulo.

Figura 2 – Esquema para projeto de controle.



Fonte: Elaborado pelo autor.

2.1.1 Métodos de sintonia do controlador PID

A seleção dos parâmetros do controlador PID, isto é, a sintonia do controlador deve, ser realizada de acordo com as especificações de projeto para um processo em questão. Geralmente, as especificações estão relacionadas com o ponto de ajuste, ou com a tarefa de rejeição de perturbações. Contudo em alguns casos, estas duas situações são de importância primordial. O esforço de controle, geralmente, é à preocupação primordial, uma vez que está relacionado com o custo final do processo e com a vida útil do atuador. Deve-se, portanto, ser mantido em um nível mínimo.

A fim de assistir o operador na sintonia do controlador PID, corretamente e com pequeno esforço, iniciou-se esse processo com as conhecidas fórmulas de Ziegler e Nichols (1942) e, posteriormente, um grande número de regras de sintonia foram criadas nas últimas décadas (ÅSTRÖM; ALBERTOS; QUEVEDO, 2001), (O'DWYER, 2009). Elas abordam os diferentes requisitos de controle possíveis e são geralmente baseadas em modelos simples da planta que derivam de fórmulas empírica ou analítica. O operador deve obter um modelo adequado para aplicar a regra de sintonização mais conveniente, relativa aos requisitos de controle especificados.

A concepção do procedimento de sintonização automática envolve muitas questões críticas, tais como a escolha do procedimento de identificação, normalmente baseado em resposta ao degrau ou em experiência de realimentação de relé (YU, 2006). Uma excelente apresentação deste tópico pode ser encontrada em (GRIMHOLT; SKOGESTAD, 2016).

2.1.2 Modelos para Controle Digital

Devido à natureza binária dos computadores digitais para comunicação processo-máquina, modelos algébricos contínuos de controladores são discretizados para o controle digital. Nesta secção apresenta-se o modelo controlador PID discretizado, maiores detalhes da formulação matemática são apresentados no Apêndice A.

2.1.2.1 Modelo Matemáticos de Sistemas em tempo discreto

As medições são amostradas e quantizadas no conversor analógico-digital. Para o processamento digital de medições e assim também para a identificação com computadores digitais. Aproximar os pulsos do sinal amostrado $x_s(t)$ que têm a largura h por um impulso δ de área equivalente é tratamento válido para grandes tempos de amostragem. A referida aproximação é dada por

$$x_s(t) \approx x\delta(t) = \frac{h}{1sec} \sum_{k=0}^{\infty} x(kT_0)\delta(t - kT_0). \quad (2.1)$$

Considerando h unitário, tem-se que

$$x^*(t) = \sum_{k=0}^{\infty} x(kT_0)\delta(t - kT_0). \quad (2.2)$$

Aplicando a transformada de Laplace na relação de $x^*(t)$, tem-se que

$$x^*(s) = \mathcal{L}\{x^*(t)\} = \sum_{k=0}^{\infty} x(kT_0)e^{-kT_0s} \quad (2.3)$$

A transformada de Laplace $x^*(s)$ tem um comportamento periódico, conforme apresentado na expressão dada por

$$x^*(s) = x^*(s + i\nu\omega_0), \quad \nu = 0, 1, 2, \dots \quad (2.4)$$

Com frequência de amostragem $\omega_0 = \frac{2\pi}{T_0}$. A transformada z é dada por

$$x(z) = \sum_{k=0}^{\infty} x(kT_0)e^{-z}. \quad (2.5)$$

Com T_0s limitado, $x(z)$ converge para $|z| > 1$, que pode ser alcançado para a maioria dos sinais, considerando uma escolha apropriada de δ . De forma semelhante, a transformada de Laplace, assume-se que $x(kT_0) = 0$ para $k < 0$ e $\delta > 0$. A sequência $x(z)$ é, em geral, uma série de comprimento infinito. No entanto, para muitos sinais de teste, pode-se fornecer expressões de forma fechada (POULARIKAS, 2010), (GRAF, 2012).

Um sinal de teste, frequentemente utilizado, é a resposta ao impulso que pode ser em tempo discreto ou em frequência. A resposta ao impulso $g(t)$ em tempo discreto corresponde uma soma de convolução obtida pela excitação com um δ -impulso, é usado para calcular a saída do sistema devido a uma entrada $u(kT_0)$. Se a saída é lida de forma síncrona à entrada, então a convolução é dada por

$$y(kT_0) = \sum_{\nu=0}^{\infty} u((k - \nu)T_0)g((k - \nu)T_0). \quad (2.6)$$

Levando em consideração a periodicidade, que é dada por

$$G^*(i\omega) = \lim_{s \rightarrow i\omega} G^*(s), \quad \omega \leq \frac{\pi}{T_0}, \quad (2.7)$$

o sinal contínuo lido na frequência angular $\omega_0 = 2\pi/T_0$, para sinais harmônicos com $\omega < \omega_s$ com $\omega_s = \frac{\omega_0}{2} = \frac{\pi}{T_0}$.

Para $\omega > \omega_s$ obtém-se sinais de saída espectrais com uma frequência mais baixa após a amostragem, tem que

$$G(z) = \mathcal{Y}\left\{\left[\mathcal{L}^{-1}\{G(s)\}\right]_{t=kT_0}\right\} = \mathcal{Z}\{G(s)\} \quad (2.8)$$

a função de transferência $G(z)$ é obtida por um segurador de ordem zero, a função de transferência resultante é dada por

$$HG(z) = \{1 - z^{-1}\} Z\left\{\frac{G(s)}{s}\right\} = \frac{z-1}{z} \mathcal{Z}\left\{\frac{G(s)}{s}\right\}, \quad (2.9)$$

com manipulações algébricas das equações Eq.(2.8) e Eq.(2.9) tem-se a função de transferência dada por

$$G(z^{-1}) = \frac{y(z)}{u(z)} = \frac{b_0 + b_1z^{-1} + \dots + b_mz^{-m}}{1 + a_1z^{-1} + \dots + a_nz^{-n}} = \frac{B(z^{-1})}{A(z^{-1})}. \quad (2.10)$$

Para processo com tempo morto, $T_D = dT_0$ com $1, 2, \dots$, tem-se a função de transferência dada por

$$G(z^{-1}) = \frac{B(z^{-1})}{A(z^{-1})} z^{-d} \quad (2.11)$$

A Eq. (2.10) na forma de equação à diferença é dada por

$$y(z)(1 + a_1^{-1} + \dots + a_n z^{-n}) = u(z)(b_0 + b_1 z^{-1} + \dots + b_m z^{-m}), \quad (2.12)$$

reescrita no domínio do tempo discreto é dada por

$$y(k) + a_1 y(k-1) + \dots + a_n y(k-n) = b_0 u(k) + b_1 u(k-1) + \dots + b_m u(k-m). \quad (2.13)$$

2.1.2.2 Controlador PID Discreto

As leis de controle previamente consideradas, até o momento devem-se ser discretizadas para implementação do controlador PID digital. Isto pode ser feito com qualquer um dos métodos de discretização disponíveis (ÅSTRÖM; WITTENMARK, 2013b), tais como: diferenças finitas, regra trapezoidal e Tustin. Considera-se a expressão em tempo contínuo de um controlador PID na forma ideal, que é dada por

$$u(t) = K \left[e(t) + \frac{1}{T_I} \int_0^t e(\tau) d\tau + T_D \frac{de(t)}{dt} \right], \quad (2.14)$$

sendo os parâmetros K, T_I e T_D , o ganho, tempo integrativo e tempo derivativo, respectivamente.

Para um período de amostragem T_0 a Eq.(2.14) é algebricamente transformada em uma equação à diferença. Por discretização, a derivada é substituída por uma diferença de primeira ordem dos erros, e a integral por uma soma, também dos erros. A integração contínua pode ser aproximada por integração retangular ou trapezoidal. A expressão na forma discreta é dada por

$$u(k) = K \left[e(k) + \frac{T_0}{T_I} \sum_{i=0}^k e(i-1) + \frac{T_D}{T_0} (e(k) - e(k-1)) \right]. \quad (2.15)$$

A Eq. (2.15) representa uma equação não recursiva do PID. Para a informação de uma soma, todos os erros passados, $e(k)$, devem ser armazenados. No entanto, algoritmos recursivos são mais adequados para programação em computadores. Esses algoritmos são caracterizados pelo cálculo da variável atual, $u(k)$, baseado na variável manipulada anterior, $u(k-1)$, e em termos de correção. Para derivar o algoritmo recursivo, é necessário atrasar a Eq. (2.15) em $k-1$ para determinar a variação $\Delta(k)$. A nova equação é dada por

$$u(k) - u(k-1) = q_0 e(k) + q_1 e(k-1) + q_2 e(k-2) \quad (2.16)$$

sendo

$$u(k-1) = K \left[e(k-1) + \frac{T_0}{T_I} \sum_{i=0}^{k-1} e(i-1) + \frac{T_D}{T_0} (e(k-1) - e(k-2)) \right], \quad (2.17)$$

com os seguintes parâmetros,

$$q_0 = K \left(1 + \frac{T_D}{T_0} \right) \quad (2.18)$$

$$q_1 = K \left(1 + 2 \frac{T_D}{T_0} - \frac{T_0}{T_I} \right) \quad (2.19)$$

$$q_2 = K \left(\frac{T_D}{T_0} \right) \quad (2.20)$$

em que a mudança na variável manipulada atual é dada por

$$\Delta u = u(k) - u(k-1). \quad (2.21)$$

A Eq.(2.17) é modificada de Eq. (2.15). No tempo discreto $k-1$ em que $e(i)$ substitui $e(i-1)$ no processamento da soma. Então, os coeficientes q_0 e q_1 mudam de tal forma que não existe uma combinação com os coeficientes definidos para tempos de amostragem maiores. Pois uma transformada z direta da equação do controlador contínuo não é possível devido ao termo derivativo.

Para uma discretização pelo método trapezoidal da Eq. (2.14), é dada por

$$u(k) = K \left[e(k) + \frac{T_0}{T_I} \left(\frac{e(o) + e(k)}{2} + \sum_{i=1}^{k-1} e(i) \right) + \frac{T_D}{T_0} (e(k) - e(k-1)) \right]. \quad (2.22)$$

Após a subtração da equação correspondente para $u(k-1)$, outra relação recursiva é dada por

$$u(k) = u(k-1) + q_0 e(k) + q_1 e(k-1) + q_2 e(k-2) \quad (2.23)$$

os parâmetros do PID com discretização pela regra trapezoidal são definidos por

$$q'_0 = K \left(1 + \frac{T_0}{2T_I} + \frac{T_D}{T_0} \right) \quad (2.24)$$

$$q'_1 = -K \left(1 + 2\frac{T_D}{T_0} - \frac{T_0}{2T_I} \right) \quad (2.25)$$

$$q'_2 = K \left(\frac{T_D}{T_0} \right). \quad (2.26)$$

2.1.3 Controlador PID discretizado com modificação

A equação diferencial, discretizada, do controlador PID em tempo contínuo como está representado Equações (2.14) e (2.17), e outras modificações foram fontes de trabalhos em pesquisas (ÅSTRÖM; WITTENMARK, 2013a) (LANDAU; ZITO, 2005). Para reduzir grandes variações da variável manipulada após mudanças rápidas da variável de referência, $w(k)$, esta não é incluída no termo derivativo, em vez do algoritmo comum, do controlador PID (ISERMANN, 2013). Substituindo a Eq. (2.22) para k e $k-1$ na Eq.(2.21), tem-se que

$$\Delta u = K \left[e(k) - e(k-1) + \frac{T_0}{T_I} e(k-1) + \frac{T_D}{T_0} (e(k) - 2e(k-1) + e(k-2)) \right]. \quad (2.27)$$

Com as modificações algébricas na Eq.(2.16), tem-se equivalência dada por

$$\Delta u = K \left[e(k) - e(k-1) + \frac{T_0}{T_I} e(k-1) + \frac{T_D}{T_0} (-y(k) + 2y(k-1) - y(k-2)) \right] \quad (2.28)$$

Com $e(k) = w(k) - y(k)$. As alterações de amplitude da variável manipulada são reduzidas, se a referência estiver presente apenas no termo de integração. A nova equação é dada por

$$\Delta u = K \left[-y(k) + \frac{T_0}{T_I} e(k-1) + \frac{T_D}{T_0} (-y(k) + 2y(k-1) - y(k-2)) \right] \quad (2.29)$$

Com este algoritmo é mais apropriado em função de $e(k)$ do que $e(k-1)$. Essas modificações, no algoritmo, são menos sensíveis aos sinais de frequência elevada de $w(k)$ do que aos de $y(k)$. Por conseguinte, para o mesmo tipo de perturbação, por exemplo, a entrada de um processo é a variável manipulada, as diferenças entre os parâmetros do controlador obtidos pela otimização de parâmetros tornam-se menores.

Com este algoritmo é então mais apropriado usar $e(k)$ em vez de $e(k-1)$. Esses algoritmos modificados são menos sensíveis aos sinais de frequência elevada de $w(k)$ do que aos de $y(k)$. Por conseguinte, para o mesmo tipo de perturbação. Por exemplo, a entrada

de um processo e a variável manipulada, as diferenças entre os parâmetros do controlador obtidos pela otimização de parâmetros tornam-se menores.

Outras modificações são obtidas por diferentes realizações do termo derivativo, por exemplo, a variação do erro dada por

$$T_D = \frac{\Delta e(k)}{T_0} = \frac{T_D}{T_0} (e(k) - e(k-1)) \quad (2.30)$$

De maneira que tem-se na forma não recursiva a Eq.(2.14), ou na forma recursiva a Eq.(2.27) é dada por

$$\frac{T_D}{T_0} (e(k) - 2e(k-1) + e(k-2)). \quad (2.31)$$

O termo derivado, no entanto, pode ser necessário para melhorar o desempenho de controle para o ruído de média frequência, uma vez que, se não for grande, um polo do processo pode ser cancelado de fora aproximada a região de estabilidade pode ser aumentada e maiores ganhos podem ser usados.

2.2 Estado da Arte

Para fins de salientar a viabilidade e importância do tema da dissertação, o estado da arte é apresentado no contexto das abordagens do controlador PID, com mecanismo de adaptação e predição via rede neural. Desta forma, os principais tópicos que alicerçam o desenvolvimento dos modelos e algoritmos para sintonia *online* de controladores PID adaptativo-ótimo via redes neuronais artificiais são apresentados sobre um ponto de vista geral, histórico e contemplando suas contribuições no contexto do trabalho realizado. Desta maneira, tem-se um mecanismo de sintonia do controlador PID composto por RNA, com o objetivo de ajustar seus parâmetros.

2.2.1 Controlador PID

O controlador PID é considerado um componente chave no controle de processos industriais. Durante o último século muitas estruturas diferentes de combinações têm sido propostas para superar as limitações deste controlador. Devido à sua simplicidade e utilização tem-se mostrado uma poderosa solução para o controle de grande número de processos industriais (ÅSTRÖM; ALBERTOS; QUEVEDO, 2001). Este modelo de controle é bastante popular e utilizado no campo industrial devido à facilidade de concepção e implementação à baixo custo (YAGHOUBI; MOJALLALI, 2016). Porém, a sintonia ideal para o ganho do controlador, ainda, é desafiadora e motivante. Em vários livros e artigos, tais como algoritmos evolutivos PSO (SOLIHIN; TACK; KEAN, 2011), DE (BINGUL, 2004), GA (HERREROS; BAEYENS; PERÁN, 2002), dentre outros têm sido usados para sintonia do controlador PID.

Os controladores PID são o algoritmo de controle mais comum. Métodos simples de sintonia para estes controladores foram desenvolvidos por Ziegler e Nichols (1942), em um artigo seminal na década de quarenta. Entretanto, existem desvantagens que são costumeiramente modificadas, em alguma forma, para se adequar a uma solução desejada. Os métodos propostos por Ziegler e Nichols (1942) para sintonia de controladores PID e PI possuem limitações que requerem atenção (HÄGGLUND; ÅSTRÖM, 2004) (ÅSTRÖM; HÄGGLUND, 2006) (ÅSTRÖM; WITTENMARK, 2013a), no entanto, mantiveram-se muito populares devido à sua simplicidade. Recentemente, existem alguns métodos avançados em Zhang, Shi e Mehr (2011) e Zhang, Shi e Liu (2013) para sintonia dos parâmetros deste controlador.

Os controladores PID convencionais são os mais preferidos em aplicações industriais, devido à sua necessidade de uma simples estrutura e *hardware*. Além disso, o controlador PID é o componente básico na hierarquia multi-nível moderno de controle, que funciona como dispositivos de regulamentação segundo uma abordagem de Chan, Chen e Chen (2016). Os processos químicos altamente não-lineares e variantes no tempo podem, no entanto, representar um grande desafio para o projeto do controlador PID. Por este motivo, as aplicações de RNAs e outras combinações tem sido crescente na sintonia deste controlador, pois o mesmo tem características lineares, como será visto na seção da adaptabilidade, juntamente com combinações em sistemas de inteligência artificial.

Uma outra combinação do controlador PID é com uma estrutura preditiva, pois tem a vantagem significativa, em relação a capacidade de prever o erro usando o modelo do processo, de perturbação estocástica e, *a priori*, o conhecimento futuro do processo. De maneira que a sintonia dos parâmetros do controlador será de minimizar os erros futuros previstos, antes de qualquer perturbação à saída do processo.

2.2.2 Controle Adaptativo

Segundo uma narrativa de Tsytkin e Nikolic (1971), pesquisadores citados em artigos e livros da área de controle adaptativo como em Landau et al. (2011) e Åström e Wittenmark (2013a) com sua contribuição fundamental e reconhecida em algoritmos adaptativos. Tsytkin e Nikolic (1971) diferenciam três períodos característicos no desenvolvimento da teoria de controle automático, sendo denominados de períodos determinístico, estocástico e adaptativo.

Os métodos e resultados dos períodos determinísticos e estocásticos, foram diretamente aplicados aos sistemas automáticos com informações suficientes, onde a modelagem matemática da planta e as suas ações externas ou características estatísticas eram conhecidas. Nesse período existia um confronto com uma maior ou menor incerteza inicial, mas com tudo isso não se tinha um controle impossível, em princípio. Isto é evidenciado pelo aparecimento de um novo período, o da adaptação.

Conforme Tsyppkin e Nikolic (1971) a possibilidade de controlar o sistema sob uma informação *a priori* incompleta e até mesmo com pouca informação, é baseado na aplicação da adaptação e aprendizagem em sistemas de controle automático que reduz a incerteza inicial usando informações obtidas durante o processo de controle. Desta forma, o controle adaptativo abrange um conjunto de técnicas que proporcionam uma abordagem sistemática para a sintonia automática de controladores em tempo real, a fim de conseguir ou manter um nível desejado de desempenho em sistema de controle, quando a dinâmica da planta são desconhecidas e/ou mudam no tempo Landau et al. (2011). Existem casos que o efeito da adaptação desaparece na medida que o tempo aumenta. Mudanças nas condições de operação pode exigir a reinicialização do processo de adaptação.

As abordagens em sistemas de controle adaptativo publicadas em Camacho e Bordons (2012), Camacho e Bordons (2004), Findeisen e Allgöwer (2002) e as referências Garcia, Prett e Morari (1989) Qin e Badgwell (1997) contribuem com o arcabouço de aplicações. As abordagens de controle ótimo auxiliam com o grau de liberdade do projetista em atender, i.e., inserir de forma sistemática as limitações de consumo energético e restrições que são oriundas da regulamentação ambiental.

Atualmente são utilizados controladores tradicionais, em grande maioria, projetados com base em modelos precisos como o controle de realimentação de estado, o controle de alocação de polos e assim por diante (CHEN et al., 2016). Porém, as variações dos parâmetros, incertezas e perturbações sempre estão presentes na planta real, para o qual o controlador projetado não atinge o desempenho desejável em todo instante ou não pode garantir a instabilidade do sistema controlado.

2.2.3 Controle preditivo via rede neural

Apesar da vasta literatura sobre sintonia do controlador PID, como já mencionado de forma introdutória, uma porcentagem significativa destes controladores, em modo automático, são mal sintonizados, conforme Garpinger, Hägglund e Åström (2014) e Seborg et al. (2010). Por conseguinte, o desempenho ótimo nem sempre é alcançado. A necessidade de produtos de alta qualidade, redução do consumo de energia (combustível e eletricidade), o aumento da concorrência de mercado cria uma necessidade indiscutível, de melhorar o desempenho do controle no processo.

O controle preditivo baseado em modelo ganhou atenção significativa no meio industrial e científico, principalmente no milênio atual. Este crescimento pode ser visto em banco de dados de jornais e revistas acadêmicos.

A capacidade do controle preditivo baseado em modelo (MPC - *Model Predictive Control*) de lidar com sistemas de múltiplas entradas e saídas (MIMO), restrições do processo e incluir, naturalmente, critérios objetivos para projeto de controladores foi

desenvolvido pela Shell Oil no início dos anos 1970, com aplicação para controle multivariáveis em processo de destilação. Mais tarde, Cutler e Ramaker (1980) apresentou uma descrição do MPC sem restrições na forma de controle, representada por uma matriz dinâmica. Desde então, tem havido numerosos estudos sobre o algoritmo MPC e suas aplicações. Uma revisão, generalizada, no campo de projetos que buscam o MPC como base, desenvolvimento e suas aplicações foram apresentados por Christofides et al. (2013a), Lee et al. (2011) e (QIN; BADGWELL, 2003). Estes trabalhos contribuíram de forma significativa para o estudo e aplicações no meio industrial e acadêmico.

O MPC é um sistema de controle considerado, como o único, que apresenta um esquema avançado e teve um impacto notável na indústria, segundo Maciejowski (2002). A aplicação da metodologia do MPC, de maneira tradicional, é implementado aos processos em grande escala e proporcionam pontos de sintonia para controlador PID no nível de regulamentação. No entanto, a evolução da computação e otimização viu a implementação de controladores baseados em MPC na camada regulamentar, mesmo para sistemas com constantes de tempo pequenas, por exemplo em Wills e Heath (2005), Valencia-Palomo e Rossiter (2011).

Um dos principais obstáculos na aplicação do sistema de controle baseado em MPC não linear se torna o problema de otimização formulado em cada instante de tempo discreto e deve ser resolvido em tempo real (LEE, 2011), no entanto, o tempo disponível entre dois instantes de tempo pode não ser suficiente para satisfazer os requisitos do MPC (GRAICHEN; KUGI, 2010). Para superar esse problema e estender a aplicabilidade do MPC, com sistemas de dinâmica rápida, o conceito de MPC explícito foi desenvolvido.

Como resultado, ao contrário do controlador PID, os algoritmos do sistema de controle baseado em MPC pode ser aplicado com sucesso aos processos que são difíceis de controlar (isto é, os processos com um atraso de tempo significativo) (ŁAWRYŃCZUK, 2014). É claro que, o modelo utilizado para a previsão deve corresponder com as propriedades do processo, o horizonte previsto tem de ser suficientemente longo. A ideia deste sistema de controle é muito geral, de maneira que não se imponha qualquer restrição sobre o tipo de estrutura do modelo. É por isso que o algoritmo baseado em MPC pode ser desenvolvido não só para processos com uma entrada e uma saída (SISO), mas também para processos multivariados (MIMO). Em tal caso, graças à utilização do modelo de previsão e de otimização dos futuros erros de controle, todos as junções existentes são automaticamente levados em conta.

A inteligência computacional tem sido amplamente utilizado durante as duas últimas décadas para a concepção de novos sistemas de controle automático, especialmente nos casos em que métodos convencionais não conseguem desenvolver modelos dinâmicos apropriados do processo e/ou calcular a lei de controle (MOHAMMADIAN, 2002).

A RNA tem-se tornado uma poderosa ferramenta de aprendizagem utilizada para

a execução de tarefas complexas, tais como a obtenção de aproximações não-lineares e controle de sistemas dinâmicos, uma prova dessa importância é vista em artigos da década de 90 à recentes como Narendra e Parthasarathy (1990), Sastry, Santharam e Unnikrishnan (1994), Arahal, Berenguel e Camacho (1998), Henriques et al. (2010) e Arinton, Caraman e Korbicz (2012). Estes trabalhos tem como principais vantagens a alta capacidade de aprendizagem baseada na otimização, com funções de erro apropriadas e alto desempenho na aproximação de funções não-lineares.

Devemos mencionar que, para a construção de neuro-controladores existem mais possibilidades ao lado do erro quadrático médio entre a saída do modelo de referência e a saída real da planta (ROVITHAKIS; CHRISTODOULOU, 2012).

2.3 Solução Proposta

Dentro da solução geral do sistema de controle proposto, tem-se o desenvolvimento de dois mecanismos agregados no sistema. O primeiro é responsável pela predição da saída da planta e o segundo é encarregado pela sintonia do controlador PID. Ambos possuem sintonia *online* dos seus parâmetros. De maneira mais detalhada, a solução da sintonia *online* do controlador PID é usada, uma abordagem adaptativa com critério de otimalidade em relação ao ajuste dos parâmetros do controlador por meio de uma RNA - RBF. Para uma interpretação em relação ao sistema de controle baseado em MPC faz-se uso de um mecanismo de predição via RNA - RBF. Este sistema de controle desenvolvido será esquematizado e aplicado em um controle de posicionamento de um painel fotovoltaico no Capítulo 5.

2.4 Comentários

Os conceitos básicos de PID, a sua importância e desenvolvimentos tecnológicos recentes constituem os alicerces que sustentam a solução proposta. Por este motivo, tem-se o desenvolvimento de métodos e algoritmos para sintonia *online* dos ganhos de controlador baseado em RNA com uma estrutura de controle adaptativo do tipo MPC.

