



Dissertação

Mestrado em Engenharia Eletrotécnica

***Modelação e Análise de um Sistema Flexível de
Produção***

Edgar Carqueijeiro Travassos

Leiria, Setembro de 2014



Dissertação

Mestrado em Engenharia Eletrotécnica

***Modelação e Análise de um Sistema Flexível de
Produção***

Edgar Carqueijeiro Travassos

Dissertação de Mestrado realizada sob a orientação do Doutor Hugo Costelha e coorientação do Doutor Carlos Neves, Professores da Escola Superior de Tecnologia e Gestão do Instituto Politécnico de Leiria.

Leiria, Setembro de 2014

AGRADECIMENTOS

Gostaria de prestar os meus agradecimentos a todos os que de uma forma direta ou indireta, contribuíram para a realização desta dissertação de mestrado.

Em especial, gostaria de agradecer:

Ao Doutor Hugo Costelha e ao Doutor Carlos Neves pela orientação e disponibilidade que sempre demonstraram.

À empresa Iber-Oleff pela motivação e colaboração concedida ao longo da realização deste trabalho.

RESUMO

A modelação dos sistemas industriais apresenta para as organizações uma vantagem estratégica no domínio do estudo dos seus processos produtivos. Através da modelação será possível aumentar o conhecimento sobre os sistemas podendo permitir, quando possível, melhorias na gestão e planeamento da produção. Este conhecimento poderá permitir também um aumento da eficiência dos processos produtivos, através da melhoria ou eliminação das principais perdas detetadas no processo.

Este trabalho tem como principal objetivo o desenvolvimento e validação de uma ferramenta de modelação, previsão e análise para sistemas produtivos industriais, tendo em vista o aumento do conhecimento sobre estes.

Para a execução e desenvolvimento deste trabalho, foram utilizadas e desenvolvidas várias ferramentas, conceitos, metodologias e fundamentos teóricos conhecidos da bibliografia, como OEE (*Overall Equipment Effectiveness*), RdP (Redes de Petri), Séries Temporais, K-means, ou SPC (*Statistical Process Control*).

A ferramenta de modelação, previsão e análise desenvolvida e descrita neste trabalho, mostrou-se capaz de auxiliar na deteção e interpretação das causas que influenciam os resultados do sistema produtivo e originam perdas, demonstrando as vantagens esperadas. Estes resultados foram baseados em dados reais de um sistema produtivo.

Palavras-chave: Sistemas Industriais, OEE, Modelação, Redes de Petri, Séries Temporais, K-means, SPC

ABSTRACT

The modelling of industrial systems presents for organizations a strategic advantage in the field of study of their production processes. Through modelling, it will be possible to increase the knowledge about the systems and may allow improvements in the management and production planning. This knowledge may also allow an increase in the efficiency of production processes, through the improvement or elimination of the major losses detected in the process.

The main goal of this work is the development and validation of a modelling, forecasting and analysis tool for industrial production systems, in order to increase the knowledge about them.

Several tools, concepts and methodologies were developed in this work, based on known theoretical foundations such as OEE (Overall Equipment Effectiveness), RdP (Petri nets), Time Series, K-means or SPC (Statistical Process Control).

The developed modelling, forecasting and analysis tool described here was able to assist in the detection and interpretation of the causes that influence the results of the production system and result in losses, demonstrating the anticipated benefits. These results were based on real data from a production line.

Keywords: Industrial Systems, OEE, Modelling, Petri Nets, Time Series, K-means, SPC.

ÍNDICE

Agradecimentos	i
Resumo	iii
Abstract	v
Índice	vii
Índice de Figuras	ix
Índice de Tabelas	xi
Lista de Abreviaturas	xiii
1 Introdução	1
1.1 Contextualização e Motivação	1
1.2 Organização	3
2 Estado da Arte	5
2.1 Séries Temporais	6
2.2 Redes Neurais	6
2.3 Algoritmos Genéticos	8
2.4 Redes de Petri	9
3 Fundamentos Teóricos	11
3.1 Sistema	11
3.1.1 Definições	11
3.2 Modelo Matemático de um Sistema	15
3.3 Rede de Petri	16
3.3.1 Conceitos Transversais RdP	16
3.3.2 Exemplo de Modelação RdP	21
3.4 Previsão	22
3.4.1 Séries Temporais	23
3.4.2 Cálculo e Análise de Erros de Previsão	26