3 Controle Adaptativo e RNA

Os métodos que sustentam o projeto *online* do sistema de controle adaptativo e ótimo são apresentados neste capítulo. Aborda-se a otimalidade, no contexto da formulação dos índices de desempenho determinístico que estão associados com a estrutura de controle adaptativo direto e indireto. Desta forma, tem-se uma visão geral do sistema de controle baseado em MPC que tem por base as abordagens de aprendizado por RNA-RBF.

No contexto de métodos e práticas de controle adaptativo baseados em redes neurais artificiais são apresentados os principais métodos das referidas abordagens que compõem o núcleo do sistema *online*, para o projeto de controladores de alto desempenho. Inicialmente, apresenta-se o controle adaptativo, envolvendo tópicos em otimalidade e seus critérios, estruturas do controle adaptativo, nas formas direta e indireta. Dando sequência, apresenta-se a filosofia do sistema de controle preditivo, apresentando a formulação do controle preditivo baseado em modelo (MPC) e sua função objetivo. Os conceitos necessários para uma melhor compreensão da associação das RNAs com controle são apresentadas no Apêndice B, tópicos tais como: elementos do neurônio elementar e redes de Perceptron Multi-Camadas (MLP - *MultiLayer Perceptron*). Aborda-se as RNAs de função de base radial e, por fim, faz-se os comentários a respeito da associação RNA - RBF e controle MPC para constituírem o núcleo das estratégias de estimação de parâmetros na estrutura de controle de alto desempenho desenvolvida.

3.1 Controle Adaptativo

Uma pesquisa na literatura vigente sobre o controle adaptativo, como citada em Rovithakis e Christodoulou (2012), Åström e Wittenmark (2013a), Landau et al. (2017), pode-se observar a existência de várias definições sobre o que se deve considerar na aprendizagem (formação), auto-aprendizagem e adaptação. Infelizmente, mesmo no caso dos sistemas automáticos, essas definições são contraditórias. Não se irá entrar na análise comparativa e crítica dessas definições. Em vez disso, trata-se de conceitos que são convenientes para o propósito do trabalho.

A auto-aprendizagem é, definida como, aprender sem correções externas, isto é, sem punições ou recompensas. Não há informações adicionais sobre a correção ou incorreção da reação do sistema (ÅSTRÖM; WITTENMARK, 2013a). A adaptação é considerada um processo de modificação dos parâmetros ou da estrutura do sistema e das ações de controle. As informações atuais são usadas para obter um estado definido, geralmente ótimo, do sistema quando as condições de operação são incertas e variam no tempo. Na linguagem cotidiana, "adaptar-se", significa mudar um comportamento para conformar as

circunstâncias. Intuitivamente, um controlador adaptativo é, portanto, um controlador que pode modificar seu comportamento em resposta às mudanças na dinâmica do processo e a perturbações.

3.1.1 Otimalidade

Pode-se dizer, sem exagero, que o problema da otimalidade é um grande contratempo central da ciência, da engenharia e até da vida cotidiana. Quaisquer conclusões, ações ou dispositivos produzidos aceitos podem ser considerados ótimos de um certo ponto de vista, uma vez que foram dados uma preferência sobre outras possíveis conclusões, ações ou dispositivos, isto é, eles foram considerados como os melhores.

Na tentativa de alcançar uma meta, surgem três problemas de imediato. O primeiro é selecionar e formular o objetivo. Algo que é melhor em certa circunstância pode estar longe de ser o melhor em outras. A seleção e formulação de uma meta dependem de muitos fatores, e são frequentemente realizados com grandes dificuldades. Muitas vezes sabe-se o que se quer, mas, infelizmente, não se pode formular precisamente o desejado.

Uma vez que o objetivo é escolhido, o segundo problema é combiná-lo com os recursos disponíveis, ou seja, levar em consideração as restrições. Mesmo um objetivo claramente formulado não é garantia de sua própria realização.

Finalmente, depois de selecionar o objetivo e considerar as restrições, tem-se que resolver o terceiro problema, para realizar o objetivo sob as restrições existentes, pelo qual o valor real de diferentes métodos matemáticos de otimização e seu poder ou fraquezas são realmente esclarecidas.

3.1.2 Critérios de Otimalidade

Um problema de otimização pode ser reduzido a outro, em um grande número de situações deve-se encontrar a melhor política, em certo sentido. Cada uma dessas políticas ótimo é caracterizada por um conjunto de números, ou funções. A qualidade de uma política adotada é medida por um índice, característica quantitativa, que define a proximidade do objetivo escolhida.

A melhor política corresponde ao extremo de um Índice de Desempenho (ID), isto é, ao mínimo ou ao máximo, dependendo de um problema particular. Os índices de desempenho são geralmente algumas funções que podem ser consideradas como expressões em que as curvas ou os vetores caracterizam as políticas e desempenham o papel de variáveis independentes.

Considera-se apenas funções vetoriais, aquelas que dependem dos vetores, formadas por várias variáveis. Tais funcionais podem ser obtidas usando métodos diretos de cálculo variacional. Em geral, o índice de desempenho pode ser dado na forma de esperança

expressa por

$$\mathbf{J}(\mathbf{c}) = \int_{\mathbf{x}} Q(\mathbf{x}, \mathbf{c})p(\mathbf{x})d\mathbf{x}, \quad (3.1)$$

ou equivalente,

$$\mathbf{J}(\mathbf{c}) = \mathbf{M}_{\mathbf{x}}\{Q(\mathbf{x}, \mathbf{c})\}, \quad (3.2)$$

sendo $Q(\mathbf{x}, \mathbf{c})$ o funcional do vetor $\mathbf{c} = (c_1, \dots, c_N)$ que depende do vetor de sequências ou processos aleatórios $\mathbf{x} = (x_1, \dots, x_N)$ com a Função Densidade de Probabilidade (FDP), $p(\mathbf{x})$; X é o espaço dos vetores \mathbf{x} . Para melhor entendimento, nesta seção, representa-se todos os vetores como matriz colunas.

Na Eq.(3.2) não é enfatizada uma possível dependência dos funcionais, em vetores conhecidos, que serão encontrados nos estudos de problemas específicos. Uma série de índices de desempenhos que diferem apenas na sua forma, correspondem à Eq.(3.2). Um critério muito difundido na teoria da decisão estatística é o risco médio, critério bayesiano, que é definido por

$$R(d) = \int_{\Lambda} \sum_{\nu, \mu=1}^N P_{\nu} w_{\nu\mu} d_{\mu}(\mathbf{x}, \mathbf{c}) p_{\nu}(\mathbf{x}) d\mathbf{x}, \quad (3.3)$$

sendo P a probabilidade do elemento observado, x pertencer ao subconjunto Λ_{ν} de Λ ; $p_{\nu}(\mathbf{x})$ é a FDP condicional, definida sobre o subconjunto Λ_{ν} ; $d_{\mu}(\mathbf{x}, \mathbf{c})$ é a regra de decisão que depende de um vetor desconhecido dos parâmetros \mathbf{c} é dado por

$$d_{\mu}(\mathbf{x}, \mathbf{c}) = \begin{cases} 1, & \text{se } \mathbf{x} \notin \Lambda_{\mu} \\ 0, & \text{se } \mathbf{x} \in \Lambda_{\mu} \end{cases} \quad (3.4)$$

e $w_{\nu\mu}$ ($\nu, \mu = 1, \dots, N$) é o elemento da matriz de custo W que define o custo de decisões incorretas. Escreve-se a fórmula para $R(d)$ expressa por

$$R = \sum_{\nu, \mu=1}^N w_{\nu\mu} \int_{\Lambda} P_{\nu} p_{\nu}(\mathbf{x}) d_{\mu}(\mathbf{x}, \mathbf{c}) d\mathbf{x} \quad (3.5)$$

Segue-se que R pode ser considerada como uma expectativa matemática condicional de uma variável aleatória $w_{\nu\mu}$ com uma distribuição de probabilidade representada por

$$\int_{\Lambda} P_{\nu} p_{\nu}(\mathbf{x}) d_{\mu}(\mathbf{x}, \mathbf{c}) d\mathbf{x},$$

usa-se o índice de desempenho que define a probabilidade de que uma certa variável esteja entre os limites $Q(\mathbf{x}, \mathbf{c}) \leq \varepsilon_2$, expressa por

$$J(\mathbf{c}) = P \{ \varepsilon_1 \leq Q(\mathbf{x}, \mathbf{c}) \leq \varepsilon_2 \}. \quad (3.6)$$

Agora, introduz-se a função característica dada por

$$\theta(\mathbf{x}, \mathbf{c}) = \begin{cases} 1, & \text{se } \varepsilon_1 \leq Q(\mathbf{x}, \mathbf{c}) \leq \varepsilon_2 \\ 0, & \text{caso contrário} \end{cases} \quad (3.7)$$

com manipulações algébricas e levando em consideração a Eq. (3.6), tem-se a forma dada por

$$J(\mathbf{c}) = M_X \{ \theta(\mathbf{x}, \mathbf{c}) \}, \quad (3.8)$$

observando que Eq.(3.8) corresponde a Eq.(3.2).

O objetivo é encontrar o mínimo, por exemplo, no caso de Eq.(3.3), ou o máximo, para a Eq.(3.6), de um funcional. Portanto, esses funcionais são chamados de critério de otimalidade.

Além dos critérios de otimalidade que são dados sob a forma de expectativa condicional, Eq.(3.2), com base na média do conjunto, os critérios de otimalidade com suporte de $Q(\mathbf{x}, \mathbf{c})$ em relação ao tempo, também podem ser usados, dependendo se x é uma sequência aleatória $\{\mathbf{x}[n]; n = 0, 1, 2, \dots\}$ ou um processo aleatório $\{\mathbf{x}(t); 0 \leq t < \infty\}$. Os critérios de otimalidade são dados por

$$J(\mathbf{c}) = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{n=0}^N Q(\mathbf{x}[n], \mathbf{c}) \quad (3.9)$$

ou equivalente,

$$J(\mathbf{c}) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T Q(\mathbf{x}(t), \mathbf{c}) dt. \quad (3.10)$$

Para as sequências do sistemas dinâmicos, os critérios de otimalidade da Eq.(3.9) e Eq.(3.10) que diferem do critério da Eq.(3.2) no procedimento de média, tempo ou média de conjunto, são equivalentes. Isso significa que as expressões desses funcionais sempre coincidirão, se pudermos obtê-los de forma explícita. Em qualquer outro caso, os critérios de otimalidade da Eq.(3.10) diferem da Eq.(3.2). No entanto, esse fato não impossibilita o uso do critério de otimalidade da Eq.(3.9) ou sua generalização, mesmo nos casos em que a cada passo, em cada instante de tempo, a forma da função Q é variável, isto é, quando o somatório da Eq.(3.9) representar $Q_n(\mathbf{x}[n], \mathbf{c})$ e a integração da Eq.(3.10) corresponder a $Q(\mathbf{x}(t), \mathbf{c}, t) dt$.

Os critérios de otimalidade têm, ou pelo menos devem ter, um certo significado físico ou geométrico definido. Nos sistemas de controle o critério de otimalidade representa uma medida de desvio do sistema desejado ou prescrito. A seleção de um critério específico de otimalidade está relacionado a uma tendência de encontrar a sintonia entre o desejo de descrever o problema apresentado com mais precisão, e a possibilidade de obter uma solução mais simples para o problema matemático correspondente.

Em processos determinísticos e estocásticos com informação, *a priori*, o critério de otimalidade, isto é, o funcional $J(\mathbf{c})$ é explicitamente conhecido, ao mesmo tempo com suas restrições. No início, supõe-se que as restrições do segundo tipo não exista, e que as do primeiro tipo estão incluídas no funcional. A dimensão inicial do vetor \mathbf{c} é reduzida.

O funcional $J(\mathbf{c})$ é diferenciável, seu extremo (máximo ou mínimo) é atingido somente para valores $\mathbf{c} = (c_1, \dots, c_N)$, os quais N derivadas parciais $\frac{\partial J(\mathbf{c})}{\partial c_\nu}$ ($\nu = 1, \dots, N$) são simultaneamente iguais a zero, ou, em outras palavras, para as quais o gradiente da função é expressa por

$$\nabla J(\mathbf{c}) = \left(\frac{\partial J(\mathbf{c})}{\partial c_1}, \dots, \frac{\partial J(\mathbf{c})}{\partial c_N} \right), \quad (3.11)$$

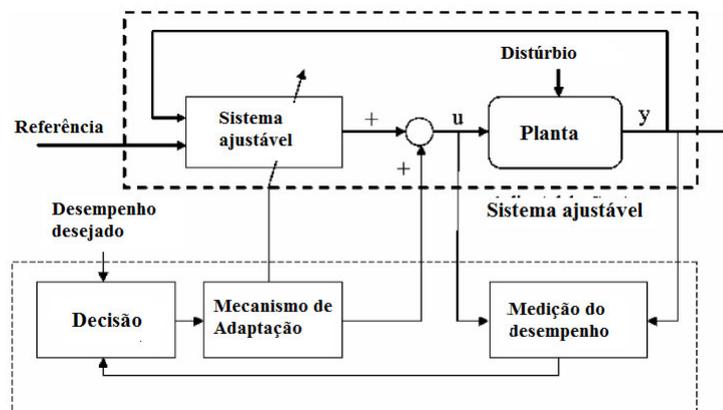
é igual a zero. Os vetores \mathbf{c} para os quais $\nabla J(\mathbf{c}) = 0$, são chamados de vetores estacionários ou singulares, mas todos eles não são ótimos, isto é, não correspondem ao extremo desejado do funcional. Portanto, $\nabla J(\mathbf{c}) = 0$ é apenas uma condição necessária.

3.1.3 Estrutura do Controle adaptativo

Para alcançar e manter um nível aceitável de desempenho do sistema de controle, quando ocorrem mudanças, grandes e desconhecidas, nos parâmetros do modelo, uma abordagem de controle adaptativo deve ser considerada. Nesses casos, a adaptação funcionará na maior parte do tempo e o termo *adaptação* não-desaparecendo, caracteriza completamente esse tipo de operação, conhecida também por adaptação contínua.

Associando com o diagrama da Figura 1, do Capítulo 2, que enfatiza os controladores adaptativos de alto desempenho com propriedade de otimalidade. No contexto de vários esquemas de controle adaptativo, a implementação dos três blocos fundamentais: medição do desempenho, comparar e decidir. De fato, pode não ser fácil decompor o esquema de controle adaptativo de acordo com o diagrama da Figura 3. Apesar disso, a característica básica que permite decidir sobre a adaptabilidade do sistema é a presença ou a ausência do controle em malha fechada de um determinado índice de desempenho.

Figura 3 – Configuração de um sistema de controle adaptativo.



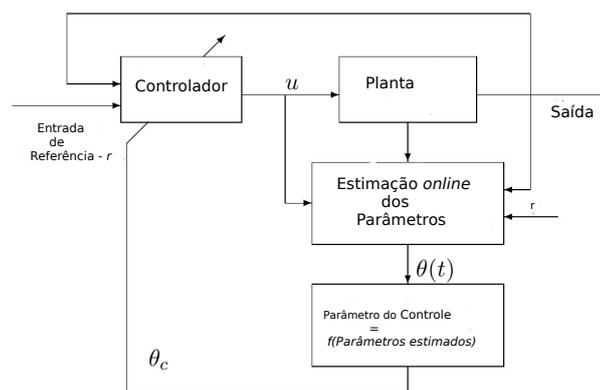
Fonte: (LANDAU et al., 2011)

O sistema de controle, especificamente, adaptativo utiliza informação obtida em tempo real para melhorar a sintonia do controlador, de modo a conseguir ou manter um nível de desempenho desejado. Existem muitos sistemas de controle que são projetados para alcançar um desempenho aceitável, na presença de variações dos parâmetros, mas eles não asseguram um controle em malha fechada do desempenho e, como tal, não são *adaptáveis* (LANDAU et al., 2011).

3.1.4 Controle Adaptativo Indireto

O esquema de controle indireto pode ser visto na Figura 4. Este esquema é visto como uma extensão para sistemas em tempo real, no procedimento de projeto do controlador, conforme exemplificado no apêndice A e representado na Figura 2.

Figura 4 – Esquema de controle adaptativo indireto

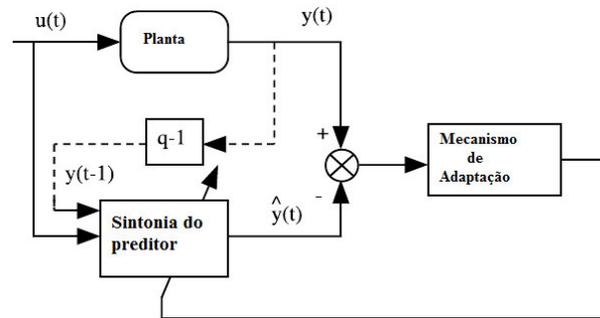


Fonte: (IOANNOU; FIDAN, 2006)

Um controlador adequado pode ser projetado de maneira *online*, se um modelo da planta for estimado em linha, a partir das medidas de entrada e saída disponíveis, conforme apresentado na Figura 5. O esquema é denominado indireto pela adaptação dos parâmetros do controlador, sendo feita em duas etapas: estimativa *online* dos parâmetros da planta e o cálculo *online* dos parâmetros do controlador com base no modelo de planta estimada.

O esquema faz uso das estimativas dos parâmetros do modelo da planta atual como se fosse igual à verdadeira para calcular os parâmetros do controlador, conhecido como princípio de *equivalência certeza ad-hoc*.

A ideia básica é construir um *preditor ajustável* para a saída da planta que pode ou não usá-la para comparar a saída prevista com a saída medida. De forma a gerar um erro entre a saída da planta e a saída prevista, denominado erro de predição ou erro do modelo da planta. Este erro é usado por um algoritmo de adaptação de parâmetros que em cada

Figura 5 – Esquema para a estimação de parâmetros *online*

Fonte: (LANDAU et al., 2011)

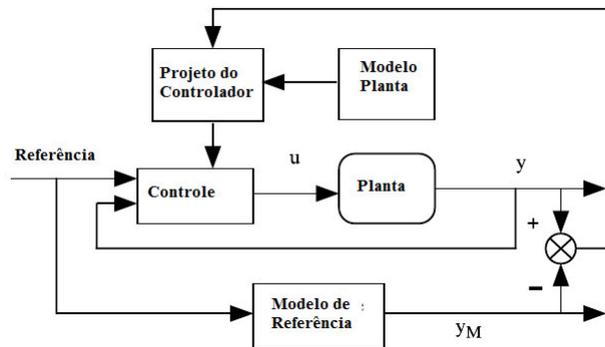
instante de amostragem irá ajustar os parâmetros do *preditor ajustável* para minimizar o erro de predição, no sentido de um determinado critério.

3.1.5 Controle Adaptativo Direto

Em contrapartida ao controle adaptativo indireto, o direto tem como uma das principais característica a especificação do desempenho desejado pela malha de controle. Em muitos casos, o desempenho desejado do sistema de controle, por realimentação, pode ser especificado em termos das características de um sistema dinâmico que é uma realização do comportamento desejado do sistema em malha fechada. Um objetivo de rastreamento especificado, em termos de tempo de subida e *overshoot* para uma entrada ao degrau pode ser alternativamente expresso como o comportamento de entrada-saída de uma função transferência. De tal forma que o objetivo de regulação em um ambiente determinístico, pode ser especificado em termos da evolução da saída, a partir de uma perturbação inicial, especificando a localização desejada dos polos de malha fechada. Para o caso em questão, o controlador é concebido, de tal modo, que um modelo de planta dado, o sistema em malha fechada tem as características do sistema dinâmico desejado.

O modelo de referência da Figura 6 é uma realização do sistema com desempenho desejado, para um projeto de controlador linear em ambiente determinístico, usando um modelo de referência explícito com especificações de desempenho. Desta forma, o projeto do controlador é feito de modo que o erro entre a saída da planta e a saída do modelo de referência é aproximadamente zero para condições iniciais idênticas, conseqüentemente o erro inicial desaparece com a dinâmica da planta (LANDAU et al., 2011). Quando os parâmetros da planta são desconhecidos ou mudam com o tempo, para alcançar e manter o desempenho desejado, uma abordagem de controle adaptativo é considerada, sendo aplicado um esquema conhecido como controle adaptativo por modelo de referência. Este esquema baseia-se na observação da diferença entre a saída da planta e a saída do modelo

Figura 6 – Esquema de um controlador linear em ambiente determinístico



Fonte: (LANDAU et al., 2011)

de referência. É uma diferença entre os desempenhos real e desejado.

Esta informação, em conjunto com outras, é utilizada pelo mecanismo de adaptação (posteriormente denominado algoritmo de adaptação de parâmetros) para ajustar diretamente os parâmetros do controlador em tempo real, de forma a forçar assintoticamente o erro do modelo da planta para zero. Este esquema corresponde ao uso de um conceito mais geral conhecido por MRAS (*Model Reference Adaptive Systems*).

Em alguns casos, o modelo de referência pode receber medições da planta, a fim de prever os valores futuros desejados da saída, isto pode ser visto em melhor detalhe em Landau (1984).

3.2 Sistema de Controle Preditivo

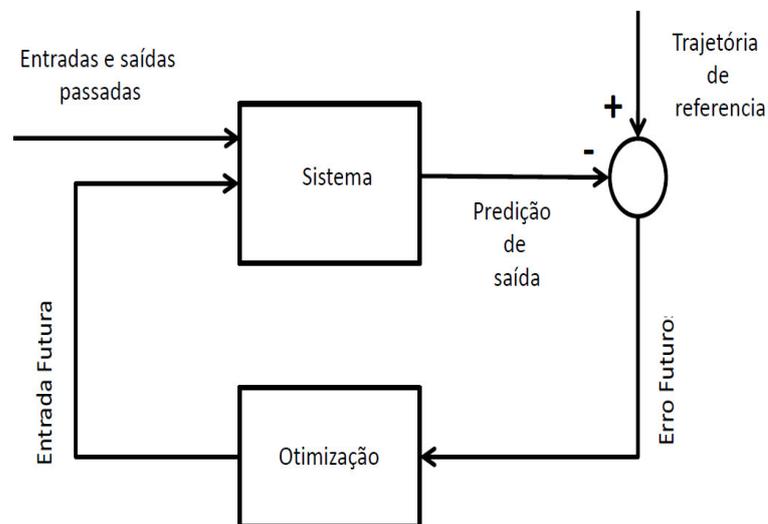
Os conceitos de predição, realimentação e antecipação estão intimamente ligados ao nosso dia-a-dia e a descrição é particularmente clara na explicação destes conceitos: conduzir (controlar) um automóvel por realimentação (reação) é como conduzi-lo olhando apenas para o retrovisor. Só depois de detectarmos o desvio é que reagiríamos e corrigiríamos a trajetória. A maneira como conduzimos é por predição e antecipação. Tal como no controle preditivo, a estratégia seguida é também de horizonte recuante, ou seja, a todo o momento, face à nova informação que nos chega, estamos a reavaliar a situação e a tomar por ótima uma nova sequência de ações, embora, obviamente, só apliquemos a que se torna imediata.

3.2.1 Controle Preditivo Baseado em Modelo - MPC

O termo Controle Preditivo Baseado em Modelo (MBPC ou MPC - *Model (Based) Predictive Control*) não designa uma estratégia de controle específica, mas uma gama muito ampla de métodos de controle que faz-se uso explícito de um modelo do processo

para obter o sinal de controle minimizando uma função objetiva (CAMACHO; ALBA, 2013). Estes métodos de projeto conduzem controladores lineares que têm praticamente a mesma estrutura e apresentam graus adequados de liberdade. As ideias que aparecem em maior ou menor grau em toda a família de controle preditivo são basicamente o uso de modelo matemático do sistema, a lei (função objetiva) e um horizonte de controle. Pode-se verificar uma ideia geral desse tipo de sistema de controle na Figura 7. A metodologia dos controladores que pertencem à família MPC é caracterizada pela estrutura representada pelo seguinte esquema,

Figura 7 – Estrutura básica do MPC.



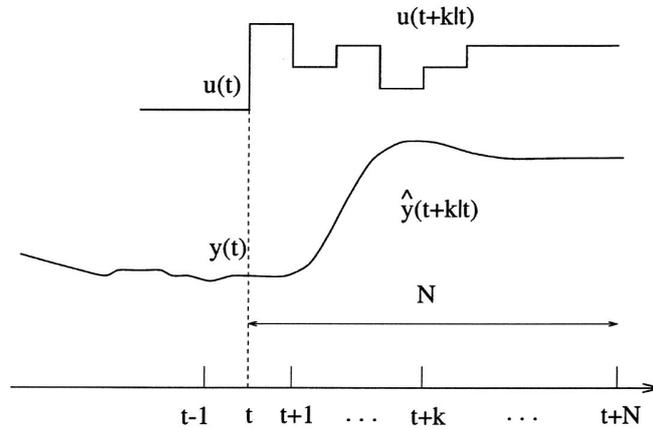
Fonte: Elaborado pelo autor.

A estratégia do sistema de controle MPC fornece as saídas futuras $y(t+k|t)$ para um determinado horizonte de controle, N , que é definido dentro de um horizonte de predição, conforme apresentado na Figura 8. Para as predições em cada instante de tempo, t , em que é usado o modelo matemático do sistema, a predição da saída depende dos valores do conjunto de entrada e saídas passadas para o sinal do controle futuro, $u(t+k|t)$, $k = 1, \dots, N$.

O conjunto de sinais do controle, no contexto do MPC, é calculado por meio da otimização de um determinado critério, a fim de manter o processo mais próximo possível da trajetória de referência $w(t+k)$, que pode ser o próprio ponto de ajuste ou uma aproximação da mesma. Este critério toma geralmente a forma de uma função quadrática.

O sinal de controle $u(t|t)$ é enviado para o processo, enquanto que os próximos sinais calculados são rejeitados, pois no próximo instante de amostragem $y(t+1)$ é conhecido e o primeiro passo é repetido com este novo valor.

Figura 8 – Estratégia do MPC.



Fonte: Elaborado pelo autor

Todos os algoritmos do sistema de controle MPC possuem elementos comuns e várias opções que podem ser escolhidos para dar origem a diferentes algoritmos para controle (CAMACHO; ALBA, 2013).

Um projeto completo deve incluir os mecanismos necessários para obter o *melhor* modelo possível, que possa possuir características o suficiente para capturar plenamente a dinâmica do processo. E também, deva ser capaz de permitir que as previsões sejam calculadas e, ao mesmo tempo, ser intuitiva e permitir análise teórica. A utilização do modelo é determinada pela necessidade de calcular a saída futura $\hat{y}(t+k|t)$. Alguns modelos utilizados para essa finalidade são: resposta ao impulso, resposta ao degrau, função de transferência, espaço de estados e outras como redes neurais artificiais (HAN; KONG; LIU, 2016) e lógica fuzzy (KILLIAN et al., 2016).

A resposta ao impulso é descrita, de maneira que a saída está relacionada com a entrada expressa por

$$y(t) = \sum_{i=1}^{\infty} h_i u(t-i), \quad (3.12)$$

em que h_i é a saída amostrada quando o processo recebe um impulso unitário, dado por Eq.(3.13). Esta soma é truncada e somente N valores são considerados (assim, apenas os processos estáveis sem integradores podem ser representados), como está representada na Figura 9a.

$$y(t) = \sum_{i=1}^{\infty} h_i u(t-i) = H(z^{-1})u(t) \quad (3.13)$$

Com $H(z^{-1}) = h_1 z^{-1} + h_2 z^{-2} + h_3 z^{-3} + \dots + h_N z^{-N}$. A previsão dos valores é dado por

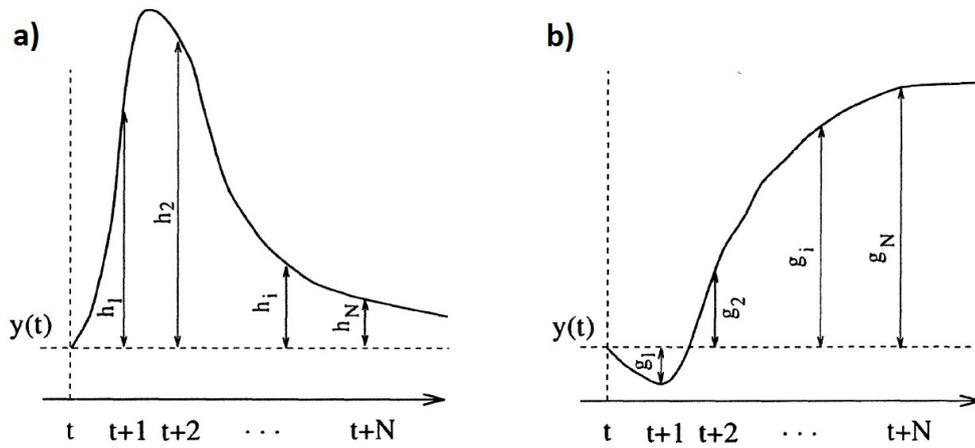
$$\hat{y}(t+k|t) = \sum_{i=1}^N h_i u(t+k-i) = H(z^{-1})u(t+k|t). \quad (3.14)$$

A resposta ao degrau é semelhante a Eq. (3.12), exceto que agora o sinal de entrada é, por sua vez, um degrau. Para sistemas estáveis, a resposta é dada por:

$$y(t) = y_0 + \sum_{i=1}^N g_i \Delta u(t - i) = y_0 + G(z^{-1})(1 - z^{-1})u(t) \quad (3.15)$$

Em que g_i representa os valores amostrados da saída para a entrada ao degrau e $u(t) = u(t) - u(t - 1)$ como mostrado na Fig. 9b. O valor de y_0 pode ser tomado como sendo 0, sem perda de generalidade, de modo que o preditor pode ser representado por

Figura 9 – Respostas ao impulso e degrau.



Fonte: Elaborado pelo autor

$$\hat{y}(t + k|t) = \sum_{i=1}^N g_i \Delta u(t + k - i|t) \quad (3.16)$$

A função de transferência utiliza, $G = \frac{B}{A}$, com saída representada por

$$A(z^{-1})y(t) = B(z^{-1})u(t) \quad (3.17)$$

com $A(z^{-1}) = 1 + a_1z^{-1} + a_2z^{-2} + \dots + a_{na}z^{-na}$ e $B(z^{-1}) = b_1z^{-1} + b_2z^{-2} + \dots + b_{nb}z^{-nb}$. Desta forma, tem-se, que a equação é dada por

$$\hat{y}(t + k|t) = \frac{B(z^{-1})}{A(z^{-1})}u(t + k - i|t) \quad (3.18)$$

A representação da Eq. (3.18) é válida para processos instáveis e tem a vantagem de não precisar de todos os parâmetros, embora o conhecimento, *a priori*, do processo seja fundamental (CAMACHO; BORDONS, 2012).

Para espaço de estado tem-se uma representação dada por

$$x(t) = Mx(t - 1) + Nu(t - 1) \quad (3.19)$$

$$y(t) = Qx(t), \quad (3.20)$$

em que x é o estado. E M , N e Q são as matrizes do sistema, entrada e saída. A predição do modelo é dada por

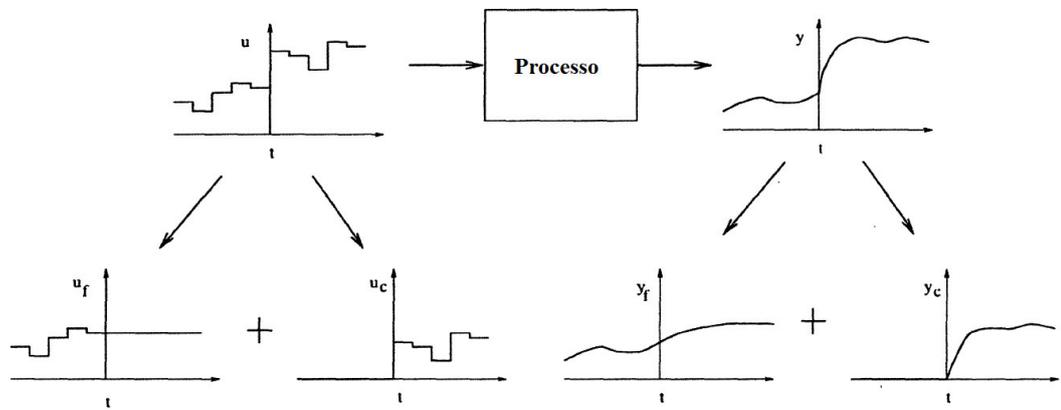
$$\hat{y}(t+k|t) = Q\hat{x}(t+k|t) = Q \left[M^k x(t) + \sum_{i=1}^k M^{i-1} N u(t+k-i|t) \right]. \quad (3.21)$$

A lei de controle é simplesmente o *feedback* de uma combinação linear do vetor de estado, embora às vezes a base de estado escolhida não tenha significado físico. Os cálculos podem ser complicados com uma necessidade adicional de incluir um observador, caso os estados não estejam acessíveis (CAMACHO; BORDONS, 2012).

3.2.2 Função Objetivo do MPC

O objetivo geral do sistema de controle MPC é obter a saída futura (y) no horizonte considerado e, ao mesmo tempo, seguir um sinal de referência (w). Com estes critérios, definir o esforço de controle (Δu) necessário para penalização. Figura 10 caracteriza as formas de sinais de resposta livre e forçada. A expressão geral para a função objetivo é dada por

Figura 10 – Representação de sinais em resposta livre e forçada



Fonte: Elaborado pelo autor

$$J(N_1, N_2, N_u) = \sum_{j=N_1}^{N_2} \delta(j) \psi^2 + \sum_{j=1}^{N_u} \mu, \quad (3.22)$$

em que ψ e μ ,

$$\begin{aligned} \psi &= [\hat{y}(t+j|t) - w(t+j)] \\ \mu &= \lambda(j) [\Delta u(t+j-1)]^2 \end{aligned} \quad (3.23)$$

As variáveis N_1 , N_2 e N_u são os horizontes mínimo, máximo e de controle, respectivamente, de forma que o horizonte máximo, não necessariamente coincide com o horizonte de

controle. Os coeficientes $\delta(j)$ e $\lambda(j)$ estão relacionado com o comportamento futuro do sistema, podendo variar entre 0 e 1.

Para a trajetória de referência $r(t+k)$ do sistema de controle preditivo a evolução futura é conhecida, à *priori*. Na Eq. (3.22) pode-se levar em consideração a trajetória de referência $w(t+k)$, que deve coincidir com a referência $r(t+k)$. Uma aproximação suave à partir do valor atual da saída $y(t)$ é dada por

$$w(t+k) = r(t+k) + \alpha^k(y(t) - r(t)), \quad (3.24)$$

usada no controle preditivo funcional. A minimização da função J , conforme Eq. (3.22), resulta nos valores de $u(t+k|t)$. Os valores das saídas futuras $\hat{y}(t+k|t)$ são calculadas em função das entradas e saídas passadas. Esta estrutura da lei de controle é imposta pela utilização do conceito de controle de horizonte (N_u), como mostrado em Kwon e Han (2006), que considera depois de um intervalo de $N_u < N_2$ variações inexistentes do sinal de controle proposto, de maneira que possa ser expressada por

$$\Delta u(t+j-1) = 0 \quad j > N_u \quad (3.25)$$

que equivale a dar pesos infinitos com mudanças no controle, a partir de um certo instante. O caso extremo seriam considerar N_u igual a 1 com o qual todas as ações futuras seria igual a $u(t)$.

3.3 Redes Neurais Artificiais para Controle

À medida que os computadores se tornam cada vez mais poderosos, os pesquisadores continuam a ser desafiados a usar máquinas de forma eficaz para tarefas relativamente simples para os seres humanos. Com base em exemplos, juntamente com alguns comentários de um "professor", aprendemos facilmente a reconhecer a letra "H". Mais experiência nos permite refinar nossas respostas e melhorar nossa representação.

Embora, possamos descrever regras pelas quais pode-se tomar essas decisões, elas não refletem necessariamente o processo real que usamos para sua descrição. Mesmo sem um professor, podemos agrupar padrões semelhantes. Uma outra atividade humana comum é tentar alcançar um objetivo que envolve a maximização de um recurso, ao mesmo tempo que satisfaz certos limites. Cada um destes tipos de problemas ilustra tarefas para as quais soluções de computadores podem ser procuradas. A computação digital tradicional, sequencial, baseada em lógica supera em muitas áreas, mas tem sido menos bem sucedida para outros tipos de problemas. O desenvolvimento de redes neurais artificiais começou há aproximadamente 50 anos, motivado por um desejo de tentar entender o cérebro e emular algumas de suas ações.

As redes neurais artificiais são uma tentativa de modelar as capacidades de processamento de informação dos sistemas nervosos. Assim, é necessário considerar as propriedades

essenciais das redes neurais biológicas do ponto de vista do processamento das informações. Isso permitirá desenhar modelos abstratos de RNAs, que podem ser simuladas e analisadas. Embora os modelos tenham sido propostos para explicar a estrutura do cérebro e os sistemas nervosos de alguns animais são diferentes em muitos aspectos, há um consenso geral de que a essência da operação de conjuntos neurais é “controle através da comunicação” (BROWN, 2012).

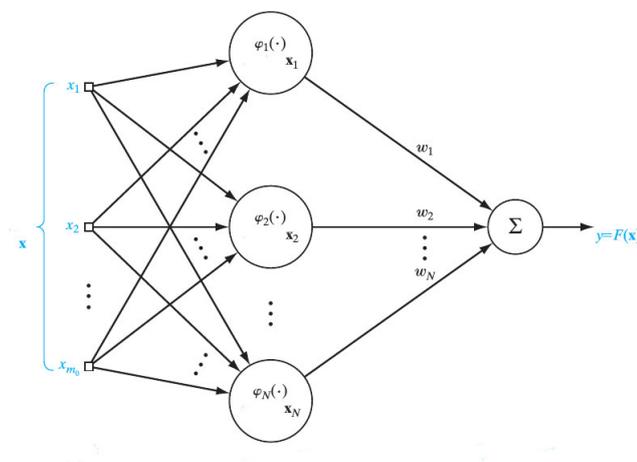
3.3.1 Modelagem Neural

A descrição de conceitos específicos da neurobiologia que pertencem a uma determinada arquitetura de RNA, como também conceitos básicos que têm um significado mais universal. Nesse sentido, aborda-se primeiro os neurônios artificiais de forma individuais, depois para as junções sinápticas entre os neurônios das RNAs. Descrevemos o modelo da computação neural, proposto por McCulloch e Pitts (1943), autores atuais como Souza e Soares (2016), Haykin et al. (2009), e examina-se sua relação específica com os modelos de redes neurais. Estas representações básicas são tratadas no Apêndice B.

3.3.2 Redes Neurais Artificiais de Função de Base Radial RNA - RBF

As Redes Neurais Artificiais de Função de Base Radial é constituída de três camadas, como apresentado na Figura 11. A camada de entrada é composta por nós de unidades sensoriais, responsável por distribuir o sinal recebido. Uma camada oculta constituída de neurônios que realizam uma transformação não-linear da entrada, por meio de funções de base radial. Por fim, uma camada de saída, responsável por receber o sinal processado da camada oculta.

Figura 11 – Estrutura de uma rede *RBF*



Fonte: Elaborado pelo autor

A RBF possui uma característica multidimensional, que depende da distância entre seu vetor de entrada $u \in \mathfrak{R}^n$ e um centro previamente definido $c \in \mathfrak{R}^n$. Com a distância definida por

$$d = \sqrt{(u - c)^T(u - c)}. \quad (3.26)$$

Existem diferentes tipos de RBFs, dentre elas tem-se a função cúbica, a função multiquadrática e a função gaussiana, que são dadas por

$$G(d) = d^3 \quad (3.27)$$

$$G(d) = \left(\frac{d^2}{\sigma^2}\right)^{\frac{1}{2}} \quad (3.28)$$

$$G(d) = e^{-\frac{d^2}{\sigma^2}} \quad (3.29)$$

Quando uma rede neural artificial RBF é usada para classificação, ela resolve esse problema, transformando-o em um espaço dimensional elevado. A justificativa para tal resolução é dada pelo teorema de Cover (1965), que estabelece um problema de classificação sendo mais provável ser linearmente separável em um espaço com dimensionalidade elevada do que em espaço de baixa dimensão.

Um esquema geral para RNA-RBF, como descrito na Figura 11, tem o seu modelo matemático representado por

$$y = F(u) = \sum_{i=1}^m w_i G\left(\|u - c_i\|_{r_i}^2\right) \quad (3.30)$$

em que $G(\cdot)$ é uma função de base radial, $u^T = (u_1, u_2, \dots, u_n)$ é a entrada, c_i é o centro, r_i é o raio, m é o número de neurônios. A relação entre estes parâmetros é dada por

$$\|u - c_i\|_{r_i}^2 = \frac{(u - c_i)^T(u - c_i)}{r_i}, \quad (3.31)$$

sendo R_i definido por

$$R_i = \begin{pmatrix} \frac{1}{\sqrt{r_i}} & 0 & \dots & 0 & \dots & 0 \\ 0 & \frac{1}{\sqrt{r_i}} & \dots & 0 & \dots & 0 \\ \cdot & \cdot & \ddots & \cdot & \dots & \cdot \\ 0 & \cdot & \dots & \frac{1}{\sqrt{r_i}} & \dots & 0 \\ \cdot & \cdot & \dots & \cdot & \ddots & \cdot \\ 0 & \cdot & \dots & \cdot & \dots & \frac{1}{\sqrt{r_i}} \end{pmatrix}, \quad (3.32)$$

na forma vetorial, é dado por

$$\Omega_i^{-1} = R_i^T R_i, \quad (3.33)$$

e com manipulações algébricas tem-se que

$$\|u - c_i\|_{r_i}^2 = (u - c_i)^T R_i^T R_i (u - c_i) = (u - c_i)^T \Omega_i^{-1} (u - c_i). \quad (3.34)$$

A matriz Ω_i é interpretada como uma covariância. Se R_i é dada por

$$R_i = \begin{pmatrix} \frac{1}{\sqrt{r_{1i}}} & 0 & \cdots & 0 & \cdots & 0 \\ 0 & \frac{1}{\sqrt{r_{2i}}} & \cdots & 0 & \cdots & 0 \\ \cdot & \cdot & \ddots & \cdot & \cdots & \cdot \\ 0 & \cdot & \cdots & \frac{1}{\sqrt{r_{ii}}} & \cdots & 0 \\ \cdot & \cdot & \cdots & \cdot & \ddots & \cdot \\ 0 & \cdot & \cdots & \cdot & \cdots & \frac{1}{\sqrt{r_{pi}}} \end{pmatrix} \quad (3.35)$$

então obtêm-se uma base elíptica para a função. A função gaussiana é uma das RBF mais populares, que é dada por

$$\begin{aligned} G\left(\|u - c_i\|_{r_i}^2\right) &= e^{-\|u - c_i\|_{r_i}^2} \\ &= e^{-(u - c_i)^T R_i^T R_i (u - c_i)} \\ &= e^{-(u - c_i)^T \Omega_i^{-1} (u - c_i)}. \end{aligned} \quad (3.36)$$

Estas funções têm a propriedade de serem fatoráveis. A RBF gaussiana é capaz de aproximar funções não-lineares contínuas. Algumas aplicações pioneiras podem ser vistas em Park e Sandberg (1991) e Narendra e Parthasarathy (1990).

Para um número de N exemplos de treinamento, a definição do erro é dada por

$$\mathcal{E} = \frac{1}{2} \sum_{n=1}^N e^2(n), \quad (3.37)$$

sendo $e(n)$ dado por

$$e(n) = d(n) - \sum_{i=1}^m w_i G\left(\|u(n) - c_i\|_{r_i}^2\right). \quad (3.38)$$

O erro quadrático \mathcal{E} é minimizado em relação a w_i , c_i e/ou r_i . Esta minimização pode ser realizada para cada passo do processo iterativo ou época. Para o caso do

atualização dos pesos w_i tem-se que

$$\begin{aligned}\frac{\partial \mathcal{E}(n)}{\partial w_i(n)} &= \frac{\partial}{\partial w_i(n)} \left(\frac{1}{2} e^2(n) \right) \\ &= e(n) \frac{\partial}{\partial w_i(n)} \left(d(n) - \sum_{i=1}^m w_i G \left(\|u(n) - c_i\|_{r_i}^2 \right) \right) \\ \frac{\partial \mathcal{E}(n)}{\partial w_i(n)} &= -e(n) G \left(\|u(n) - c_i\|_{r_i}^2 \right).\end{aligned}\quad (3.39)$$

Com o uso da regra do gradiente descendente, os pesos atualizados para $i = 1, \dots, m$ obtêm-se de forma dada por

$$w_i(n+1) = w_i(n) - \eta_w \frac{\partial \mathcal{E}(n)}{\partial w_i(n)}.\quad (3.40)$$

Considerando a atualização dos centros, tem-se que

$$\begin{aligned}\frac{\partial \mathcal{E}(n)}{\partial c_i(n)} &= \frac{\partial}{\partial c_i(n)} \left(\frac{1}{2} e^2(n) \right) \\ &= -w_i(n) e(n) \frac{\partial}{\partial c_i(n)} \left(\|u(n) - c_i(n)\|_{r_i}^2 \right) G \frac{\partial}{\partial c_i(n)} \left(\|u(n) - c_i(n)\|_{r_i}^2 \right) \\ &= G' \left(\|u(n) - c_i(n)\|_{r_i}^2 \right) \frac{\partial}{\partial c_i(n)} \left(\|u(n) - c_i(n)\|_{r_i}^2 \right)\end{aligned}\quad (3.41)$$

em que $G'(\beta)$ é dado por

$$G'(\beta) = \frac{\partial G(\beta)}{\partial \beta}$$

Ainda, considera-se que

$$\frac{\partial}{\partial c_i(n)} \left(\|u(n) - c_i(n)\|_{r_i}^2 \right) = -2R_i^T(n)R_i(n)(u(n) - c_i(n))\quad (3.42)$$

para se obter a derivada parcial, que é dada por

$$\frac{\partial \mathcal{E}(n)}{\partial c_i(n)} = 2w_i(n)e(n)G' \left(\|u(n) - c_i(n)\|_{r_i}^2 \right) R_i^T(n)R_i(n)(u(n) - c_i(n)).\quad (3.43)$$

Os centros atualizados para $i = 1, \dots, m$ são obtidos a partir da expressão que é dada por

$$c_i(n+1) = c_i(n) - \eta_c \frac{\partial \mathcal{E}(n)}{\partial c_i(n)}.\quad (3.44)$$

Por conseguinte, tem-se a atualização dos raios, considera-se que os três parâmetros são atualizados. A seguir apresenta-se a dedução da adaptação do raio, da matriz Ω_i^{-1} ,

$$\begin{aligned}\frac{\partial \mathcal{E}(n)}{\partial \Omega_i^{-1}(n)} &= \frac{\partial}{\partial \Omega_i^{-1}(n)} \left(\frac{1}{2} e^2(n) \right) \\ &= -w_i(n)e(n) \frac{\partial}{\partial \Omega_i^{-1}(n)} G \left(\|u(n) - c_i(n)\|_{r_i(n)}^2 \right) \frac{\partial}{\partial \Omega_i^{-1}(n)} G \left(\|u(n) - c_i(n)\|_{r_i(n)}^2 \right) \\ &= G' \left(\|u(n) - c_i(n)\|_{r_i(n)}^2 \right) \frac{\partial}{\partial \Omega_i^{-1}(n)} \left(\|u(n) - c_i(n)\|_{r_i(n)}^2 \right)\end{aligned}\quad (3.45)$$

para se obter,

$$\frac{\partial \mathcal{E}(n)}{\partial \Omega_i^{-1}(n)} \left(\|u(n) - c_i(n)\|_{r_i(n)}^2 \right) = (u(n) - c_i(n)) (u(n) - c_i(n))^T = Q_i(n), \quad (3.46)$$

derivando em relação Ω_i^{-1} Eq. (3.46) tem que

$$\frac{\partial \mathcal{E}(n)}{\partial \Omega_i^{-1}(n)} = -w_i(k)e(n)G' \left(\|u(n) - c_i(n)\|_{r_i(n)}^2 \right) Q_i(k).$$

Os raios são atualizados, $i = 1, \dots, m$, pela expressão que é dada por

$$\Omega_i^{-1}(n+1) = \Omega_i^{-1}(n) - \eta_\Omega \frac{\partial \mathcal{E}(n)}{\partial \Omega_i^{-1}(n)}. \quad (3.47)$$

Nota-se que \mathcal{E} é uma função convexa apenas em relação a w_i . Geralmente a seguinte relação é selecionada

$$\eta_\Omega < \eta_r < \eta_w.$$

Desta forma, o passo de interação da descida dos pesos é maior do que os centros, e este último passo é maior do que o raio. A adaptação de pesos ajuda a minimizar o erro entre a saída da rede e a saída desejada. Adaptar os centros assegura o agrupamento das informações de entrada. Os raios são adaptados para atingir um certo grau de sobreposição entre as funções de base radial.

3.4 Comentários

Apresentou os conceitos e formulação matemática das abordagens de controle adaptativo associados com otimalidade e redes neurais. Especificamente, tratou-se das redes RBF e a metodologia do sistema de controle MPC.

4 Sintonia RNA-Preditiva de Controladores PID

O desenvolvimento das estratégias e das adequações de modelos e algoritmos para sintonia de controladores PID são apresentados neste capítulo. Os modelos permitem a inserção de estratégias para ajustes dos ganhos do controlador, apresentando-se uma estratégia fundamentada em RNA - RBF que está associada com o sistema de predição da saída da planta.

O capítulo é organizado em cinco seções que descrevem os métodos e procedimentos para sintonia *online* RNA-preditiva de controladores PID. A arquitetura do sistema de predição da proposta é apresentado na Seção 4.1. O modelo do controle preditivo e da RNA é apresentado na Seção 4.2., discute-se a arquitetura do MPC direto baseado em RNAs com preditores recursivo e não-recursivo *d - step* à frente.

Os modelos para predição de sistemas e a estrutura do controle baseada em RNA-RBF são apresentados na Seção 4.3, associando o esquema de controle adaptativo direto com uma RNA - RBF. Na Seção 4.4 a arquitetura da proposta da sintonia RNA-RBF de controlador PID em um contexto adaptativo é apresentado por meio de expressões matemáticas que expressam os parâmetros. Aborda-se a estrutura do controlador PID-RBF neural e os passos para elaboração do procedimento de atualização dos parâmetros da RNA - RBF. Na Seção 4.5 apresenta-se os principais comentários a finais do capítulo.

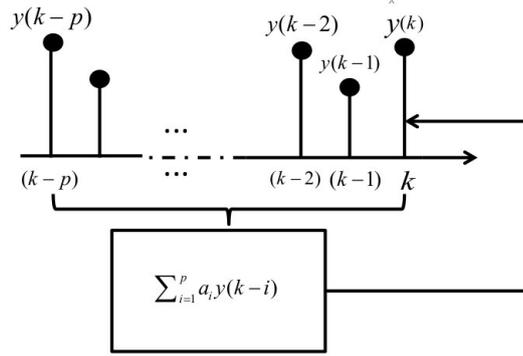
4.1 Arquitetura do Sistema de Predição

A maneira pela qual os elementos das RNAs estão interligados descrevem a arquitetura de um preditor. A arquitetura, ou estrutura, de um preditor suporta sua capacidade de representar as propriedades dinâmicas do sinal de entrada em tempo discreto estatisticamente não estacionário e, portanto, sua capacidade de prever algum valor futuro. Os blocos de construções básicas dos preditores de tempo discretos são formados por os somadores, retardadores e multiplicadores. Os fundamentos de preditores lineares para sinais estatisticamente estacionários são encontradas no trabalho de WIENER (1950). Os estudos posteriores de Christofides et al. (2013b) e Box et al. (2015) foram construídos sobre estes fundamentos. Tais estruturas lineares estão muito bem estabelecidas no processamento de sinais digitais e são classificadas como filtros digitais de resposta ao impulso finito (FIR - *Finite Impulse Response*) ou de resposta de impulso infinita (IIR - *Infinite Impulse Response*) (KAY, 2013).