3.5	OEE	27
3.5.1	Conceito OEE	27
3.6	Carta de Controlo	31
3.6.1	Carta de Controlo de Média e Amplitude.....	32
3.6.2	Análise de Carta de Controlo	34
3.7	K-means Clustering.....	35
4	Metodologia Desenvolvida	41
4.1	Descrição do Sistema	41
4.2	Modelo do Sistema.....	43
4.3	Modelo de Previsão	50
4.3.1	Previsão com Média Móvel	52
4.3.2	Previsão com Suavização Exponencial	54
4.3.3	Seleção do Modelo de Previsão	57
4.3.4	Previsão Cumprindo Restrições	57
4.4	Perdas por Qualidade.....	58
4.4.1	Estudo do Comportamento de Rejeição	60
4.5	Planeamento e Previsão da Produção	66
4.6	Análise de Variabilidade e Sensibilidade	72
5	Resultados	75
5.1	Análise de Equipamentos Idênticos	75
5.2	Análise de Componentes Idênticos	77
5.3	Análise das Perdas.....	78
5.4	Erros de Previsão.....	79
	Conclusões	81
	Referências.....	83

ÍNDICE DE FIGURAS

Figura 1 – Exemplo estrutura RN (adaptado de [5])	7
Figura 2 – Saída(s) e entrada(s) de um sistema.	12
Figura 3 – Sistema de eventos discretos [19].	13
Figura 4 – Exemplo de RdP.....	18
Figura 5 – Exemplo de RdP (Peso arco).	18
Figura 6 – Exemplo de RdP (Peso transição).	19
Figura 7 – Arco inibidor.....	20
Figura 8 – RdP com partilha de recurso.....	22
Figura 9 – Exemplo de CC (adaptado de [31]).....	31
Figura 10 – Exemplo de violação da regra 3 (adaptado de [31]).	35
Figura 11 – K-means – Representação dos objetos no plano.....	37
Figura 12 – K-means - Resultado da primeira iteração do exemplo.	38
Figura 13 – K-means - Resultado final do exemplo.	38
Figura 14 – Fluxograma do algoritmo K-means.....	39
Figura 15 – RdP Modelo horário do sistema.....	44
Figura 16 – Exemplo de tendência.	49
Figura 17 – Gráfico Previsão Média Móvel.	53
Figura 18 – Erros Médios de Previsão (Média Móvel).....	54
Figura 19 – Gráfico Previsão Suavização Exponencial.	56
Figura 20 – Erros Médios de Previsão (Suavização Exponencial).	56
Figura 21 – RdP que modela as Perdas por Qualidade.	59
Figura 22 – RdP do modelo horário do sistema com defeitos.....	60
Figura 23 – Fluxograma K-means (alterado).	63
Figura 24 – Exemplo <i>Cluster</i> 12.....	64
Figura 25 – <i>Cluster</i> 12 (próxima hora de produção).....	65
Figura 26 – <i>Cluster</i> 5 (próxima hora de produção).	65
Figura 27 – Exemplo Planeamento.....	68
Figura 28 – Exemplo de Planeamento e Previsão (resultados por hora).	69
Figura 29 – Exemplo de Planeamento e Previsão (resultados totais).	70
Figura 30 – Exemplo de Planeamento e Previsão (resultados por hora).	71

Figura 31 – Histograma da saída Produto com Qualidade.	73
Figura 32 – CC média e amplitude Produto com Qualidade.	73
Figura 33 – CC média e amplitude entrada Operador 5.	74
Figura 34 – Exemplo de análise equipamentos idênticos (janela da ferramenta).	76

ÍNDICE DE TABELAS

Tabela 1 – Valores das constantes A_2 , D_3 , D_4 [31].	34
Tabela 2 – K-means – Coordenadas dos objetos.	36
Tabela 3 – Exemplo do cálculo de distâncias para o algoritmo K-means.	37
Tabela 4 – Combinação de estados das entradas (Dias da Semana).	46
Tabela 5 – Combinação de estados das entradas (Mês do Ano).	46
Tabela 6 – Combinação de estados das entradas (Hora do dia).	46
Tabela 7 – Combinação de estados das entradas (Operador).	46
Tabela 8 – Combinação de estados das entradas (Referência).	46
Tabela 9 – Combinação de estados das entradas (Fornecedor de Parafusos).	47
Tabela 10 – Resultados de 10 horas distintas (mesma combinação de estados das entradas).	51
Tabela 11 – Previsão usando Média Móvel.	53
Tabela 12 – Previsão usando Suavização Exponencial.	55
Tabela 13 – Estado das variáveis de entrada - <i>Cluster 17</i> .	66