Um sinal aleatório em tempo real discreto $\{y(k)\}$, onde k é o índice de tempo

discreto $e\{\cdot\}$ denota o conjunto de valores, sendo comumente obtido por amostragem de alguma medida analógica. Tais sinais aleatórios em tempo discreto têm estatísticas que variam no tempo, mas em curto prazo, elas podem ser assumidas como sendo invariantes no tempo. O princípio da previsão de um sinal em tempo discreto é representado na Figura 12. O valor do sinal $y(k)$ é previsto com base na soma dos valores de p passado, isto é,

Figura 12 – Representação de resposta livre e forçada



Fonte: Elaborado pelo autor

$y(k-1), y(k-2), \dots, y(k-p)$, ponderado pelos coeficientes a_i , com $i = 1, 2, \dots, p$ para formar a previsão $\hat{y}(k)$. O erro de previsão, $e_p(k)$, torna-se,

$$e_p(k) = y(k) - \hat{y}(k) = y(k) - \sum_{i=1}^p a_i y(k-i). \quad (4.1)$$

A estimativa do parâmetro a_i baseia-se na minimização da função do erro, e o erro quadrático médio $E[e^2(k)]$, em que $E[\cdot]$ denota o operador de esperança e $\{y(k)\}$, assume como estatisticamente estável, com média zero (ATHANASIOS, 2017). Uma vantagem fundamental do critério de erro quadrático médio é a chamada condição de ortogonalidade, que implica em:

$$E[e(k)y(k-j)] = 0, \quad (4.2)$$

em que $j = 1, 2, \dots, p$ é satisfeito somente quando $a_i = 1, 2, \dots, p$, assumir valores ótimos. Como consequência da Eq.(4.2) e da estrutura linear do preditor, os parâmetros dos pesos ótimos podem ser encontrados a partir de um conjunto de equações lineares, denominadas equações de Box et al. (2015) dada por

$$\begin{bmatrix} r_{yy}(0) & r_{yy}(1) & \cdots & r_{yy}(p-1) \\ r_{yy}(1) & r_{yy}(0) & \cdots & r_{yy}(p-2) \\ \vdots & \vdots & \ddots & \vdots \\ r_{yy}(p-1) & r_{yy}(p-2) & \cdots & r_{yy}(0) \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_p \end{bmatrix} = \begin{bmatrix} r_{yy}(1) \\ r_{yy}(2) \\ \vdots \\ r_{yy}(p) \end{bmatrix}, \quad (4.3)$$

em que $r_{yy}(\tau) = E[y(k)y(k + \tau)]$ é um valor da função de autocorrelação de $y(k)$ à defasagem τ . Estas equações podem ser escritas em forma vetorial expressa por

$$\mathbf{R}_{yy}\mathbf{a} = \mathbf{r}_{yy}, \quad (4.4)$$

em que $\mathbf{R}_{yy} \in \mathbb{R}^{p \times p}$ é a matriz de autocorrelação e $\mathbf{a}, \mathbf{r}_{yy} \in \mathbb{R}$ são o vetores de parâmetro do preditor e correlação cruzada, respectivamente.

A qualidade da previsão é julgada pelo mínimo erro médio quadrático (MMSE - *Minimum Mean Square Error*), calculado a partir de $E[e^2(k)]$ quando os parâmetros dos pesos do preditor assumem valores ótimos. O MMSE é calculado a partir de $r_{yy}(0) - \sum_{i=1}^p a_i r_{yy}(i)$.

As medidas reais só podem ser assumidas como sendo localmente de sentido amplo e, portanto na prática, os valores da função de autocorrelação devem ser estimados a partir da medida de comprimento finito para empregar Eq. (4.3), aplicando uma medida N de comprimento finito, $\{y(G), y(l), \dots, y(N - 1)\}$ tem-se que,

$$\hat{r}_{yy}(\tau) = \frac{1}{N} \sum_{k=0}^{N-\tau-1} y(k)y(k + \tau) \quad (4.5)$$

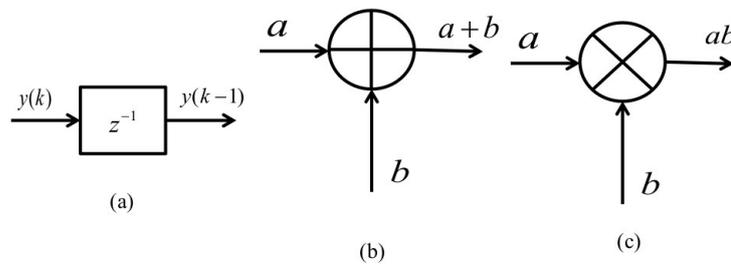
em que $\tau = 0, 1, 2, \dots, p$.

A estimativa dos parâmetros dos pesos são refinadas em cada número de amostras, k , com base na nova amostra $y(k)$, com erro de previsão $e_p(k)$. A atualização dos pesos é dada por

$$\hat{a}(k + 1) = \hat{a}(k) + \eta f(e_p(k), y(k)) \quad (4.6)$$

em que $\eta, f(\cdot)$ são o ganho de adaptação e uma função dependente do algoritmo de

Figura 13 – Blocos para construção de preditores: (a) deformador, (b) adicionador, (c) multiplicador



Fonte: Elaborado pelo autor

aprendizagem, respectivamente. O $\hat{a}(k)$ é o estimador e $\hat{y}(k)$ é o vetor preditor.

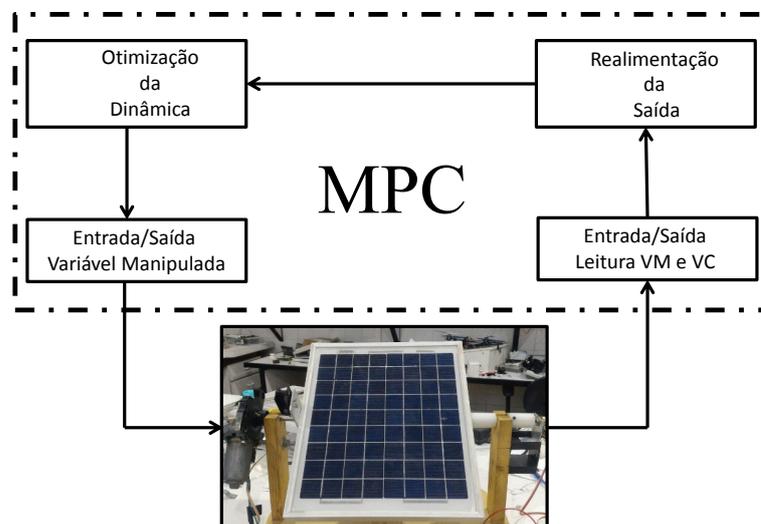
Sem conhecimento prévio adicional, zero ou valores aleatórios, são escolhidos para condições iniciais dos pesos em Eq. (4.6), ou seja, \hat{a}_i , ou n_i , $i = 1, 2, \dots, p$, em que n_i é uma variável aleatória.

A abordagem sequencial da estimação paramétrica dos pesos é particularmente adequada para o funcionamento de preditores em ambientes estatisticamente não estacionários.

4.2 Controle Preditivo e RNA

A modelagem no sentido de aplicações em MPC são bem reconhecidos. Ao contrário do controle tradicional, em que a modelagem e análise representam uma pequena parte do esforço no desenvolvimento de aplicativos, pois em projeto de controle que a maior parte do tempo gasto é atribuído à modelagem e identificação do sistema. A estruturação e sequencia de tarefas envolvidas do sistema de controle MPC no posicionamento do painel fotovoltaico é representado na Figura 14.

Figura 14 – Sequência de tarefas envolvidas na aplicação genérica de sistema MPC.



Fonte: Elaborado pelo autor

Um problema que ocorre durante o treinamento da rede neural é denominado *overfitting*. O erro no conjunto de treinamento é direcionado para um valor muito pequeno, mas quando novos dados são apresentados à rede, o erro é grande. A rede memoriza os exemplos de treinamento, mas não aprendeu a generalizar as novas situações. Um método para melhorar a generalização da RNA é utilizado um erro grande o suficiente para proporcionar um ajuste adequado. Quanto maior a rede utilizada, mais complexas

são as funções que a rede pode criar. Se for utilizada uma rede suficientemente pequena, não terá energia suficiente para sobrecarregar os dados.

Um dos algoritmos mais avançados da segunda abordagem é a chamada “regularização”. Este algoritmo envolve a modificação da função de desempenho, normalmente escolhido para ser a soma dos quadrados dos erros.

O uso da função de desempenho fará com que a RNA tenha pesos e bias menores, forçando a sua resposta ser suave e menos provável o *overfit*. O problema da regularização mostra-se difícil para determinação do valor ótimo do parâmetro. Os parâmetros muito grandes, pode-se haver *overfitting*, enquanto que se a proporção for muito pequena, a RNA não irá ajustar adequadamente os dados de treinamento. É desejável determinar os parâmetros de regularização ótimos da forma *online*.

4.2.1 MPC direto baseado em RNAs

Existem várias maneiras de usar RNAs em sistemas de controle. Na descrição dos algoritmos de controle baseados em modelos RNAs, considera-se que o modelo do processo é expresso na forma discreta, dada por

$$y(k+1) = f(y(k), \dots, y(k-n+1), u(k), \dots, u(k-m+1)), \quad (4.7)$$

em que $u(k)$ e $y(k)$ são vetores de entrada e saída no instante de tempo k . O valor de n e m estão relacionados com a ordem de sistema. A função f é não linear que se pensa ser conhecida, embora alguma ideia de sua estrutura seja provavelmente aparente.

O tempo de atraso do processo é crucial para a obtenção do modelo baseado em RNA de maneira adequada. O tempo de atraso ($d, d \geq 0$) do processo é introduzido na seguinte pela equação dada por

$$y(k+1) = f(y(k), \dots, y(k-n+1), u(k-d), \dots, u(k-d-m+1)). \quad (4.8)$$

O controle MPC baseado em RNA confia-se nas considerações da função aproximada de f expressa por uma RNA. Para isso, considera-se que $y(k), \dots, y(k-n+1), u(k-d), \dots, u(k-d-m+1)$, são as entradas e $y(k+1)$ é a saída, respectivamente, de maneira que um modelo dinâmico aproximado é construído ajustando um conjunto de pesos de conexão e bias por meio do treinamento. Consequentemente a estimação da saída predita é dada por

$$\hat{y}(k+1) = f_{ANN}(y(k), \dots, y(k-n+1), u(k-d), \dots, u(k-d-m+1)) \quad (4.9)$$

Esta RNA recursiva é utilizada na estrutura MPC, para obter a predição do modelo, de maneira que se possa usar a previsão de várias maneiras.

Descreve-se dois tipos de preditores com estrutura *d-step* à frente para compensar a influência do tempo de atraso.

4.2.2 Preditor recursivo d -Step à frente

Com base no modelo da Eq. (4.9), pode-se usar uma técnica recursiva sucessiva para obter o preditor d -step à frente que é dado por

$$\hat{y}(k+d+1) = f_{ANN}(\hat{y}(k+d), \dots, \hat{y}(k+d-n+1), u(k-d), \dots, u(k-d-m+1)) \quad (4.10)$$

Esse preditor depende das previsões nas etapas anteriores, dentro do horizonte de previsão. A propriedade recursiva do preditor habilita a extensão para previsão de longo alcance. Para um horizonte de previsão P , o preditor de longo alcance é dado por

$$\begin{aligned} \hat{y}(k+i|k) = & f_{ANN}(\hat{y}(k+i-1), \dots, \hat{y}(k+i-\min(i, n)), y(k), \dots \\ & \dots, y(k-\max(n-i, 0)), u(k+i-d), \dots, u(k+i-d-m+1)), \end{aligned} \quad (4.11)$$

em que $\hat{y}(k+i|k)$ é o valor de predição de y para o momento $k+i$ obtido em k com base nas informações disponíveis até k .

4.2.2.1 Preditor não recursivo d -Step à frente

O preditor não recursivo d -step à frente utiliza as sequências de ambas as entradas e saídas passadas do processo até o tempo de amostragem k para construir o modelo preditivo dado por

$$\hat{y}(k+d+1) = g_{ANN}(y(k), \dots, y(k-n+1), u(k), \dots, u(k-d-m+1)). \quad (4.12)$$

Comparado com o preditor recursivo d -step à frente, o preditor não recursivo é simples, pois não requer o procedimento recursivo. No entanto, um banco de preditores deve ser usado em um horizonte preditivo se houver qualquer intenção de usar esse tipo de preditor para a previsão de longo alcance. A previsão de longo alcance usando o preditor d -step à frente não-recursivo é dado por

$$\hat{y}(k+i) = g_{ANN}^{i-d}(y(k), \dots, y(k-n+1), u(k+i-d), \dots, u(k-d-m+1)). \quad (4.13)$$

A seguir, deriva-se as formas explícitas do preditor neural da Eq. (4.13). O modelo neural *feedforward*, com q camadas para a representação do processo é dado por

$$\hat{y}(k+i) = t_f^q \left(W_i^q \cdot t_f^{q-1} \left(W_i^{q-1} \cdot \dots \cdot t_f^1 \left(W_i^1 \cdot I(k+i) \right) \right) \right), \quad (4.14)$$

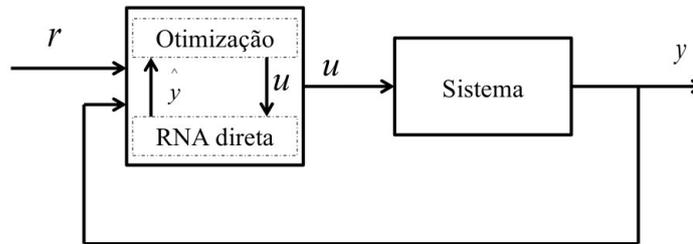
em que $I(k+i) = \{y(k), \dots, y(k+1-n), u(k+i-d), \dots, u(k+1-d-m)\}$. Deve-se notar que em contraste com o preditor neural recursivo, para os diferentes passos de predição dentro do horizonte de previsão, os valores dos pesos dos preditores neurais não recursivos são diferentes.

Usando as previsões obtidas dos procedimentos descritos anteriormente, o movimento de controle é determinado de maneira a solucionar o seguinte problema de otimização dado por

$$\min_{u(k)...u(k+M-1)} = \left\{ \sum_{i=1}^P \| Q_i(r(k+i) - \hat{y}(k+i)) \|^2 + \sum_{i=1}^M \| R_i \Delta u(k+i-1) \|^2 \right\}. \quad (4.15)$$

Isso leva a um problema de otimização não-linear e não-convexo, para o qual a solução global é difícil de se encontrar. Portanto, os algoritmos de otimização especiais devem ser usados. A representação esquemática do MPC baseado em RNAs são apresentados na Figura 15.

Figura 15 – MPC direto baseado em RNAs com de otimização iterativo.



Fonte: Elaborado pelo autor

4.3 Predição de Sistemas e RNA-RBF

A base da previsão de séries temporais foram explorados para a identificação de sistemas dinâmicos não-lineares usando RNA parcialmente recorrentes (NARENDRA; PARTHASARATHY, 1990). Na descrição dos algoritmos de controle com base em modelos de RNA considera-se que o processo é escrito na forma discreta (HUNT et al., 1992) (ANILKUMAR; PADHIYAR; MOUDGALYA, 2016). A dinâmica da plantas não-lineares é dada por

$$y(k+1) = f(y(k), \dots, y(k-n+1), \dots, u(k), \dots, u(k-m+1)), \quad (4.16)$$

em que $u(k)$ e $y(k)$ são vetores de entrada e saída no instante de tempo k . Os valores de n e m está relacionado com as ordens de $y(k)$ e $u(k)$, respectivamente. A função f representa um padrão não linear, considerada desconhecida, embora alguma ideia da sua estrutura é provavelmente evidenciada.

Considerando o sistema de segunda ordem dado por

$$y(k) = -a_1 y(k-1) - a_2 y(k-2) + b_0 u(k) + b_1 u(k-1) + b_2 u(k-2).. \quad (4.17)$$

A RNA para previsão da saída do sistema dinâmico é baseado em uma *RBF* de treinamento *online*. A predição na saída do sistema baseado na Eq.(4.16) é dada por

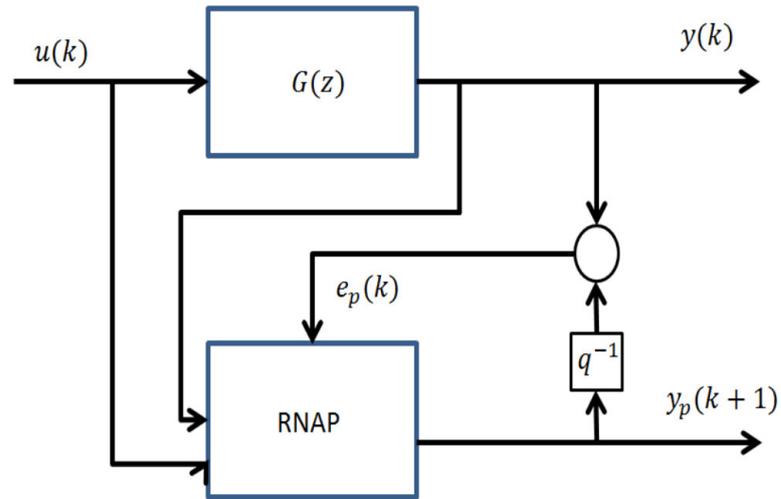
$$y_p(k+1) = f(y(k), y(k-1), y(k-2), u(k), u(k-1) + u(k-2)). \quad (4.18)$$

Para a predição da saída do sistema dinâmico no instante de $(k+1)$ é adquirida, utilizando a propriedade de aproximação de funções por meio de RNA - RBF, já descrita na Seção (3.3).

A entrada da RNA - RBF é composta por seis unidades sensoriais que são representadas pelas entradas e saídas do sistema. A entrada da RBF é dada por $y(k)$, $y(k-1)$, $y(k-2)$, $u(k)$, $u(k-1)$ e $u(k-2)$.

O esquema do mecanismo de predição neural é mostrado na Figura 16.

Figura 16 – Esquema do mecanismo de predição baseado na RNA - RBF.



Fonte: Elaborado pelo autor

A entrada da camada da rede neural RBF é composta de unidades sensoriais dado por $\mathbf{x} = [x_1 \ x_2 \ x_3 \ x_4 \ x_5 \ x_6]^T$. A entrada da camada oculta de j neurônios é dada por

$$\begin{aligned} I_{h_1} &= c_{11}x_1 + \dots + c_{41}x_4 + c_{51}x_5 + c_{61}x_6 \\ I_{h_2} &= c_{12}x_1 + \dots + c_{42}x_4 + c_{52}x_5 + c_{62}x_6 \\ &\vdots = \quad \quad \quad \vdots \\ I_{h_8} &= c_{18}x_1 + \dots + c_{48}x_4 + c_{58}x_5 + c_{68}x_6 \end{aligned} \quad (4.19)$$

A saída de cada neurônio da camada oculta é dada por

$$\begin{aligned} O_{h_1} &= f_{RBF}(I_{h_1}) \\ O_{h_2} &= f_{RBF}(I_{h_2}) \\ &\vdots = \vdots \\ O_{h_8} &= f_{RBF}(I_{h_8}) \end{aligned} \quad (4.20)$$

em que c_{ij} é o centro que ligam j ($j = 1, 2, \dots, 8$) neurônios na camada oculta ($i = 1, 2, 3, \dots, 6$) às unidades sensoriais da camada de entrada. A f_{RBF} representa uma função gaussiana dada por

$$f_{RBF_{h_j}} = \exp\left(-\frac{\|\mathbf{X}-c_{jn}\|}{2b_j^2}\right), \quad (4.21)$$

em que n e j representam os números de neurônios na camadas de entrada e na camada oculta, respectivamente. O vetor da largura na função gaussiana é dada por

$$b = [b_1 \ b_2 \ b_3 \ \dots \ b_7 \ b_8], \quad (4.22)$$

em que $b_j > 0$. E o vetor peso sendo $w = [w_1, \ w_2, \ w_3, \ \dots \ w_7, \ w_8]$. A entrada do neurônio na camada de saída é representada por

$$I_{O_1} = w_{11}f_{RBF}(I_{h_1}) + w_{21}f_{RBF}(I_{h_2}) + \dots + w_{81}f_{RBF}(I_{h_8}). \quad (4.23)$$

A saída do neurônio na camada de saída da rede é dada por

$$y_p(k+1) = f_O(I_{O_1}). \quad (4.24)$$

Para o índice de performance da função RBF tem-se que

$$E(k) = \frac{1}{2}(y(k) - \Psi) \quad (4.25)$$

em que Ψ é o valor da predição da saída atrasada. A atualização dos pesos w_{ij} e centros c_{jn} da rede neural *RBF* é realizada pela expressão dada por

$$\Psi = y_p(k+1) q^{-1}. \quad (4.26)$$

O método do gradiente descendente é usado para a atualização dos parâmetros da rede neural *RBF* expressa por

$$\Delta w_j(k) = -\eta \frac{\partial E}{\partial w_j} = -\eta(y(k) - y_p(k+1) q^{-1}). \quad (4.27)$$

Em que substituindo Ψ na Eq.(4.27) calcula-se a variação do peso, dado por

$$\Delta w_j(k) = -\eta \frac{\partial E}{\partial w_j} = -\eta(y(k) - \Psi) \quad (4.28)$$

Considerando os pesos anteriores e fazendo as devidas manipulações algébricas tem-se a atualização dos pesos é dada por

$$w_j(k) = w_j(k-1) + \Delta w_j(k) + \dots + \alpha(w_j(k-1) - w_j(k-2)). \quad (4.29)$$

Para a atualização da largura na função gaussiana, tem-se que

$$\Delta b_j(k) = -\eta \frac{\partial E}{\partial b_j} \quad (4.30)$$

Substituindo Ψ em Eq. (4.30), tem-se que

$$\Delta b_j(k) = -\eta(y(k) - \Psi)w_j f_{RBF}\left(\frac{\|\mathbf{x} - c_{jn}\|^2}{b_j^2}\right). \quad (4.31)$$

A atualização de $b_j(k)$ é dada por

$$b_j(k) = b_j(k-1) + \Delta b_j(k) + \dots + \alpha(b_j(k-1) - b_j(k-2)). \quad (4.32)$$

Por fim, as atualizações dos centros c_{ji} é dada por

$$\Delta c_{ji}(k) = -\eta \frac{\partial E}{\partial c_{ji}} \quad (4.33)$$

Substituindo Ψ em Eq. (4.33), tem-se que

$$\Delta c_{ji}(k) = -\eta(y(k) - \Psi)w_j \left(\frac{\|\mathbf{x} - c_{jn}\|^2}{b_j^2}\right) \quad (4.34)$$

em que as atualizações dos centros é dada por

$$c_{ji}(k) = c_{ji}(k-1) + \Delta c_{ji}(k) + \dots + \alpha(c_{ji}(k-1) - c_{ji}(k-2)) \quad (4.35)$$

em que $\eta \in (0, 1)$ é a taxa de aprendizagem e $\alpha \in (0, 1)$ é o momento. No caso de aplicações para aproximações de funções com rede neurais *RBF*, os parâmetros de b_i e c_i devem ser escolhidos de acordo com o valor de entrada. Esse procedimento foi o mesmo adotado para o procedimento de ajustes da rede neural *RBF*. Se os valores dos parâmetros são escolhidos de forma inadequada, a função de gaussiana não vai ser efetivamente mapeados e a RNA-RBF será inválido, para aplicação proposta pelo dissertação. O método do gradiente descendente é um método eficaz para ajustar c_i e b_i em aproximações de funções com rede neural *RBF*.

4.4 Sintonia RNA-RBF de Controlador PID

O controlador PID é um componente básico na hierarquia multinível moderno de controle, que funcionam como controladores de regulamentação segundo uma abordagem em Chan, Chen e Chen (2016).

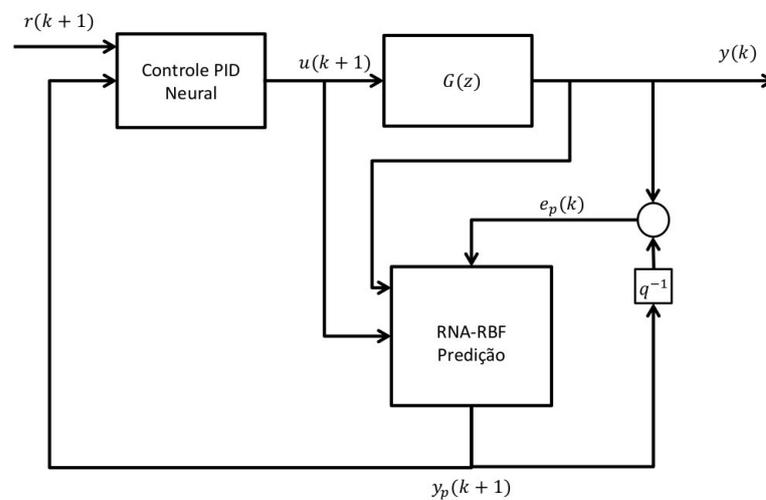
Apesar da vasta literatura sobre sintonia do controlador PID, uma porcentagem significativa em modo automático são mal sintonizadas, segundo Ender (1993). Por conseguinte, o desempenho ótimo nem sempre é alcançado. A necessidade de produtos de alta qualidade, redução do consumo de energia (combustível e eletricidade), o aumento da concorrência de mercado cria uma necessidade, indiscutível, de melhorar o desempenho do controle no processo.

4.4.1 Estrutura do controlador PID-RBF neural

Os modos tradicionais do controlador PID é dada pelos modos localizado e incremental. A realização da estrutura da RNA - RBF no modo localizado é modificado por meio de uma combinação linear dos termos do controlador PID.

A estrutura do controlador PID neural, representada pela Figura 17 é desenvolvida pelo método direto, no sentido de obter a saída do controlador por meio das entradas da RNA - RBF.

Figura 17 – Esquema do controlador PID Neural RBF



Fonte: Elaborado pelo autor

A RNA - RBF é composta por três *unidades sensoriais*, oito neurônios na camada oculta e um neurônio na camada de saída. A entrada da rede, \mathbf{x} , na RNA - RBF é dada por

$$\begin{aligned} x_1 &= e(k) \\ x_2 &= T \sum_{i=0}^k e(k). \\ x_3 &= \frac{\Delta e(k)}{T} \end{aligned} \quad (4.36)$$

A estrutura da rede neural é escrita em função de J , dada por

$$J = \frac{1}{2} [y_d(k) - y(k)]^2. \quad (4.37)$$

O método da descida mais íngreme é usado para os ajustes dos pesos da RNA - RBF para atingir o objetivo de J . Em que a função de erro é dado por

$$e(k) = y_d - y, \quad (4.38)$$

A saída do controlador, $u(k)$, já definido, tem-se o vetor de entrada da RNA - RBF dado por

$$\begin{aligned}
I_{h_1}^u &= c_{11}x_1 + c_{21}x_2 + c_{31}x_3 \\
I_{h_2}^u &= c_{12}x_1 + c_{22}x_2 + c_{32}x_3 \\
I_{h_3}^u &= c_{13}x_1 + c_{23}x_2 + c_{33}x_3 \\
I_{h_3}^u &= c_{13}x_1 + c_{23}x_2 + c_{33}x_3 \\
I_{h_5}^u &= c_{15}x_1 + c_{25}x_2 + c_{35}x_3
\end{aligned} \tag{4.39}$$

em que $x_1 = e(k)$, $x_2 = T \sum_{i=0}^k e(k)$ e $x_3 = \frac{\Delta e(k)}{T}$. Sendo que o h representa a camada oculta e u está relacionada com a RNA de controle. A saída de cada neurônio da camada oculta é dada por,

$$\begin{aligned}
O_{h_1}^u &= f_{RBF}(I_{h_1}) \\
O_{h_2}^u &= f_{RBF}(I_{h_2}) \\
O_{h_3}^u &= f_{RBF}(I_{h_3}) \\
O_{h_4}^u &= f_{RBF}(I_{h_4}) \\
O_{h_5}^u &= f_{RBF}(I_{h_5}),
\end{aligned} \tag{4.40}$$

em que f_{RBF} e b foram definidos pela Eq. (4.21) e Eq. (4.22). A entrada do neurônio na camada de saída é dado por

$$I_{O_1}^u = w_{11}f_{RBF}(I_{h_1}^u) + w_{21}f_{RBF}(I_{h_2}^u) + \dots + w_{51}f_{RBF}(I_{h_5}^u). \tag{4.41}$$

A saída da rede RBF fornece a ação de controle $u(k)$ dada por

$$u(k) = f_O(I_{O_1}^u). \tag{4.42}$$

A função da camada de saída da rede f_O tem um comportamento linear.

4.4.2 Atualização dos parâmetros da rede

A atualização dos parâmetros da rede neural RBF de controle é realizado pelo método do gradiente decrescente, dado por

$$E(k) = \frac{1}{2}[(y_d(k) - y(k))]^2. \tag{4.43}$$

Para a atualização dos pesos $w_j(k)$ da rede de controle tem-se que

$$\Delta w_j(k) = -\eta \frac{\partial E}{\partial w_j} = -\eta e(k)(y(k) - y_d(k)) \frac{\partial y(k)}{\partial u(k)} h_j \tag{4.44}$$

$$w_j(k) = w_j(k-1) + \Delta w_j(k) + \alpha \Delta w_j(k),$$

sendo η e α as taxa de aprendizagem e momento, respectivamente.

As próximas atualizações dos parâmetros b e c , são dados por

$$\begin{aligned}\Delta b_j(k) &= -\eta \frac{\partial E}{\partial b_j} = \eta e(k) \frac{\partial y(k)}{\partial u(k)} \frac{\partial u(k)}{\partial b_j} \\ \Delta b_j(k) &= \eta e(k) \frac{\partial y(k)}{\partial u(k)} w_j f_{RBF}\left(\frac{\|\mathbf{x}-c_{jn}\|^2}{b_j^2}\right)\end{aligned}\tag{4.45}$$

$$b_j(k) = b_j(k-1) + \eta \Delta b_j(k) + \dots + \alpha(b_j(k-1) - b_j(k-2))\tag{4.46}$$

Para os centros da função gaussiana tem-se que,

$$\begin{aligned}\Delta c_j(k) &= -\eta \frac{\partial E}{\partial b_j} = \eta e(k) \frac{\partial y(k)}{\partial u(k)} \frac{\partial u(k)}{\partial c_j} \\ \Delta c_j(k) &= \eta e(k) \frac{\partial y(k)}{\partial u(k)} c_j f_{RBF}\left(\frac{\|\mathbf{x}-c_{jn}\|^2}{b_j^2}\right)\end{aligned}\tag{4.47}$$

$$c_{ij}(k) = c_{ij}(k-1) + \eta \Delta c_{ij}(k) + \dots + \alpha(c_{ij}(k-1) - c_{ij}(k-2)),\tag{4.48}$$

em que $\frac{\partial y(k)}{\partial u(k)}$ é o valor jacobiano expressando a sensibilidade da saída e entrada do sistema. Este valor pode ser obtido pelo sinal de $\frac{\partial y(k)}{\partial u(k)}$.

4.5 Comentários

Apresentou-se as arquiteturas de predição em sistemas discretos baseados em RNAs. Para a saída futura do sistema foi considerado *d-step* à frente, com atualização dos pesos da rede neural preditiva. Abordou-se o mecanismo de sintonia do controlador PID baseado em uma rede neural estruturada por funções de base radiais e levando em consideração os ajustes ótimos dos pesos da rede RBF.

5 O Sistema Embarcado *SC-Tracker*

A caracterização do problema-solução que consiste na descrição da sintonia *online* e formulação do controlador PID são apresentadas neste capítulo. Aborda-se a metodologia do método de solução e desenvolvimento de algoritmos *online* via inteligência computacional.

O sistema desenvolvido, chamado de *SC-Tracker*, embarcado em microcontrolador está relacionado com a avaliação da proposta e sua implementação dos algoritmos de controle adaptativo do tipo MPC. Estes algoritmos são baseados em RNA-RBF para sintonia *online* dos parâmetros do controlador PID. O capítulo está organizado em seções que descrevem o problema do alvo móvel e a modelagem do sistema de controle para rastreamento nas Seções 5.1 e 5.2, respectivamente. Na Seção 5.3 apresenta-se os modelos de sintonia RNA-RBF desenvolvidos para realização do controle de alto desempenho. O enfoque do sistema embarcado deve-se ao algoritmo de controle para rastreamento que é apresentado na Seção 5.4.

Os experimentos computacionais e *hardware* são apresentados na Seção 5.5 que são baseados em um modelo reduzido com atuador, sensores, microcontrolador e planta. Nos experimentos computacionais o desempenho do *SC-Tracker* são mensurados com respostas ao degrau e diagrama de bode. O experimentos em *hardware* mostram os resultados da implementação *online* dos algoritmos para sintonia dos parâmetros do controle baseado em estruturas adaptativas.

5.1 O Problema do Alvo Móvel

No contexto de controle, o problema do rastreamento é constituído por dois momentos: o primeiro é a fase de detecção que representa a presença do objeto e no segundo momento consiste no posicionamento do dispositivo. A caracterização do processo permite a extração de parâmetros, tais, como constante de tempo, ganhos e estabilidade, que permitem estabelecer restrições ou especificações para o entendimento dos requisitos de controle.

Um das dificuldades em modelagem de sistemas é a impossibilidade de conhecer toda a dinâmica do sistema que se pretende trabalhar. Isto leva a obter um modelo para uma dada aplicação, devido à complexidade dos processos subjacentes ou à falta de conhecimento dos parâmetros críticos (como por exemplo, coeficientes de transferência de massa, calor, ou viscosidades dependentes da temperatura e da pressão) do modelo. Uma maneira de superar esses problemas em modelagem de processo, com alterações, é a utilização de RNA como modelo caixa preta não linear do comportamento dinâmico do

processo (SIENIUTYCZ, 2016).

5.2 Modelagem do *SC-Tracker*

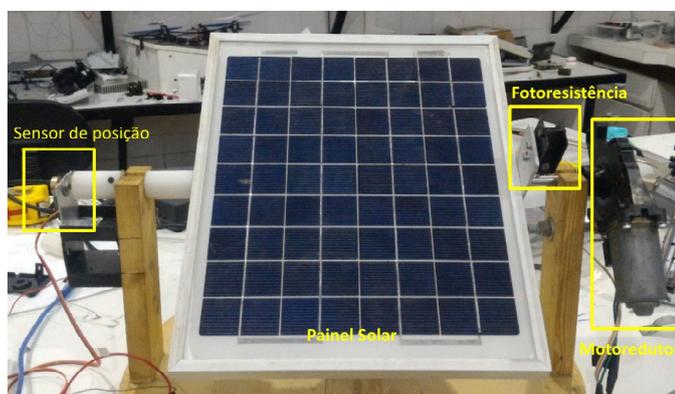
A formulação do problema do *SC-Tracker* solar envolve equações que expressam a relação entre as derivadas de uma ou mais funções desconhecidas em relação às variáveis independentes, como momento de inércia, variação do coeficiente de atrito e outras variáveis.

5.2.1 Descrição do Sistema Planta/Controle

O rastreamento da radiação solar da Figura 18 é constituído por duas estruturas baseados em componentes mecânicos e eletroeletrônicos. A primeira é responsável pelo mecanismo de transmissão do movimento.

A função de transferência do sistema é composta por atuador (motor) e processo (painel), sendo representada por $G(s)$. O momento de inércia ($J_m = 3,2 \times 10^{-6} \text{ kgm}^2$) e o coeficiente de atrito ($b_m = 5,5 \times 10^{-6}$) do motor são desprezíveis em relação ao momento de inercia ($J_p = 100 \text{ kgm}^2$) e o coeficiente de atrito ($b_m = 1$) do painel. Assim ao momento de inércia e o coeficiente de atrito do motor são adicionados o J da planta.

Figura 18 – Sistema de rastreamento.



Fonte: Elaborado pelo autor

Seguindo uma taxonomia convencional, os elementos do sistema de controle da Figura 18 são descritos como:

- Processo e Carga

Para fins de controle, o processo de rastreamento do alvo móvel (Radiação Solar) é composto por cargas distribuídas, caracterizadas como fixas e variadas. A carga fixa é a soma das forças de atrito geradas pelos mancais de deslizamento. A carga variada é composta pelo momento de inércia e reações naturais e normais.

- Sensores

O processo é constituído por dois sensores, um LDR para o rastreamento da radiação solar, cuja resistência varia conforme a radiação que incide sobre ele. Este sensor é responsável pela localização que deve satisfazer as condições especificadas para alvo móvel e tem o papel importante para referência do sistema de controle. O segundo sensor é responsável pelo correto posicionamento da painel solar, formado por um potenciômetro linear. A curva da variação de resistência é constante (linear) em relação ao ângulo de giro do eixo. A posição do painel é verificada pelo potenciômetro e enviado para o sistema de controle.

- Atuadores

O motoredutor representa o atuador que possui as seguintes características técnicas de tensão de 12 V e rotação de 75 rpm e fabricado pela BOSCH. O atuador é acoplado no eixo do painel solar e com função de movimentar o conjunto móvel, composto por eixo, painel solar e sensores.

- Unidade de Controle

A unidade controle consiste do microcontrolador ATmega328 da Atmel de 8 bits, pertencente à família AVR da Atmel. Possui uma arquitetura e conjunto de instruções básicas, particular dos grupos tinyAVR (microcontroladores ATtiny), megAVR (os ATmega) e XMEGA (os Atxmega).

5.2.2 Modelo da Planta

O rastreamento da radiação solar possui como parâmetros do motor os seguintes dados de projeto, $R_a = 4 \Omega$, $L = 2.75 \times 10^{-6} H$, $b_m = 3.5077 \times 10^{-6}$ e $K_m = 0.0274$ que foram extraídos do *datasheet* fornecido pelo *site* fabricante. Contudo, para muitos motores CC, em relação a sua modelagem para fins de controle, é desconsiderado o efeito da indutância de armadura, pois a contribuição de L é muito menor que o efeito J (FRANKLIN; POWELL; WORKMAN, 1998). Neste caso a função de transferência para análise é dada por

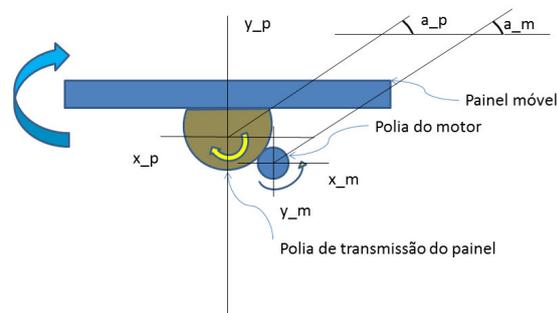
$$\frac{\Theta(s)}{V_c(s)} = \frac{10\pi K_M}{\pi s[(Ls + R)(J_p s + b_p) + K_b K_M] + 10K_M} \quad (5.1)$$

para considerações dos efeitos da indutância em relação ao momento de inércia do motor CC a nova equação é dada por

$$\frac{\Theta(s)}{V_c(s)} = \frac{10\pi K_M}{\pi[(R J_p s^2 + R b_p s) + K_b K_M s] + 10K_M}. \quad (5.2)$$

Levando em consideração a relação entre o ângulo do eixo (a_m) do motor e o ângulo do painel (a_p), é exemplificada conforme a geometria apresentada pela Figura 19. Desta forma,

Figura 19 – Modelagem matemática do painel solar



Fonte: Elaborado pelo autor

a função de transferência do sistema é dada por

$$\frac{\Theta(s)}{V_c(s)} = \frac{0.006849}{(0.0009998s^2 + s)} \quad (5.3)$$

Esta situação do sistema de controle em malha fechada é estável, não possuindo nenhum polo no semi plano s do lado direito.

5.2.3 Modelo do Controle Adaptativo Ótimo

O sistema de controle atuando no âmbito de rastreamento, desse projeto de controle, tem-se as abordagens vistas nos Capítulos 3 e 4, referentes ao controle adaptativo baseado na estruturação direta dos parâmetros do controlador. Os critérios de otimalidade são processos determinísticos estocásticos com informações, *a priori* da planta. Este critério é escolhido de maneira à encontrar o melhor ajuste para os pesos da RNA-RBF do sistema de predição e controle.

A realimentação do controle de rastreamento é tratada sobre um ponto de vista do MPC para a predição da saída futura do sistema em *um passo a frente*. O ajuste dos pesos da RNA e o mecanismo de sintonia do sistema de controle adaptativo é apresentado em detalhes no Capítulo 4.

As aplicações do sistema de controle proposto é desenvolvido a parte de diretrizes que são dadas por:

1. A modelagem do processo dinâmico, entrada e saída, em forma discreta é dada por:

$$y(k) = -a_1y(k-1) - a_ny(k-n) + \dots + b_0u(k) + b_1u(k-1) + b_mu(k-m) \quad (5.4)$$

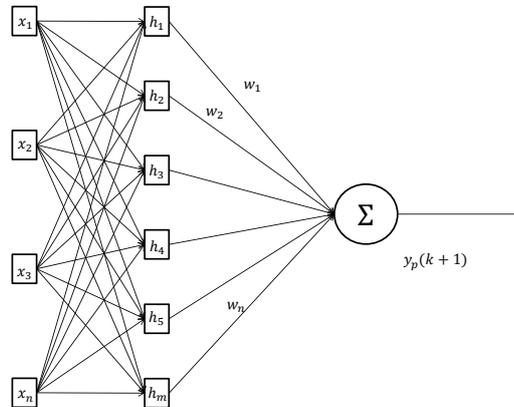
2. O controlador PID desenvolvido na forma de equações a diferença, realizável pelo método de Euler,

$$u(k) = K \left[e(k) + \frac{T_0}{T_i} \sum_{i=0}^k e(i-1) + \frac{T_d}{T_0} \Delta e(k) \right], \quad (5.5)$$

sendo definido a variação do erro $\Delta e(k)$, em que $\Delta e(k) = e(k) - e(k-1)$.

3. A rede neural baseada na RBF para a função de predição, representado na Figura 20, é dada por uma estrutura 6-5-1.

Figura 20 – Estrutura da Neural RBF Preditiva



Fonte: Elaborado pelo autor

A entrada da rede é composta por seis unidades sensoriais de maneira que as três primeiras são formadas pela entrada atual e duas atrasadas. As outras são a saída atual e duas saídas atrasadas da planta. Especificamente as entradas são representadas pelo vetor $\mathbf{x}_p = [x_1, x_2, x_3, x_4, x_5, x_6]$, que tem suas componentes dadas por

$$\begin{aligned} x_1 &= y(k) \\ x_2 &= y(k-1) \\ x_3 &= y(k-2) \\ x_4 &= u(k) \\ x_5 &= u(k-1) \\ x_6 &= u(k-2) \end{aligned} \quad (5.6)$$

4. O controlador neural preditivo baseado em RBF é contituido por uma estrutura 3-5-1. A entrada da RNA-RBF que constitui o controle é definida pelo vetor $\mathbf{x}_c = [x_1, x_2, x_3]$,

os elementos do referido vetor são expresso por

$$\begin{aligned} x_1 &= e(k) \\ x_2 &= T \sum_{i=0}^k e(k) \\ x_3 &= \frac{\Delta e(k)}{T} \end{aligned} \quad (5.7)$$

5.3 Sintonia RNA-RBF proposta

A RNA-RBF é usada para arquitetura do controlador PID neural adaptativo. A RNA é projetada com estrutura 3-5-1 baseada na RBF com sintonia *online* aplicada em uma estrutura polinomial. O controlador PID neural é desenvolvida pelo método direto, para se obter a saída por meio das entradas da RNA-RBF.

A estrutura da RNA é fundamentada na função de custo J que é dada por,

$$J = \frac{1}{2} [r(k+1) - y_p(k+1)]^2. \quad (5.8)$$

O método da descida mais íngreme é usado para ajustes dos pesos da RNA com o objetivo de atingir e tolerável (especificado pelo projeto), na forma:

$$e(k) = r(k+1) - y_p(k+1), \quad (5.9)$$

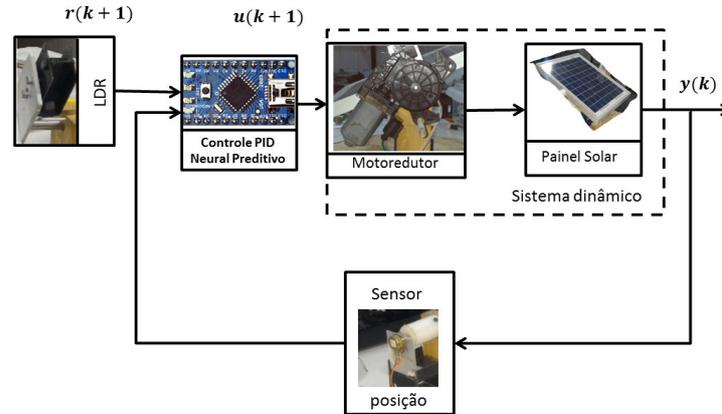
para o critério da Eq. (5.8), a saída do controlador é a atuação futura do mesmo em um passo a frente, como $u(k+1)$. O vetor de entrada da RNA-RBF é definido por

$$\begin{aligned} I_{h_1}^u &= c_{11}x_1 + c_{21}x_2 + c_{31}x_3 \\ I_{h_2}^u &= c_{12}x_1 + c_{22}x_2 + c_{32}x_3 \\ I_{h_3}^u &= c_{13}x_1 + c_{23}x_2 + c_{33}x_3, \\ I_{h_3}^u &= c_{13}x_1 + c_{23}x_2 + c_{33}x_3 \\ I_{h_5}^u &= c_{15}x_1 + c_{25}x_2 + c_{35}x_3, \end{aligned} \quad (5.10)$$

em que $I_{h_5}^u$ e u são a saída da camada oculta e o índice referente a saída do controle.

5.4 Sistema Embarcado de Controle para Rastreamento

O objetivo do controle é rastrear a variação de Radiação Solar (RS), neste caso não pelo movimento aparente da rotação do sol, mas provocada por um sistema circular de luz artificial em uma velocidade de 1 m/s . O sistema dinâmico recebe a RS pelo conjunto de sensores formado pelos LDRs e envia para a unidade de controle. A arquitetura em malha fechado do sistema MPC de rastreamento RS é representado na Figura 21. É utilizado um modelo matemático de segunda ordem do sistema de controle do processo. O controlador PID neural baseado numa RBF com uma estrutura 3-5-1 e para a rede neural preditiva é usada uma rede com estrutura 6-5-1.

Figura 21 – Arquitetura em malha fechada do *SC-Tracker* MPC

Fonte: Elaborado pelo autor

5.4.1 Algoritmos do Sistema Embarcado

O algoritmo de controle adaptativo baseia-se no modelo de previsão implementado com uma RNA-RBF a fim de otimizar os ajustes dos pesos da RNA. A próxima etapa tem o objetivo de sintonizar o controlador PID por meio dos ajustes dos pesos da RNA-RBF de controle para um error tolerável da saída do sistema de rastreamento. A otimização está relacionado no ajuste dos pesos das RNA-RBF de predição e controle do sistema. Os indicadores de desempenho da otimização variam no tempo. O pseudocódigo do sistema de controle é descrito no Algoritmo 1.

Os parâmetros do algoritmo relacionados com RNA-RBF são os raios, as constantes de aprendizado r , α e η , respectivamente. A inicialização do algoritmo consiste em estabelecer valores numéricos para estes parâmetros que possuem a sua magnitude baseado em heurísticas.

A seguir apresenta-se o mecanismo de atuação do algoritmo. Para tanto, descreve-se as interações entre as linha 2 até 31 do referido algoritmo. Este laço maior envolve cálculo da lei de controle por meio de operações, ie, instruções que são classificadas em blocos.

Nas linhas 3-5. Laço Interno 1 - Cálculo do Centroide para M_c neurônios. Nas linhas 6-7. Bloco Sequencial 1- Instrução 3 - Cálculos de $u(k)$ e $e(k)$.

Nas linhas 8-10. Laço Interno 2 - Instruções para o cálculo de $du_w(j)$. Na linha 11. Bloco Sequencial 2- Cálculo das Entradas - Instruções. Nas linhas 12-14. Laço Interno 3 - Instruções para o cálculo de $h_c(j)$.

Nas linhas 15-16. Bloco Sequencial 3- Instruções para o cálculos de $y_p(k)$ e $e(k)$ e $e_p(k)$, apresentados com maior detalhe no Capítulo 4.

Início da atualização da predição para fazer a correção dos pesos da rede. Nas

Algoritmo 1: Algoritmo-de-controle

Entrada: r, α, η
Resultado: u_p

- 1 inicialização;
- 2 **para** $k = 1$ **até** N **faça**
- 3 **para** $j = 1$ **até** M_c **faça**
- 4 $h_c(j) = \exp\left(-\frac{\|x_c - c_c(:, j)\|^2}{2 \times b^2}\right)$
- 5 **fim**
- 6 $u(k) = w_u \times h_u$;
- 7 $e(k) = r(k) - y(k)$;
- 8 **para** $j = 1$ **até** M_c **faça**
- 9 $du_w(j) = \eta \times e(k) \times h_u \times dy_u(k)$
- 10 **fim**
- 11 $w_u = w_{u_1} + du_w + \alpha * (w_{u_1} - w_{u_2})$;
- 12 **para** $j = 1$ **até** M_p **faça**
- 13 $h_c(j) = \exp\left(-\frac{\|x_p - c_p(:, j)\|^2}{2 \times b^2}\right)$
- 14 **fim**
- 15 $y_p(k) = w' * h'$;
- 16 $e_p(k) = (y(k) - y_p(k - 1))$;
- 17 **para** $j = 1$ **até** M_p **faça**
- 18 $h_p(j) = \exp\left(-\frac{\|x_p - c_p(:, j)\|^2}{2 \times b^2}\right)$ **para** $j = 1$ **até** $N_{u_{entrada}}$ **faça**
- 19 $d_c(i, j) = \eta \times e_p(k) \times w(j) \times h(j) \times (x(i) - c(i, j)) \times (b(j)^{-2})$;
- 20 **fim**
- 21 **fim**
- 22 **para** $j = 1$ **até** M_c **faça**
- 23 $h_c(j) = \exp\left(-\frac{\|x_c - c_c(:, j)\|^2}{2 \times b^2}\right)$
- 24 **fim**
- 25 $u(k) = w_u \times h_u$;
- 26 $e(k) = r(k) - y(k)$;
- 27 **para** $j = 1$ **até** M_c **faça**
- 28 $du_w(j) = \eta \times e(k) \times h_u(j) \times dy_u(k)$
- 29 **fim**
- 30 $w_u = w_{u_1} + du_w + \alpha \times (w_{u_1} - w_{u_2})$;
- 31 $yp_1 = yp(k)$;
- 32 **fim**

linhas 17-21. Laço Interno 3 - Instruções para o cálculo de $h_p(j)$. Nas linhas 18-5. Laço Interno 3a - Instruções para o cálculo de $d_c(i, j)$ que é interno ao laço para o cálculo $h_c(j)$.

Nas linhas 22-31, tem-se o início das instruções para o controle RBF. Nas linhas 22-24. Laço Interno 4 - Instruções para o cálculo de $h_c(j)$.

Nas linhas 25-26. Bloco Sequencial 4- Instruções para o cálculos de $u(k)$ e $e(k)$. Nas linhas 26-27. Laço Interno 5- Instruções para o cálculo de $du_w(j)$. Bloco Sequencial 5-

Instruções para o cálculo de w_u e $e(k)$ para armazenamento da saída yp_1 .

5.5 Experimentos Computacionais e Hardware

A validação do sistema de controle proposto é realizada de duas maneiras por meio de experimentos computacionais e *hardware*. O primeiro experimento é desenvolvido para avaliar o desempenho da sintonia *online* em atingir o objetivo de controle, tais como: valor de pico, tempo de acomodação, erro de regime e etc. A segunda experimento avalia a realizabilidade do projeto em sistemas embarcados de controle via sintonia *online*.

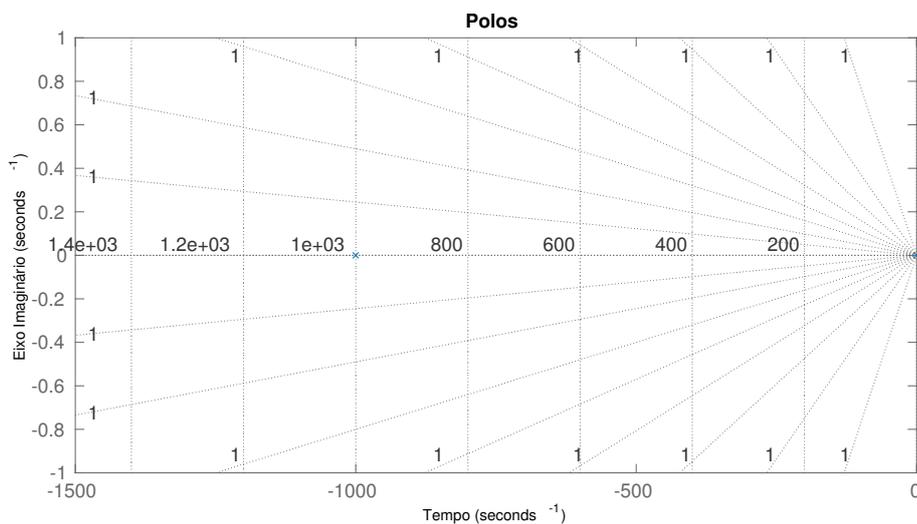
5.5.1 Experimentos Computacionais

Os experimentos computacionais apresentam resultados do controlador PID clássico e do controlador proposto.

1. Controlador PID clássico

A função de transferência do sistema no domínio da frequência tem-se a análise em relação ao polos e zeros, em malha fechada, de maneira que a seguinte representação gráfica mostrada na Figura 22. O sistema possui um par de polos complexos. Não

Figura 22 – Representação dos Polos e Zeros

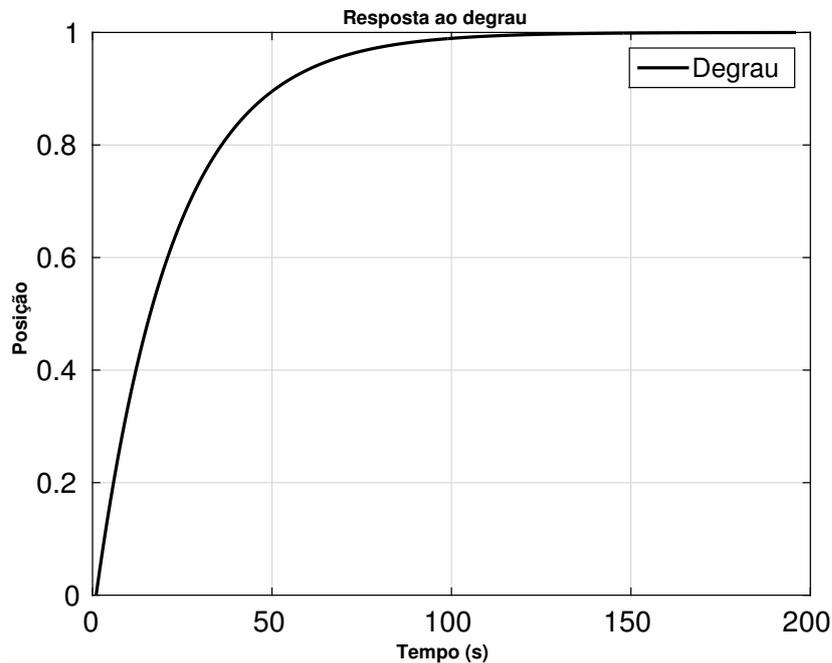


Fonte: Elaborado pelo Autor

há nenhum polo no lado do semi plano direito.

A Figura 23 representa uma entrada degrau para análise do sistema, sem controle, em relação a sua robustez em relação ao estado inicial, após uma perturbação.

Figura 23 – Resposta ao degrau com sistema sem controle.



Fonte: Elaborado pelo autor

Tabela 1 – Comportamento do sistema em relação ao ID

Parâmetros	Figuras de Mérito sem SC-PID	
Tempo de subida	t_r	320.79
Tempo de acomodação	t_a	571.21
<i>Overshoot</i>	M_p	0
Tempo do pico	t_p	1.54e+03

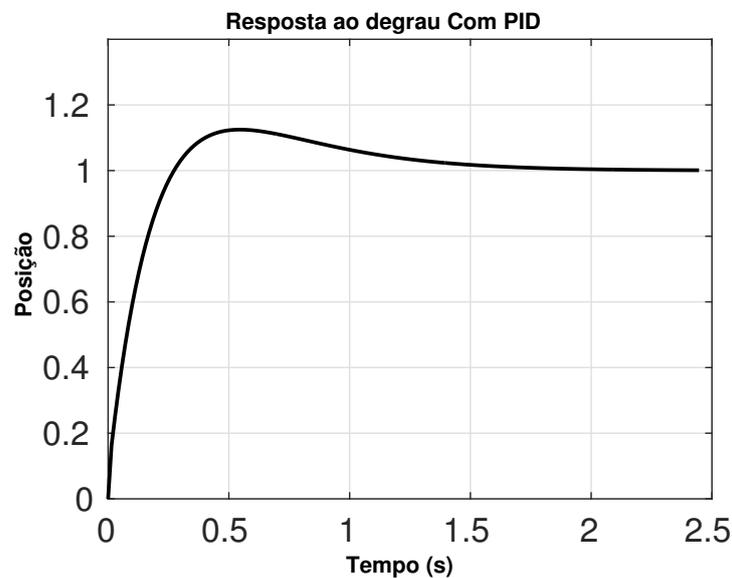
Para o comportamento do sistema solar, sem a aplicação do controle, tem-se o Índice de Desempenho (ID) mostrado na Tabela 1.

Em relação ao comportamento do sistema com o controlador PID clássico sintonizado pelo método proposto por Ziegler e Nichols (1942). O sistema tem como resposta ao degrau o sinal de saída mostrado na Figura 24 e resumido os parâmetros do controlador PID na Tabela 2. E o índice de desempenho do sistema de controle é mostrado na Tabela 3.

Em relação ao comportamento do sistema aplicada o método de sintonia do controlador PID proposto por Ziegler e Nichols (1942), tem-se como resposta ao degrau o sinal de saída mostrado na Figura 24 e os parâmetros do controlador PID resumido na Tabela 2. O índice de desempenho do sistema de controle é mostrado na Tabela 3.

De forma que o índice de desempenho do sistema com o controle PID é resumido na

Figura 24 – Resposta ao degrau com PID.



Fonte: Elaborado pelo autor.

Tabela 2 – Valores dos parâmetros do controlador PID

Parâmetros do Controlador		
K_p	K_i	K_d
1156.464	2094.16	11.87

Tabela 3 – Comportamento do sistema em relação aos IDs com controle

Parâmetros	Figuras de Mérito com SC-PID	
Tempo de subida	t_r	0.2008
Tempo de acomodação	t_a	1.4524
<i>Overshoot</i>	M_p	14.48
Tempo do pico	t_p	0.5405

Tabela 3.

2. Controlador PID-RBF Adaptativo

O controlador PID-RBF Adaptativo é composto por duas partes. A primeira é responsável pela predição da saída do sistema. Este recebe o sinal de controle aplicado no atuador (motorreductor) e a leitura da posição do painel (Potenciômetro). Os dados são enviados para RNA-RBF que inicializa os parâmetros internos da rede. Na Figura 25 verifica-se a predição da saída do sistema em *um passo à frente*. A segunda parte é responsável pela sintonia do controlador PID que em conjunto com a primeira representa uma característica do controle preditivo baseado em MPC.

a) Predição da saída do sistema

A predição da saída do processo é baseado em uma rede RBF com treinamento *online*. A entrada da rede é composta por seis unidades sensoriais. Representadas por

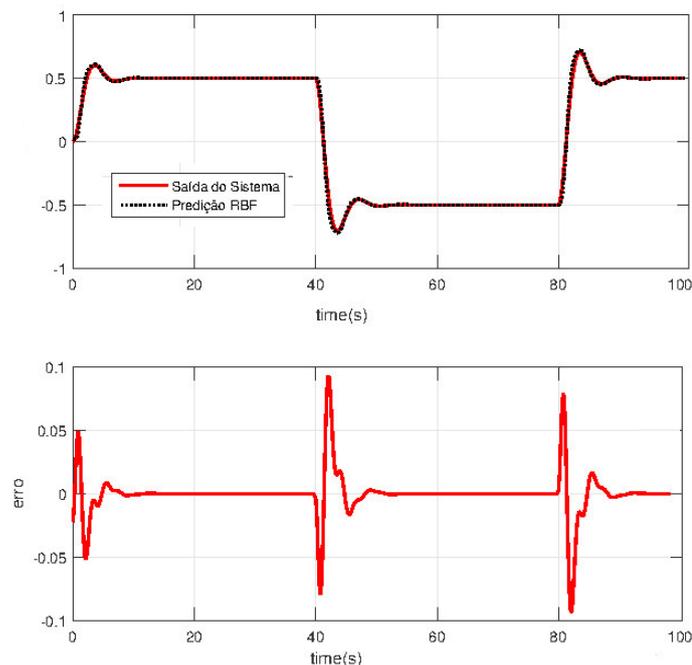
$$y_p(k+1) = f(y(k), y(k-1), y(k-2), \dots, u(k), u(k-1) + u(k-2)) \quad (5.11)$$

Para a predição da saída do processo no instante de $(k+1)$ é adquirida utilizando a RNA-RBF com uma estrutura 6-5-1.

O esquema do mecanismo de predição neural é mostrado pela Figura 16. Pode-se verificar o bloco do mecanismo de predição formado por uma RNA baseada em RBF. O bloco fornece a saída futura da planta em um passo à frente.

A Figura 25 fornece o erro da predição de um passo à frente da saída do processo em relação à saída atual. Compare-se a saída real com a predita pelo sistema, de maneira que se obtêm um bom sinal de predição para o processo de rastreamento da radiação solar.

Figura 25 – Sinal de predição do sistema de rastreamento.

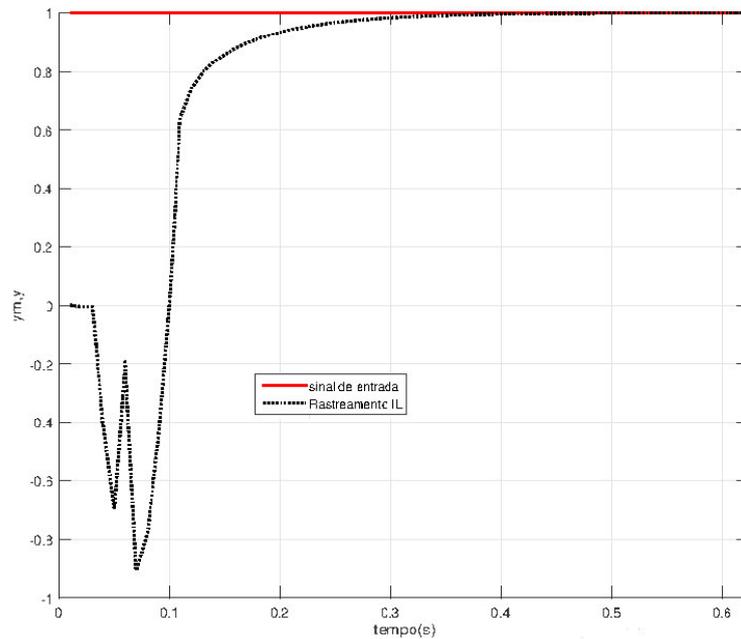


Fonte: Elaborado pelo autor.

b) Controlador PID-RBF Adaptativo

O controle PID-RBF Adaptativo possui uma estrutura 3-5-1 e a função de custo J é descrita na Eq. (5.8). Na entrada da rede é realizada uma combinação linear em função do erro, descrito em detalhe na Seção 5.3.

Figura 26 – Resposta ao degrau unitário - sistema simulado.



Fonte: Elaborado pelo autor.

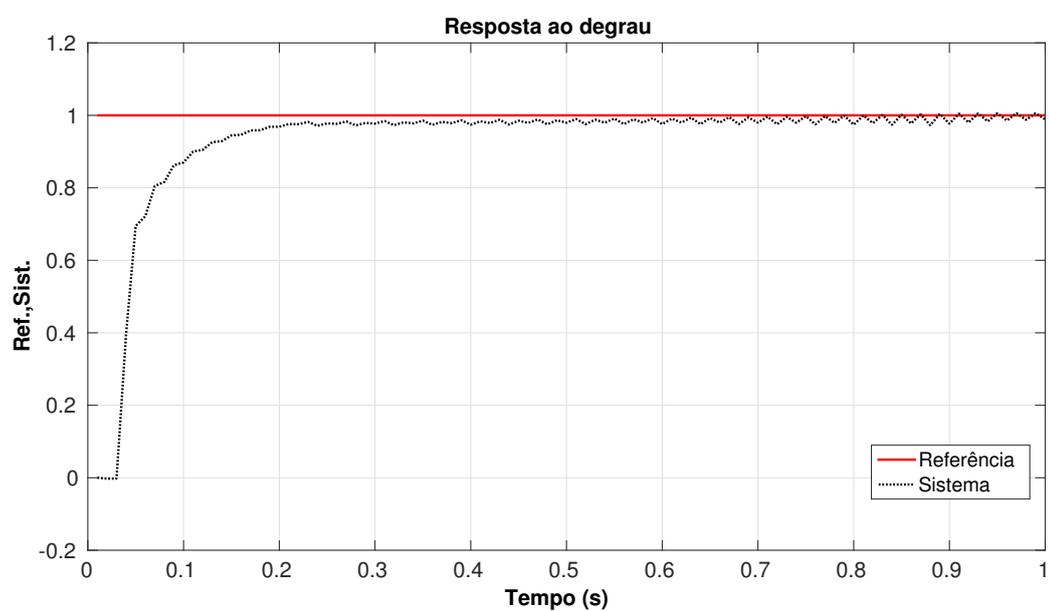
5.5.2 Experimentos em Hardware

O desempenho do sistema de controle é avaliado para rastreamento. Nos testes de validação a fonte de alimentação do motorreductor é limitado com uma tensão de -12V à 12V. Na Figura 27 mostra o sinal da posição do sistema de controle proposto, juntamente com o valor de referência. O sistema está com uma faixa de operação de ângulo de rastreamento de 0 à 300°, sendo que a tensão obtida no potenciômetro varia entre 0 e 3,57 V e nominal de 0 à 5 V.

5.6 Comentários

O problema do rastreamento da Radiação Solar (RS), a dificuldade quanto à modelagem e a impossibilidade de conhecer toda sua dinâmica foram apresentados neste capítulo. O sistema foi descrito para uma melhor compreensão do mecanismo de controle em uma sequência lógica para desenvolvimento do algoritmo final de controle. Apresentou-se as estruturas das RNAs baseadas em RBF e mecanismo de ajustes dos pesos, da mesma forma, abordou-se a estrutura do PID adaptativo. Por fim, explanou-se os experimentos computacionais e de hardware com seus respectivos resultados associados com gráficos e tabelas.

Figura 27 – Resposta ao degrau unitário - sistema real.



Fonte: Elaborado pelo autor.

6 Conclusão

Na conclusão apresenta-se comentários gerais da dissertação juntamente com suas principais contribuições. Ainda, cita-se sugestões para desenvolvimentos futuros, novas estruturas de controle adaptativo e aplicações da metodologia para o projeto *online* de sistemas de controle do tipo MPC, enfatizando os métodos para sintonia de parâmetros de controladores e preditores desenvolvido pela pesquisa.

6.1 Conclusões Gerais

Apresentou-se nesta dissertação o problema e estudo do desenvolvimento da sintonia do controlador PID, ao longo de sua trajetória na indústria. Fez-se a organização das estruturas do controle adaptativo via RNA-RBF com uma abordagem *online* de ajustes dos pesos da rede. Desenvolveu-se o *SC-Tracker* para rastreamento da radiação solar que apresentou bons resultados em campo. Demonstrou-se um novo método para atender novas demandas tecnológicas que exigem a ação de sistemas de alto desempenho operacional. O método proposto possui características de adaptabilidade representado pelo controle adaptativo. A otimalidade está fundamentada na otimização dos parâmetros da RNA-RBF preditiva e sintonização do controle PID de forma *online* para o sistema de posicionamento. Os experimentos em *hardware* mostrou-se melhores em relação ao experimentos computacionais, pois o primeiro se adaptou rapidamente com as incertezas reais da planta. Esta melhora é justificada pela característica da RNA - RBF em realizar sintonia *online* em seus parâmetros livres do *SC-Tracker*.

6.2 Contribuições

As principais contribuições desta dissertação estão em torno dos seguintes contextos:

- Desenvolvimento de uma metodologia para o projeto online de controladores de alto desempenho que baseia-se nas abordagens de controle adaptativo do tipo Model Predictive Control (MPC) e redes neurais do tipo Radial Basis Function (RBF).
- Criação de metodologia para implementação do algoritmo *SC-Tracker* (controlador e estimador) em microcontroladores.
- Desenvolvimento de uma plataforma para avaliação de algoritmos para captura e posicionamento na referência *tracker-target*.

6.3 Trabalhos Futuros

Como trabalhos futuros, enumera-se os seguintes tópicos em controle e sistemas embarcados que são:

- Aplicar o *SC-Tracker* em sistema de geração de calor e processos compostos por sistemas MIMO.
- Desenvolver outras estruturas de controle adaptativo, tais como GPC e GMV. Estes controladores estão presentes nos processos industriais e combinados com outros sistemas de controles.
- Avaliar a complexidade computacional dos núcleos de controle e estimadores para aplicações e desenvolver métricas para avaliar o desempenho dos referidos algoritmos.

Referências

AGUIRRE, L. A. *Introdução à identificação de sistemas—Técnicas lineares e não-lineares aplicadas a sistemas reais*. [S.l.]: Editora UFMG, 2004. Citado na página 85.

ANILKUMAR, M.; PADHIYAR, N.; MOUDGALYA, K. Lexicographic optimization based mpc: Simulation and experimental study. *Computers & Chemical Engineering*, v. 88, p. 135 – 144, 2016. ISSN 0098-1354. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0098135416300217>>. Citado na página 56.

ARAHAL, M.; BERENGUEL, M.; CAMACHO, E. Neural identification applied to predictive control of a solar plant. *Control Engineering Practice*, Elsevier, v. 6, n. 3, p. 333–344, 1998. Citado na página 31.

ARINTON, E.; CARAMAN, S.; KORBICZ, J. Neural networks for modelling and fault detection of the inter-stand strip tension of a cold tandem mill. *Control Engineering Practice*, Elsevier, v. 20, n. 7, p. 684–694, 2012. Citado na página 31.

Artificial Intelligence Tutorial. *Introducing the Neuron*. 2017. Access date: 1 fev. 2017. Disponível em: <https://www.tutorialspoint.com/artificial_intelligence/artificial_intelligence_neural_networks.htm>. Citado na página 92.

ÅSTRÖM, K. J.; HÄGGLUND, T. *Advanced PID control*. [S.l.]: ISA-The Instrumentation, Systems, and Automation Society; Research Triangle Park, NC 27709, 2006. Citado na página 28.

ÅSTRÖM, K. J.; WITTENMARK, B. *Adaptive control*. [S.l.]: Courier Corporation, 2013. Citado 3 vezes nas páginas 26, 28 e 32.

ÅSTRÖM, K. J.; WITTENMARK, B. *Computer-controlled systems: theory and design*. [S.l.]: Courier Corporation, 2013. Citado na página 24.

ATHANASIOS, P. *Probability, random variables, and stochastic processes*. McGraw-Hill, 2017. Citado na página 51.

BEVRANI, H. *Robust power system frequency control*. [S.l.]: Springer, 2009. v. 85. Citado na página 17.

BINGUL, Z. A new pid tuning technique using differential evolution for unstable and integrating processes with time delay. In: SPRINGER. *Neural Information Processing*. [S.l.], 2004. p. 254–260. Citado na página 27.

boundless.com. *Introducing the Neuron*. 2017. Access date: 1 fev. 2017. Disponível em: <<https://www.boundless.com/psychology/textbooks/boundless-psychology-textbook/biological-foundations-of-psychology-3/neurons-33/introducing-the-neuron-141-12676/>>. Citado na página 91.

BOX, G. E. et al. *Time series analysis: forecasting and control*. [S.l.]: John Wiley & Sons, 2015. Citado 2 vezes nas páginas 50 e 51.

- BROWN, A. G. *Nerve cells and nervous systems: An introduction to neuroscience*. [S.l.]: Springer Science & Business Media, 2012. Citado 2 vezes nas páginas 45 e 92.
- CAMACHO, E.; BORDONS, C. *Model predictive control*. [S.l.]: Springer Verlag, Berlin, Germany, 2004. Citado na página 29.
- CAMACHO, E. F.; ALBA, C. B. *Model predictive control*. [S.l.]: Springer Science & Business Media, 2013. Citado 2 vezes nas páginas 40 e 41.
- CAMACHO, E. F.; BORDONS, C. *Model predictive control in the process industry*. [S.l.]: Springer Science & Business Media, 2012. Citado 3 vezes nas páginas 29, 42 e 43.
- CHAN, L. L. T.; CHEN, T.; CHEN, J. {PID} based nonlinear processes control model uncertainty improvement by using gaussian process model. *Journal of Process Control*, v. 42, p. 77 – 89, 2016. ISSN 0959-1524. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0959152416300142>>. Citado 2 vezes nas páginas 28 e 59.
- CHEN, Y. et al. Indirect model reference adaptive control for a class of fractional order systems. *Communications in Nonlinear Science and Numerical Simulation*, v. 39, p. 458 – 471, 2016. ISSN 1007-5704. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1007570416300880>>. Citado na página 29.
- CHRISTOFIDES, P. D. et al. Distributed model predictive control: A tutorial review and future research directions. *Computers & Chemical Engineering*, v. 51, p. 21 – 41, 2013. ISSN 0098-1354. {CPC} {VIII}. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0098135412001573>>. Citado na página 30.
- CHRISTOFIDES, P. D. et al. Distributed model predictive control: A tutorial review and future research directions. *Computers & Chemical Engineering*, Elsevier, v. 51, p. 21–41, 2013. Citado na página 50.
- COVER, T. M. Geometrical and statistical properties of systems of linear inequalities with applications in pattern recognition. *IEEE transactions on electronic computers*, IEEE, n. 3, p. 326–334, 1965. Citado na página 46.
- CUTLER, C. R.; RAMAKER, B. L. Dynamic matrix control?? a computer control algorithm. In: *joint automatic control conference*. [S.l.: s.n.], 1980. p. 72. Citado na página 30.
- ENDER, D. B. Process control performance: Not as good as you think. *Control Engineering*, v. 40, n. 10, p. 180–190, 1993. Citado na página 59.
- FINDEISEN, R.; ALLGÖWER, F. An introduction to nonlinear model predictive control. v. 11, p. 119–141, 2002. Citado na página 29.
- FRANKLIN, G. F.; POWELL, J. D.; WORKMAN, M. L. *Digital control of dynamic systems*. [S.l.]: Addison-wesley Menlo Park, 1998. v. 3. Citado na página 65.
- GARCIA, C. E.; PRETT, D. M.; MORARI, M. Model predictive control: theory and practice a survey. *Automatica*, Elsevier, v. 25, n. 3, p. 335–348, 1989. Citado na página 29.

GARPINGER, O.; HÄGGLUND, T.; ÅSTRÖM, K. J. Performance and robustness trade-offs in pid control. *Journal of Process Control*, Elsevier, v. 24, n. 5, p. 568–577, 2014. Citado na página 29.

GRAF, U. *Applied Laplace transforms and z-transforms for scientists and engineers: a computational approach using a Mathematica package*. [S.l.]: Birkhäuser, 2012. Citado na página 23.

GRAICHEN, K.; KUGI, A. Stability and incremental improvement of suboptimal mpc without terminal constraints. *IEEE Transactions on Automatic Control*, IEEE, v. 55, n. 11, p. 2576–2580, 2010. Citado na página 30.

GRIMHOLT, C.; SKOGESTAD, S. Optimal pid control of double integrating processes. *IFAC-PapersOnLine*, Elsevier, v. 49, n. 7, p. 127–132, 2016. Citado na página 22.

HÄGGLUND, T.; ÅSTRÖM, K. J. Revisiting the ziegler-nichols tuning rules for pi control—part ii: the frequency response method. *Asian journal of control*, Chinese Automatic Control Society., v. 6, n. 4, p. 469–482, 2004. Citado na página 28.

HAN, M.; KONG, X.; LIU, X. Distributed mpc of the standalone hybrid wind and solar generation system based on neural network modeling. In: IEEE. *Intelligent Control and Automation (WCICA), 2016 12th World Congress on*. [S.l.], 2016. p. 2738–2742. Citado na página 41.

HAYKIN, S. S. et al. *Neural networks and learning machines*. [S.l.]: Pearson Upper Saddle River, NJ, USA:, 2009. v. 3. Citado 6 vezes nas páginas 45, 93, 94, 96, 100 e 101.

HENRIQUES, J. et al. Adaptive neural output regulation control of a solar power plant. *Control Engineering Practice*, Elsevier, v. 18, n. 10, p. 1183–1196, 2010. Citado na página 31.

HERREROS, A.; BAEYENS, E.; PERÁN, J. R. Design of pid-type controllers using multiobjective genetic algorithms. *ISA Transactions*, v. 41, n. 4, p. 457 – 472, 2002. ISSN 0019-0578. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0019057807601025>>. Citado na página 27.

HUNT, K. J. et al. Neural networks for control systems—a survey. *Automatica*, Elsevier, v. 28, n. 6, p. 1083–1112, 1992. Citado na página 56.

IOANNOU, P.; FIDAN, B. *Adaptive control tutorial*. [S.l.]: Society for Industrial and Applied Mathematics, 2006. (Advances in design and control). ISBN 9780898716153,0898716152. Citado na página 37.

ISERMANN, R. *Digital control systems*. [S.l.]: Springer Science & Business Media, 2013. Citado na página 26.

KAY, S. M. *Fundamentals of statistical signal processing: Practical algorithm development*. [S.l.]: Pearson Education, 2013. v. 3. Citado na página 50.

KILLIAN, M. et al. Cooperative fuzzy model-predictive control. *IEEE Transactions on Fuzzy Systems*, IEEE, v. 24, n. 2, p. 471–482, 2016. Citado na página 41.

- KRAMER, A.; SANGIOVANNI-VINCENTELLI, A. *Efficient parallel learning algorithms for neural networks Advances in Neural Information Processing Systems*. [S.l.]: San Francisco, CA: Morgan Kaufmann Publishers Inc.) ISBN, 1989. Citado na página 101.
- KWON, W. H.; HAN, S. H. *Receding horizon control: model predictive control for state models*. [S.l.]: Springer Science & Business Media, 2006. Citado na página 44.
- LANDAU, I. D. et al. Introduction to adaptive and robust active vibration control. In: *Adaptive and Robust Active Vibration Control*. [S.l.]: Springer, 2017. p. 3–17. Citado na página 32.
- LANDAU, I. D. et al. *Adaptive control: algorithms, analysis and applications*. [S.l.]: Springer Science & Business Media, 2011. Citado 6 vezes nas páginas 28, 29, 36, 37, 38 e 39.
- LANDAU, I. D.; ZITO, G. *Digital control systems: design, identification and implementation*. [S.l.]: Springer Science & Business Media, 2005. Citado 2 vezes nas páginas 26 e 88.
- LANDAU, Y. D. Adaptive control: The model reference approach. *IEEE Transactions on Systems, Man, and Cybernetics*, IEEE, n. 1, p. 169–170, 1984. Citado na página 39.
- ŁAWRYŃCZUK, M. *Computationally efficient model predictive control algorithms*. [S.l.]: Springer, 2014. v. 3. Citado na página 30.
- LEE, J. et al. A constrained consensus problem using mpc. *International Journal of Control, Automation and Systems*, Springer, v. 9, n. 5, p. 952–957, 2011. Citado na página 30.
- LEE, J. H. Model predictive control: Review of the three decades of development. *International Journal of Control, Automation and Systems*, Springer, v. 9, n. 3, p. 415–424, 2011. Citado na página 30.
- MACIEJOWSKI, J. M. *Predictive control: with constraints*. [S.l.]: Pearson education, 2002. Citado na página 30.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, Springer, v. 5, n. 4, p. 115–133, 1943. Citado 2 vezes nas páginas 45 e 98.
- MOHAMMADIAN, M. *Computational intelligence in control*. [S.l.]: IGI Global, 2002. Citado na página 30.
- NARENDRA, K. S.; ANNASWAMY, A. M. *Stable adaptive systems*. [S.l.]: Courier Corporation, 2012. Citado na página 19.
- NARENDRA, K. S.; PARTHASARATHY, K. Identification and control of dynamical systems using neural networks. *IEEE Transactions on neural networks*, IEEE, v. 1, n. 1, p. 4–27, 1990. Citado 3 vezes nas páginas 31, 47 e 56.
- O'DWYER, A. *Handbook of PI and PID controller tuning rules*. [S.l.]: World Scientific, 2009. Citado 2 vezes nas páginas 19 e 22.

- PAPAIOANNOU, I. V.; ROUSSAKI, I. G.; ANAGNOSTOU, M. E. Comparing the performance of mlp and rbf neural networks employed by negotiating intelligent agents. In: IEEE COMPUTER SOCIETY. *Proceedings of the IEEE/WIC/ACM international conference on Intelligent Agent Technology*. [S.l.], 2006. p. 602–612. Citado na página 19.
- PARK, J.; SANDBERG, I. W. Universal approximation using radial-basis-function networks. *Neural computation*, MIT Press, v. 3, n. 2, p. 246–257, 1991. Citado na página 47.
- PHAM, D.; LIU, X. Neural networks for identification, prediction and control. 1995. Citado na página 101.
- POULARIKAS, A. D. *Transforms and applications handbook*. [S.l.]: CRC press, 2010. Citado na página 23.
- QIN, S.; BADGWELL, T. A. A survey of industrial model predictive control technology. *Control Engineering Practice*, v. 11, n. 7, p. 733 – 764, 2003. ISSN 0967-0661. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0967066102001867>>. Citado na página 30.
- QIN, S. J.; BADGWELL, T. A. An overview of industrial model predictive control technology. v. 93, n. 316, p. 232–256, 1997. Citado na página 29.
- ROSENBLATT, F. Principles of neurodynamics. Spartan Book, 1962. Citado na página 98.
- ROVITHAKIS, G. A.; CHRISTODOULOU, M. A. *Adaptive control with recurrent high-order neural networks: theory and industrial applications*. [S.l.]: Springer Science & Business Media, 2012. Citado 2 vezes nas páginas 31 e 32.
- SASTRY, P.; SANTHARAM, G.; UNNIKRISHNAN, K. Memory neuron networks for identification and control of dynamical systems. *IEEE Transactions on Neural Networks*, IEEE, v. 5, n. 2, p. 306–319, 1994. Citado na página 31.
- SEBORG, D. E. et al. *Process dynamics and control*. [S.l.]: John Wiley & Sons, 2010. Citado na página 29.
- SIENIUTYCZ, S. *Thermodynamic Approaches in Engineering Systems*. 1. ed. Elsevier, 2016. ISBN 012805462X,978-0-12-805462-8,9780128093399,0128093390. Disponível em: <<http://gen.lib.rus.ec/book/index.php?md5=DC1F55C7D65D07A6B6B2B959BADBDFC7>>. Citado na página 64.
- SOLIHIN, M. I.; TACK, L. F.; KEAN, M. L. Tuning of pid controller using particle swarm optimization (pso). *International Journal on Advanced Science, Engineering and Information Technology*, v. 1, n. 4, p. 458–461, 2011. Citado na página 27.
- SOUZA, A. M.; SOARES, F. M. *Neural network programming with Java*. [S.l.]: Packt Publishing Ltd, 2016. Citado 4 vezes nas páginas 45, 92, 94 e 101.
- ÅSTRÖM, K. J.; ALBERTOS, P.; QUEVEDO, J. {PID} control. *Control Engineering Practice*, v. 9, n. 11, p. 1159 – 1161, 2001. ISSN 0967-0661. {PID} Control. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0967066101000612>>. Citado 2 vezes nas páginas 22 e 27.

- TSYPKIN, Y. Z.; NIKOLIC, Z. J. *Adaptation and learning in automatic systems*. [S.l.]: Academic Press New York, 1971. v. 73. Citado 2 vezes nas páginas 28 e 29.
- VALENCIA-PALOMO, G.; ROSSITER, J. Efficient suboptimal parametric solutions to predictive control for plc applications. *Control Engineering Practice*, Elsevier, v. 19, n. 7, p. 732–743, 2011. Citado na página 30.
- VINTER, R. *Optimal control*. [S.l.]: Springer Science & Business Media, 2010. Citado na página 17.
- WIENER, E. N. *Interpolation, and Smoothing of Stationary Time Series with Engineering Applications*. [S.l.]: Wiley, New York, 1950. Citado na página 50.
- WILLS, A. G.; HEATH, W. P. Application of barrier function based model predictive control to an edible oil refining process. *Journal of Process Control*, Elsevier, v. 15, n. 2, p. 183–200, 2005. Citado na página 30.
- YAGHOOBI, S.; MOJALLALI, H. Tuning of a {PID} controller using improved chaotic krill herd algorithm. *Optik - International Journal for Light and Electron Optics*, v. 127, n. 11, p. 4803 – 4807, 2016. ISSN 0030-4026. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0030402616001042>>. Citado na página 27.
- YU, C.-C. *Autotuning of PID controllers: A relay feedback approach*. [S.l.]: Springer Science & Business Media, 2006. Citado na página 22.
- ZHANG, H.; SHI, Y.; LIU, M. H infinity step tracking control for networked discrete-time nonlinear systems with integral and predictive actions. *Industrial Informatics, IEEE Transactions on*, IEEE, v. 9, n. 1, p. 337–345, 2013. Citado na página 28.
- ZHANG, H.; SHI, Y.; MEHR, A. S. Robust static output feedback control and remote pid design for networked motor systems. *Industrial Electronics, IEEE Transactions on*, IEEE, v. 58, n. 12, p. 5396–5405, 2011. Citado na página 28.
- ZIEGLER, J. G.; NICHOLS, N. B. Optimum settings for automatic controllers. *trans. ASME*, v. 64, n. 11, 1942. Citado 3 vezes nas páginas 22, 28 e 72.

A Conceitos de Modelagem e Controladores PID

No intuito de fornecer um melhor apoio para as explicações dos capítulos desta dissertação foram conceituados os assuntos como modelagem de sistemas dinâmicos, controladores PID em tempo contínuo e discreto. Nesta dissertação, o termo analógico refere-se aos aspectos das implementação em sistemas de tempo contínuo. No ponto de vista teórico dos objetos em estudo, tais como: planta e controlador. Faz-se no decorrer do apêndice uma conexão entre sistemas analógicos e digitais por meio da discretização de sistemas em tempo contínuo. De forma resumida, discute-se a conversão analógica para digital, por meio da qual os sinais se tornam compatíveis com sistemas. Aborda-se as considerações referentes ao controlador PID com uma introdução em sistema de malha fechada.

A.1 Modelagem de Sistemas Dinâmicos

A concepção de algoritmos sofisticados de controle e bem sintonizados pressupõe o conhecimento de modelos dos processos em que se deseja aplicar. Os requisitos para o sistema de controle esperado, em diferentes campos de aplicação, não são idênticos devido às diferenças nos processos envolvidos. Para vários tipos de processos tem-se uma abordagem diferenciada, em relação às variáveis envolvidas, por exemplo, nos processos mecânicos e aeroespacial, embora a estabilidade seja um problema, a não linearidade e os atrasos de tempo não são significativos em relação aos processos da indústria química.

O controle analógico e digital são as duas classes existentes na técnica de projeto. Como existe um grande número de sistemas no mundo real que são descritos por equações diferenciais, as técnicas para projeto de controladores analógicos tornaram-se populares, pois a maioria são embarcados de forma digital, que é bastante popular. Embora seja possível discretizar os controladores analógicos para obtê-los de forma digitais.

Uma revisão das técnicas de modelagem em sistemas não-lineares são abordados em Aguirre (2004). Sendo que as três classes de sistemas, entrada e saída, são os modelos paramétricos, não-paramétricos e semi-paramétricos.

Os alicerces básico por trás das abordagens da modelagem não é estimar o que já é conhecido, mas utilizar o conhecimento prévio sobre a física do sistema ao selecionar um modelo.

As RNAs, especialmente as redes recorrentes, podem ser empregadas como estima-

dores de todas as classes dos modelos citados acima. Estreitamente relaciona-se com os conceitos das técnicas da modelagem de caixa branca, caixa cinza e caixa preta.

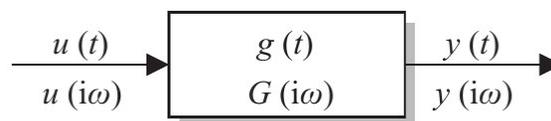
Devido às suposições simplificadoras e ao conhecimento impreciso dos parâmetros de processo, é preciso validar com periodicidade um modelo teoricamente derivado, com experiências conduzidas em um processo real. Para um modelo linear dado na forma de uma função transferência, a medição da resposta à frequência fornece uma boa ferramenta para sua validação. Uma dessas ferramentas é o diagrama de Bode que fornece uma representação transparente da dinâmica do processo, tais como ressonâncias, tempo de atraso e a ordem do modelo. A principal vantagem da resposta em frequência é o fato de não serem realizadas suposições sobre a estrutura do modelo. E em contrapartida a sua desvantagem é que ao longo tempo de medição, especialmente, para processos com longos tempos de sedimentação se necessita da suposição de linearidade.

Em caso de distúrbios leves, também pode ser suficiente para comparar as respostas ao degrau do processo e modelo. Na presença de distúrbios mais graves, entretanto, é preciso recorrer à métodos de correlação ou de estimação paramétrica de modelos em tempo contínuo.

A.1.1 Modelo matemáticos de sistemas em tempo contínuo

Modelos matemáticos de processos podem ser paramétricos ou não-paramétricos. Os modelos não-paramétricos representam a relação entre a entrada e saída por meio de uma tabela ou curva, Figura 28. Eles não exibem uma certa estrutura, possuem uma dimensão infinita e estabelecem a base para o método de identificação, conhecido por caixa-preta. Os modelos não-paramétricos mais proeminentes de processos lineares invariantes no tempo são fundamentados em resposta ao impulso, resposta ao degrau e à frequência.

Figura 28 – Processo dinâmico com entrada u e saída y .



Fonte: Elaborado pelo autor

Os modelos paramétricos representam a relação entre a entrada e saída por meio de equações. Em geral, eles contêm um número finito de parâmetros explícitos. Estas equações podem ser estabelecidas pela aplicação de técnicas de modelagem. Por meio da formulação das equações de equilíbrio para sistemas físicos ou químicos, de equações de estados e fenomenológicas, constrói-se um sistema de expressões que contém os parâmetros

físicos, que são chamados de coeficientes do processo. Este sistema de equações expõe a estrutura elementar do modelo e pode ser representado por meio do diagrama de blocos detalhado. Modelos que exibem uma estrutura elementar são chamados de modelos caixa branca, os não-paramétricos são os caixa preta.

Para as equações diferenciais o comportamento da entrada e saída do processo é de interesse, então os estados do sistema serão eliminados (se possível). O modelo matemático resultante assume a forma de uma Equação Diferencial Ordinária (EDO) para um sistema de parâmetros agrupados. No caso linear a EDO é dada por

$$y^n(t) + a_{n-1}\dot{y}(t) + \dots + a_1\dot{y}(t) + a_0y(t) = b_m u^m(t) + b_{m-1}u^{m-1}(t) + \dots + b_1\dot{u}(t) + b_0u(t), \quad (\text{A.1})$$

em que os parâmetros do modelo a_i e b_i são determinados pelos coeficientes do processo c_i . Durante a transição do processo físico, para o modelo de entrada/saída, a estrutura subjacente pode ser perdida. Para processos com parâmetros distribuídos, pode-se obter Equações Diferenciais Parciais (EDP) semelhantes. Já em relação a função transferência e a resposta à frequência por aplicação da transformada de Laplace à EDO na Eq. (A.1) e fazendo todas as condições iniciais a zero, obtém-se a função de transferência, neste caso, paramétrica,

$$G(s) = \frac{y(s)}{u(s)} = \frac{b_0 + b_1s + \dots + b_ms^m}{a_0 + a_1s + \dots + a_ns^n} = \frac{B(s)}{A(s)}. \quad (\text{A.2})$$

Determinando o limite $s \rightarrow i\omega$, tem-se a resposta à frequência é dada por

$$G(i\omega) = \lim_{s \rightarrow i\omega} G(s) = |G(i\omega)|e^{i\phi(i\omega)}, \quad (\text{A.3})$$

em que a magnitude é $|G(i\omega)|$ e a fase $\phi(i\omega) = \angle G(i\omega)$ que estão representadas em função dos parâmetros do modelo.

A.1.2 Sistemas de controle por malha fechada

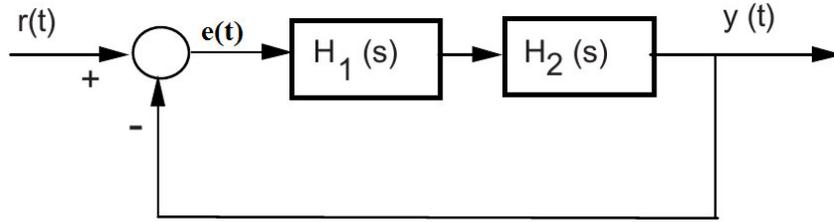
O sistema de controle de malha fechada é representado na Figura 29. Sendo $y(t)$ a saída do sistema e $r(t)$ é o sinal de referência.

O sistemas de malha fechada apresentado na Figura 29 contém pelo menos dois sistemas dinâmicos: a planta ($H_1(s)$) e o controlador($H_2(s)$). A saída $y(t) = H_M(s)e^{st}$ do sistema com uma referência externa $r(t) = e^{st}$ é resultante em $H_2(s)H_1(s)u_1(t)$, sendo $e(t) = r(t) - y(t)$ e com manipulações algébricas obtêm-se o resultado do sistema em malha fechada dada por

$$H_M(s) = \frac{H_2(s)H_1(s)}{1 + H_2(s)H_1(s)}, \quad (\text{A.4})$$

a estratégia do controle de malha fechada envolve a medição, a comparação com o valor requerido e a utilização de uma correção adequada.

Figura 29 – Sistema de controle em malha fechada.

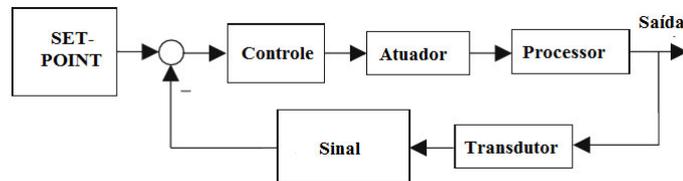


Fonte: Elaborado pelo autor

A.2 Ações do Controlador PID

A aplicação correta de uma lei para o controlador PID consiste na soma das três ações de controle: uma ação proporcional, uma ação integral e uma derivada. Estas ações são descritas singularmente a seguir. Com as operações do sistema de malha fechada, de forma generalizada, os principais componentes podem ser agrupados conforme a Figura 30.

Figura 30 – Sistema de típico de controle industrial.



Fonte: Elaborado pelo autor.

Embora os parâmetros do controlador PID em tempo contínuo possam ser recuperados a partir do projeto do controlador PID digital, em alguns casos, as metodologias de tempo discreto não foram desenvolvidas para a sintonização em tempo contínuo (LANDAU; ZITO, 2005).

Na indústria de processo, o controlador mais utilizado é o controlador PID, ou também chamada de controlador de "três termos". Para este controlador em tempo contínuo tem-se que

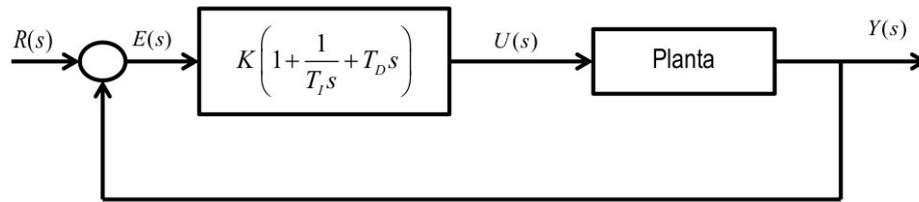
$$D(s) = K_p + \frac{K_I}{s} + K_D s. \quad (\text{A.5})$$

Na Eq.(A.5) os três parâmetros K_p , K_I e K_D são escolhidos para desempenhar um comportamento desejado do processo. Uma forma alternativa de representar o controlador PID é dada por

$$K \left(1 + \frac{1}{T_I s} + T_D s \right), \quad (\text{A.6})$$

em que, para esta representação, os parâmetros K , T_I e T_D definem o controlador de três termos. As duas formas são equivalentes. Preferi-se usar no decorrer do trabalho a forma expressa na Eq. (A.5), pois os ganhos associados a cada termo fica mais claro. Uma versão digital é obviamente necessária para aplicações de controle em computador, onde as operações contínuas necessitam ser discretizadas e aproximadas. Tem-se o controlador no ponto de erro em um sistema de malha fechada como mostrado na Figura 31.

Figura 31 – Sistema de controle com PID em s .



Fonte: Elaborada pelo autor.

A.2.1 Ação proporcional (P) do controlador PID

A ação do controle proporcional é proporcional ao erro de controle, conforme com a expressão dada por

$$u(t) = K_p e(t) = K_p (r(t) - y(t)), \quad (\text{A.7})$$

em que K_p é o ganho proporcional. Seu significado é direto, pois implementa a operação típica de aumentar a variável de controle. A função de transferência do controlador proporcional pode ser derivada trivialmente como $C(s) = K_p$.

A.2.2 Ação integrativa (I) do controlador PID

A ação integral é proporcional à magnitude e à duração do erro de controle, em que K_i é o ganho integral. A ação integrativa está relacionada aos valores passados do erro de controle. A função de transferência correspondente é dada por

$$u(t) = K_i \int_0^t e(\tau) d\tau, \quad (\text{A.8})$$

a ação integrativa é chamado, muitas vezes, de *reset* automático. Deste modo, o uso de uma ação proporcional em conjunto com uma ação integral, isto é, de um controlador PI, resolve os principais problemas da resposta oscilatória. A representação em domínio da frequência é dado por

$$C(s) = K_p \left(1 + \frac{1}{T_i s} \right). \quad (\text{A.9})$$

O controlador integrativo é usado quando é necessário uma correção, durante qualquer *offset* estável, o valor de referência constante.

A.2.3 Ação derivativa (D) do controlador PID

Enquanto a ação proporcional é baseada no valor atual do erro de controle e a ação integrativa é baseada nos valores passados do erro de controle, a ação derivativa é baseada nos valores futuros previstos do erro de controle. Uma lei ideal para esse controle é dada por

$$u(t) = K_d \frac{de(t)}{dt}, \quad (\text{A.10})$$

em que K_d é definido como ganho derivado. A função de transferência do controlador correspondente é $C(s) = K_d s$. O controlador pode usar a taxa de mudança do sinal de erro como uma entrada, isso introduz um elemento de previsão na ação de controle.

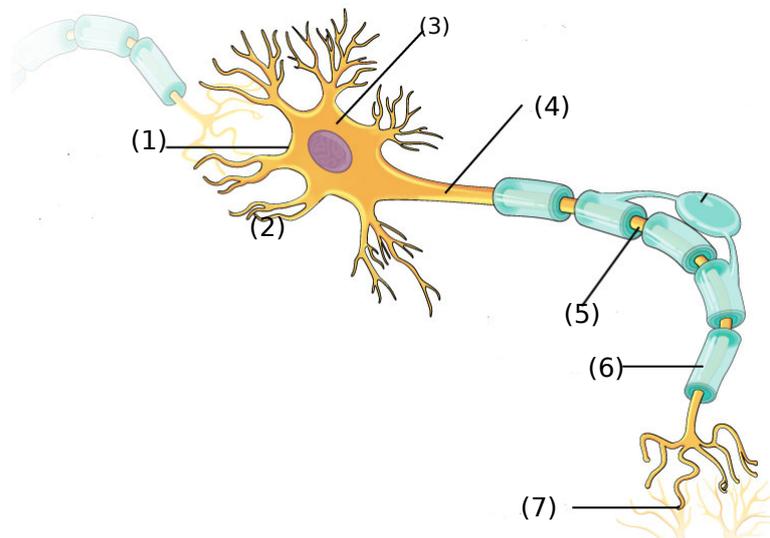
B Conceitos de Redes Neurais Artificiais

Este apêndice tem por objetivo fornecer apoio para uma melhor compreensão da abordagem sobre RBF apresentada no Capítulo 3. Aborda-se a fisiologia neural, a junção sináptica, funções de ativações, arquitetura das redes neurais artificiais e perceptrons de múltiplas camadas

B.1 Fisiologia Neural

A Figura 32 descreve os principais componentes de uma célula nervosa típica no sistema nervoso central. A membrana (1) de um neurônio separa o plasma intracelular do fluido intersticial externo à célula. A membrana é permeável a certas espécies iônicas e atua para manter uma diferença de potencial entre o fluido intracelular e extracelular. Ele realiza essa tarefa, principalmente, pela ação de uma bomba de sódio-potássio. Este mecanismo transporta íons de sódio para fora e íons de potássio para dentro da célula. Outras espécies iônicas presentes são os íons cloreto e íons orgânicos negativos.

Figura 32 – Principais componentes de uma célula nervosa.



Fonte: (boundless.com, 2017)

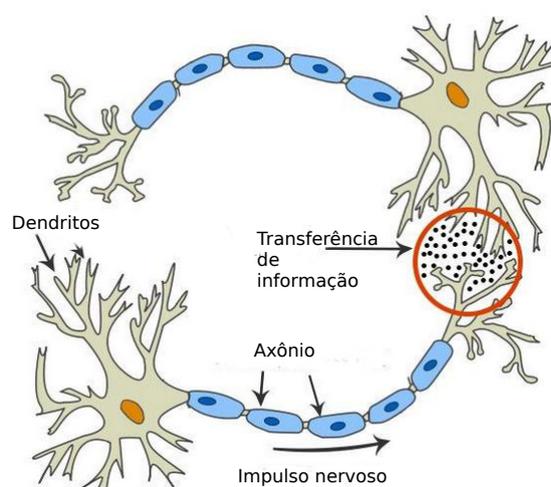
As principais estruturas de uma célula nervosa incluem dendritos (2), o corpo celular (3) e um único axônio (4). O axônio de muitos neurônios é cercado por uma membrana chamada bainha de mielina (6). Os nós de Ranvier (5) interrompem a bainha

de mielina periodicamente ao longo do comprimento do axônio. As sinapses (7) conectam os axônios de um neurônio a várias partes de outros neurônios.

B.1.1 Junção Sináptica

A comunicação entre os neurônios ocorre como resultado da liberação pela célula pré-sináptica de substâncias chamadas neurotransmissores e da subsequente absorção dessas substâncias pela célula pós-sináptica. Quando o potencial de ação chega como a membrana pré-sináptica, mudanças na permeabilidade da membrana causam um influxo de íons de cálcio. Estes íons fazem com que as vesículas contendo os neurotransmissores se fundam com a membrana pré-sináptica e libertem os seus neurotransmissores para a fenda sináptica.

Figura 33 – Conexão sináptica entre neurônios.



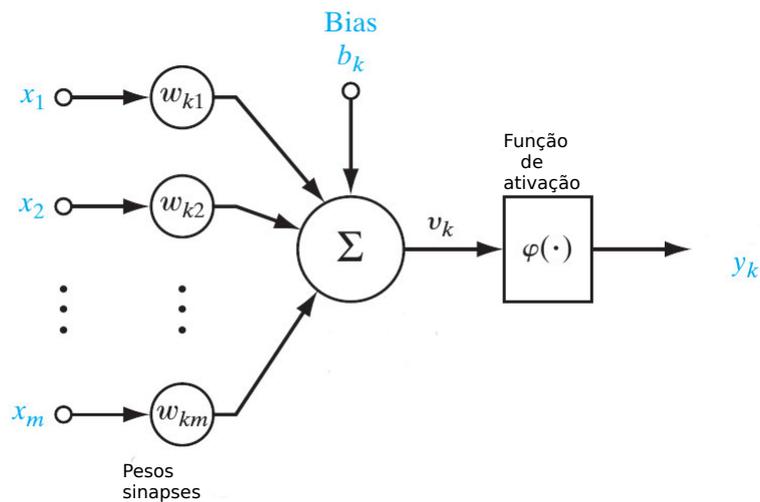
Fonte: (Artificial Intelligence Tutorial, 2017)

Em resumo, embora as atividades relacionadas ao neurônio biológico possam parecer simples no início, seus componentes, ao funcionarem totalmente são responsáveis por todo o processo executado e gerenciado pelo cérebro humano. Estima-se que a rede neural biológica, com característica muito excêntrica, seja composta por cerca de 100 bilhões de neurônios (SOUZA; SOARES, 2016). Cada um deles está interligado através de conexões sinápticas (tornadas possíveis por mais de cinquenta substâncias neurotransmissoras) para uma média de 6.000 neurônios, resultando em um total de 600 trilhões de sinapses (BROWN, 2012).

B.1.2 Unidade Neural

Um neurônio é uma unidade de processamento de informação que é fundamental para o funcionamento de uma Rede Neural Artificial (RNA) (HAYKIN et al., 2009). A RNA é composta por conjunto de sinapses (ou elos de conexão), somador e função de ativação, mostrada na Figura 34. O conjunto de sinapses, cada um dos quais, é caracterizado por um peso ou força própria. Especificamente, um sinal x_j na entrada da sinapse j conectada ao neurônio k é multiplicado pelo peso sináptico w_{kj} . Onde o primeiro subscrito em w_{kj} refere-se ao neurônio em questão, e o segundo subscrito refere-se ao final da entrada da sinapse a que se refere o peso. E por fim, a função de ativação vem para limitar a amplitude da saída do neurônio. A função de ativação é também referida como uma função restritiva, na medida em que restringe (limita) o intervalo permissível de amplitude do sinal de saída a um valor finito.

Figura 34 – Modelo não-linear de um neurônio.



Fonte: (HAYKIN et al., 2009)

Em relação ao modelo RNA da Figura 34, tem-se a inclusão de *bias* aplicado externamente, representado por b_k . O bias b_k tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ela é positiva ou negativa, respectivamente. Escrevendo em termos matemáticos o neurônio k é dada por

$$u = \sum_{j=1}^m w_{kj} x_j \quad (\text{B.1})$$

$$y_k = \varphi(u_k + b_k). \quad (\text{B.2})$$

Sendo x_1, x_2, \dots, x_m os sinais de entrada e $w_{k1}, w_{k2}, \dots, w_{km}$ são os respectivos pesos sinápticos do neurônio k ; u_k é a saída do combinador linear devido aos sinais de entrada; b_k é o

bias; $\varphi(\cdot)$ é a função de ativação; e y_k é o sinal de saída do neurônio. O uso do bias b_k tem o efeito de aplicar uma *transformação afim* à saída u_k do combinador linear no modelo dado por

$$v_k = u_k + b_k. \quad (\text{B.3})$$

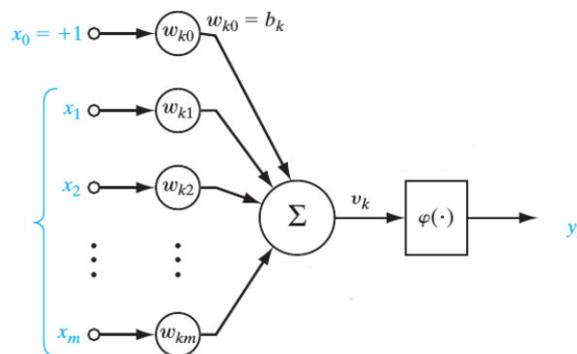
Os bias b_k podem ser positivo ou negativo. A relação do campo induzindo local ou potencial de ativação, v_k do neurônio k e a saída de combinador linear u_k é dada pela Eq. B.3. O bias b_k é um parâmetro externo do neurônio artificial k . Considerando a Eq. (B.2) e com manipulações algébricas da Eq. (B.1) e Eq. (B.3), pode-se formular a expressão dada por

$$v_k = \sum_{j=0}^m w_{kj} x_j \quad (\text{B.4})$$

$$y_k = \varphi(v_k) \quad (\text{B.5})$$

Na Eq. (B.4) tem-se a adição de uma nova sinapse e fazendo a entrada $x_0 = +1$ com peso $w_{k0} = b_k$ obtêm-se um modelo não-linear do neurônio, uma ilustração desse modelo neural é visto na Figura 35.

Figura 35 – Modelo não-linear de um neurônio.



Fonte: (HAYKIN et al., 2009)

B.1.3 Função de ativação

As funções de ativação podem ser divididas em dois grupos fundamentais, as *parcialmente diferenciáveis* e *totalmente diferenciáveis*, quando se considera seus domínios de definição completa (SOUZA; SOARES, 2016). As funções degrau (limiar), sinal e rampa simétrica são as três principais funções *parcialmente diferenciáveis*. Para as *funções totalmente diferenciáveis* tem-se as funções logística, tangente hiperbólica e gaussiana. Existe uma infinidade de outras funções de ativação, porém para nível de conhecimento deste trabalho o último grupo é de grande utilidade.

A função de ativação, ou também conhecida como função de transferência, mostrada no bloco, $\varphi(\cdot)$, da Figura 35 é uma função linear ou não linear, definindo a saída de um neurônio em termos do campo local induzido v_k . Uma função de ativação particular é escolhida para satisfazer a especificação de um problema que o neurônio está tentando resolver.

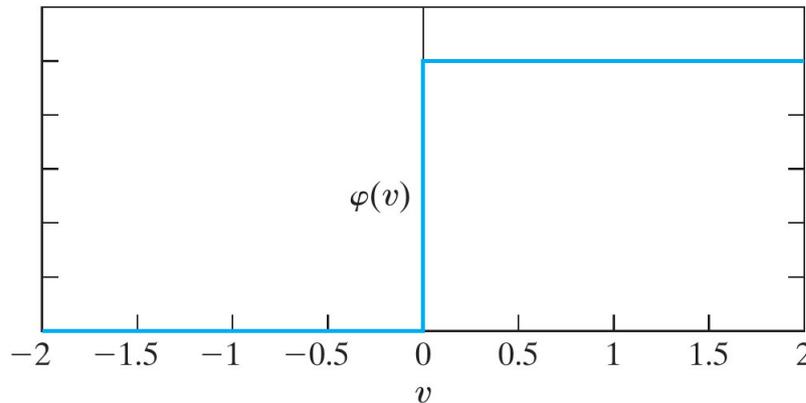
Um exemplo de uma função *parcialmente diferenciáveis* é limiar. Esta assumirá valores positivos unitários quando o potencial de ativação do neurônio for maior ou igual a zero, caso contrário, o resultado será nulo, Figura 36. Desta forma sua representação matemática é dada por

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq 0 \\ 0, & \text{se } v < 0 \end{cases} \quad (\text{B.6})$$

em que v_k é o campo local induzido do neurônio com representação dada por

$$v_k = \sum_{j=1}^m w_{kj}x_j + b_k. \quad (\text{B.7})$$

Figura 36 – Função limiar.



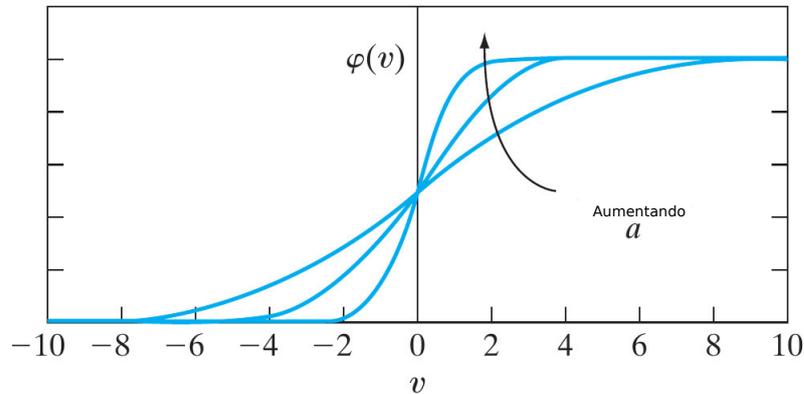
Fonte: Elaborado pelo autor.

Já para caso de funções *totalmente diferenciáveis* tem-se, por exemplo, a função logística representado pela Figura 37. Esta função sempre assume valores reais entre zero e um. A sua representação é dada por

$$\varphi(v) = \frac{1}{1 + e^{(-av)}} \quad (\text{B.8})$$

As funções de ativação definidas nas Eq. (B.6) e Eq. (B.8) variam de 0 a 1. Para o caso de uma função de ativação impar tem-se variação de -1 a $+1$. A função limiar da Eq. (B.8) é dada por

$$\varphi(v) = \begin{cases} 1, & \text{se } u > 0 \\ 0, & \text{se } u = 0 \\ -1, & \text{se } u < 0 \end{cases}, \quad (\text{B.9})$$

Figura 37 – Função logística para variar o parâmetro de inclinação a .

Fonte: (HAYKIN et al., 2009)

B.1.4 Topologia das Redes Neurais Artificiais - RNAs

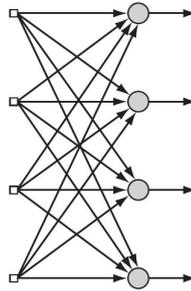
A topologia das RNAs está associada com diferentes formas estruturais possíveis e diferentes números de neurônios nas camadas de entrada, intermediária e de saída da rede. Quando se trata das arquiteturas RNAs, tem-se a descrição de como os seus neurônios são dispostos, ou colocados, em relação uns aos outros. A organização da RNA está, de certa forma, ligada ao algoritmo de aprendizagem usado para treinamento da rede.

Em geral, pode-se identificar três classes fundamentais de arquitetura das RNAs, que são as: *feedforward* de camadas simples, *feedforward* de camadas múltiplas e redes recorrentes ou realimentada.

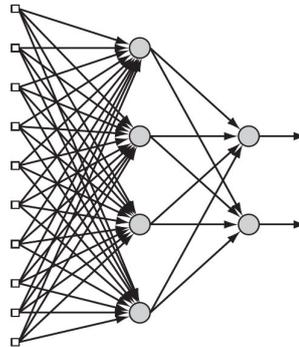
As redes *feedforward* de camada simples, Figura 38, tem como característica, na forma simples, uma camada de entrada de nós (unidades sensoriais) que se projeta diretamente sobre uma camada de saída de neurônios (nós de computação), mas não o contrário. Não se conta a camada de entrada porque não há uma computação envolvida, mas se o envio do sinal para camada seguinte (HAYKIN et al., 2009).

As classes de RNAs *feedforward* de camadas múltiplas, Figura 39, se diferenciam pela presença de uma ou mais camadas ocultas, cujos nós de computação são correspondentemente chamados neurônios ocultos ou unidades ocultas, parte da rede neural que não é vista diretamente da entrada ou na saída da rede.

E por fim, tem-se a rede neural recorrente diferenciada de uma rede neural *feedforward* por possuir pelo menos uma laço de realimentação. Pode-se ver melhor essa

Figura 38 – Rede *feedforward* de Camada Simples

Fonte: Elaborado pelo autor.

Figura 39 – Rede *feedforward* de Camadas Múltiplas

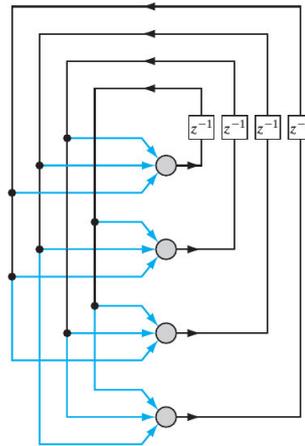
Fonte: Elaborado pelo autor.

realimentação na Fig. 40. A realimentação refere-se a da saída do neurônio voltando para sua própria entrada.

A dinâmica neural consiste em duas partes: do estado de ativação e dos pesos sinápticos. A memória de curto prazo em redes neurais é modelada pelo estado de ativação da rede. A memória de longo prazo corresponde à informação do padrão codificada nos pesos sinápticos devido à aprendizagem. As leis de aprendizagem são meramente modelos de implementação da dinâmica sináptica. Para a representação do conhecimento tem-se quatro regras que são de natureza de senso comum representadas por:

1. Entradas semelhantes de classes semelhantes devem produzir representações semelhantes no interior da rede, sendo classificadas como pertencentes à mesma classe.
2. Os itens a serem categorizados como classes separadas devem receber representações amplamente diferentes na rede.
3. Se uma característica particular é importante, então deve haver um grande número de

Figura 40 – Redes Recorrentes ou realimentada



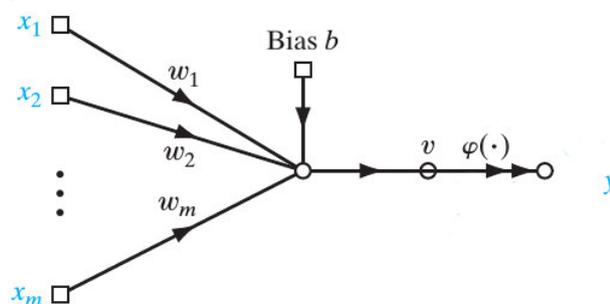
Fonte: AUTOR

neurônios envolvidos na representação desse item na rede. Desta forma o desempenho de detecção de um tal sistema de radar é medido em termos de duas probabilidades: a de *detecção* e *alarme falso*.

4. Informações prévias e as invariâncias devem ser incorporadas na concepção de uma RNA sempre que estiverem disponíveis, de modo a simplificar o projeto da rede por não ter que aprendê-los.

O perceptron de Rosenblatt (1962) é construído em torno de um neurônio não linear do modelo McCulloch e Pitts (1943) de um neurônio. De maneira que a modelagem neural consiste em um combinador linear limitado por uma função de ativação.

Figura 41 – Esquema da rede Perceptron



Fonte: Elaborado pelo autor

A simplicidade da rede Perceptron deve-se à sua condição de ser constituída por

apenas uma camada neural, possuindo assim um único neurônio artificial. Onde a rede é composta por m sinais de entrada (unidades sensoriais) e apenas uma saída.

Em relação a Figura 41, os pesos sinápticos do perceptron são w_1, w_2, \dots, w_m . As entradas aplicadas ao perceptron são denotadas por x_1, x_2, \dots, x_m . Tendo os bias, b , aplicada externamente. A partir do modelo, encontra-se um limitador na entrada, ou campo local induzido dada por

$$v = \sum_{i=1}^m w_i x_i + b. \quad (\text{B.10})$$

A finalidade do perceptron é classificar corretamente o estímulo nas entradas sensoriais em uma das duas classes, \mathcal{C}_1 ou \mathcal{C}_2 . Em que a regra para decidir a classificação é atribuir o ponto representado pelas entradas para a classe \mathcal{C}_1 se a saída do perceptron y for $+1$ e para a classe \mathcal{C}_2 se for -1 . Na forma mais simples do perceptron, existem duas regiões de decisão separadas por um hiperplano, que é definido pela Eq. (B.10) sendo igual a zero.

- Método da descida mais íngreme

O método da descida mais íngreme é uma lei de aprendizagem que descreve o vetor de peso para a i -ésima unidade de processamento na interação $(n + 1)$, em termos do vetor de peso no momento (n) , dado por

$$\mathbf{w}(n + 1) = \mathbf{w}(n) - \eta \mathbf{g}(n) \quad (\text{B.11})$$

$$\Delta \mathbf{w}(n) = \mathbf{w}(n + 1) - \mathbf{w}(n) \quad (\text{B.12})$$

$$= -\eta \mathbf{g}(n) \quad (\text{B.13})$$

em que $\mathbf{g} = \Delta \mathcal{E}(\mathbf{w})$, g é o vetor gradiente calculado na interação $\mathbf{w}(n)$ e η é a taxa de aprendizagem, sendo uma constante positiva. De forma que o vetor gradiente é expresso por

$$\Delta \mathcal{E}(\mathbf{w}(n)) = \left[\frac{\partial \mathcal{E}}{\partial w_1}, \frac{\partial \mathcal{E}}{\partial w_2}, \dots, \frac{\partial \mathcal{E}}{\partial w_m} \right]^T \quad (\text{B.14})$$

em que Δ é o operador gradiente.

- Método de Newton

O método de Newton tem uma ideia básica de minimizar a aproximação quadrática da função de custo \mathcal{E} , em torno do ponto corrente $w(n)$ dado por

$$\mathcal{E}(\mathbf{w}(n + 1)) < \mathcal{E}(\mathbf{w}(n)) \quad (\text{B.15})$$

sendo $w(n)$ o valor antigo do peso e $\mathbf{w}(n + 1)$ o valor atual dado por

$$\Delta \mathcal{E}(\mathbf{w}(n)) = \mathcal{E}(\mathbf{w}(n + 1)) - \mathcal{E}(\mathbf{w}(n)) \quad (\text{B.16})$$

$$= \mathbf{g}^T(n) \Delta \mathbf{w}(n) + \frac{1}{2} \Delta \mathbf{w}^T(n) \mathbf{H}(n) \Delta \mathbf{w}(n) \quad (\text{B.17})$$

em que \mathbf{g} é o vetor gradiente com dimensão $m \times 1$ e $\mathbf{H}(n)$, sendo a matriz hessiana dada por

$$\begin{aligned} \mathbf{H} &= \nabla^2 \mathcal{E}(\mathbf{w}) \\ &= \begin{bmatrix} \frac{\partial^2 \mathcal{E}}{\partial w_1^2} & \frac{\partial^2 \mathcal{E}}{\partial w_1 \partial w_2} & \cdots & \frac{\partial^2 \mathcal{E}}{\partial w_1 \partial w_M} \\ \frac{\partial^2 \mathcal{E}}{\partial w_2 \partial w_1} & \frac{\partial^2 \mathcal{E}}{\partial w_2^2} & \cdots & \frac{\partial^2 \mathcal{E}}{\partial w_2 \partial w_M} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 \mathcal{E}}{\partial w_M \partial w_1} & \frac{\partial^2 \mathcal{E}}{\partial w_M \partial w_2} & \cdots & \frac{\partial^2 \mathcal{E}}{\partial w_M^2} \end{bmatrix} \end{aligned} \quad (\text{B.18})$$

- Método de Gauss-Newton

O método de Gauss-Newton é baseado na função de custo expressa por uma soma dos erros quadrados dada por

$$\mathcal{E}(\mathbf{w}) = \frac{1}{2} \sum_{i=1}^n e^2(i) \quad (\text{B.19})$$

de forma que o erro é calculado com base em $e(i) = d(i) - y(i)$, com $d(i)$ sendo a resposta desejada e $y(i)$ é a saída da rede. Pode-se verificar a Figura 41 e obter facilmente a equação dada por

$$y(i) = v(i) = \sum_{i=1}^m w_i x_i + b \quad (\text{B.20})$$

O sinal de erro é uma função do vetor de peso ajustável. Para uma equivalência, com manipulações lineares, pode-se escrever na forma modificada (HAYKIN et al., 2009), expressa por

$$\mathbf{w}(n+1) = \mathbf{w}(n) - (\mathbf{J}^T(n)\mathbf{J}(n) + \delta\mathbf{I})^{-1}\mathbf{J}^T(n)\mathbf{e}(n) \quad (\text{B.21})$$

em que $(\mathbf{J}^T(n)\mathbf{J}(n) + \delta\mathbf{I})$ é definida positivamente para todo n .

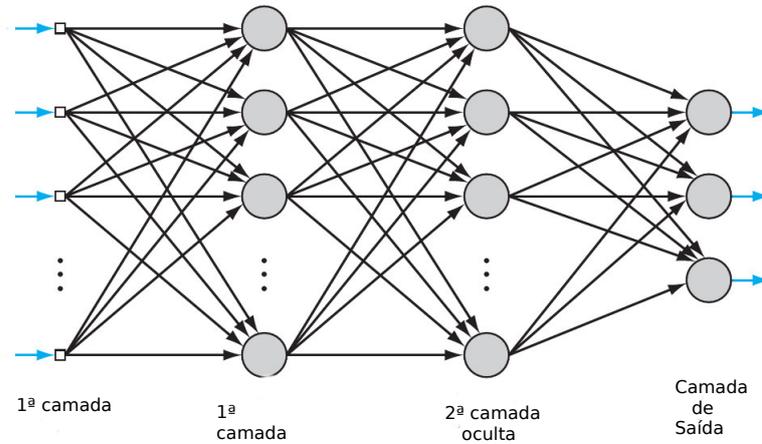
B.1.5 Perceptrons de Múltiplas Camadas

A Figura 42 mostra um exemplo de perceptrons de múltiplas camadas com uma estrutura de uma camada de entrada, uma camada intermediária, ou oculta e uma camada de saída. Os neurônios na camada de entrada atuam como distribuidores dos sinais de entrada x_i para os neurônios da camada seguinte, neste caso, na camada oculta. Cada neurônio na camada oculta resume seus sinais de entrada x_i depois de ponderar com as forças das respectivas conexões da camada de entrada e, desta forma, calcula a saída $y(i)$ como uma função f da soma dada por

$$y(i) = f\left(\sum w_{ji}x_i\right) \quad (\text{B.22})$$

em que f é uma função de ativação, do tipo logística, já descrita na Seção (B.1.3) ou uma Função de Base Radial da Seção (3.3.2).

Figura 42 – Estrutura perceptrons de múltiplas camadas



Fonte: Elaborado pelo autor

B.1.6 Algoritmo *Backpropagation*

O algoritmo *backpropagation* (BP), com método por descida do gradiente, é o algoritmo de treinamento MLP mais comumente utilizado (SOUZA; SOARES, 2016) (HAYKIN et al., 2009). Dá a mudança na variação dos pesos Δw_{ji} de uma conexão entre neurônios i e j expresso por

$$\Delta w_{ji}(n) = \eta \delta_j(n) y_i(n) \quad (\text{B.23})$$

em que $\delta(n)$ é um gradiente local definido por

$$\delta_j(n) = \frac{\partial \mathcal{E}(n)}{\partial v_j(n)}. \quad (\text{B.24})$$

Para todos, exceto os problemas mais triviais, várias épocas são necessárias para que a MLP seja devidamente treinado. O que efetivamente permite que a alteração dos pesos anteriores influenciem a nova mudança do peso atual expresso por

$$\Delta w_{ji}(n) = \eta \delta_j(n) y_i(n) \quad (\text{B.25})$$

em que $\Delta w_{ji}(n)$, η , $\delta_j(n)$ e $y_i(n)$ é a correção dos pesos, taxa de aprendizado, gradiente local e sinal de entrada do neurônio j .

O critério de convergência sensível para aprendizado por retropropagação é considerar que o algoritmo tenha convergido quando a norma euclidiana do vetor gradiente alcançar um limiar suficientemente pequeno (KRAMER; SANGIOVANNI-VINCENTELLI, 1989). Outra propriedade utilizada é considerar que o algoritmo de retropropagação tenha convergido é quando a taxa absoluta de variação do erro médio quadrado por época for suficientemente pequena (HAYKIN et al., 2009) (PHAM; LIU, 1995).