LISTA DE ABREVIATURAS

BD – Base de Dados

ST – Séries Temporais

RN – Redes Neurais

AG – Algoritmos Genéticos

IEEE – Instituto de Engenheiros Eletrotécnicos e Eletrônicos (*Institute of Electrical and Electronics Engineers*)

ANSI – Instituto Nacional Americano de Standards (*American National Standards Institute*)

RdP – Rede de Petri

GSPN – Rede de Petri Estocástica (*Generalized Stochastic Petri Nets*)

MAE – Média Absoluta dos Erros

MQE – Média do Quadrado dos Erros

MAPE – Média Absoluta Percentual dos Erros

OEE – Eficiência Global dos Equipamentos (*Overall Equipment Effectiveness*)

TPM – Manutenção Produtiva Total (*Total Productive Maintenance*)

SPC – Controlo Estatístico de Processo (*Statistical Process Control*)

CC – Carta de Controlo

IPC – Computador Industrial (*Industrial PC*)

1 INTRODUÇÃO

1.1 Contextualização e Motivação

Ao longo dos tempos, o Homem tem observado e estudado os sistemas no intuito de os compreender e controlar. A necessidade de compreensão do passado e de previsão do futuro tem impulsionado vários estudos e trabalhos.

A vantagem da previsão do futuro dos sistemas incide na minimização da incerteza, um fator crítico à inovação e ao crescimento das organizações. Qualquer organização necessita de fundamentos concretos sobre o futuro para que possa investir e potenciar o seu negócio. A previsão é uma ferramenta largamente aplicada em muitos campos incluindo a indústria, economia, ambiente, política, medicina, ou a ciência [1].

Existem inúmeros casos ao longo da história de previsões pobres ou simplesmente erradas que levaram a decisões desastrosas [2]. A aprendizagem com os erros cometidos no passado e o desenvolvimento das tecnologias de processamento e armazenamento de dados tem contribuído para a melhoria e aumento das técnicas utilizadas, assim como para o conhecimento sobre previsão.

As empresas não são alheias a estes avanços tecnológicos, sendo hoje em dia comum na indústria o uso de sistemas automáticos de recolha de dados da produção e dos processos em Bases de Dados (BD), promovendo o desenvolvimento de ferramentas de análise e previsão vocacionadas para sistemas industriais. Subjacente ao desenvolvimento destas ferramentas está a modelação dos sistemas que se pretende analisar. Um modelo fornece uma previsão do comportamento do sistema modelado, previsão essa que depende do método de modelação.

A modelação de um sistema industrial pode ser complexa, dependendo da dimensão do sistema, dos seus limites de interação e da sua composição. O grande número de variáveis e combinações que influenciam o comportamento destes sistemas dificulta o conhecimento sobre os mesmos. As técnicas de planeamento e gestão industriais são formuladas de

acordo com o conhecimento sobre o sistema, ou seja, um bom modelo do sistema potencia melhorias no planeamento e na gestão do sistema industrial.

Outra das grandes vantagens da modelação dos sistemas industriais é a melhoria dos processos produtivos. Estas melhorias equivalem a rendimento adquirido pela organização aumentando a sua competitividade. Ao analisar o modelo do sistema podem-se retirar conclusões que irão permitir aumentar a eficiência dos processos produtivos, atuando de uma forma mais clara nas causas que originam problemas nos processos.

Este trabalho tem como principal objetivo o desenvolvimento e validação de uma ferramenta de modelação, previsão e análise para sistemas produtivos industriais, tendo em vista o aumento do conhecimento sobre estes sistemas. Este conhecimento permitirá, quando possível, intervir nos processos produtivos de forma a aumentar a sua eficiência. Será também possível planear e gerir estes sistemas de uma forma mais eficiente, resultando em ganhos para a organização.

O trabalho desenvolvido emprega principalmente conhecimentos nas áreas de sistemas, modelação de sistemas, modelos de previsão, análise estatística de processos, *clustering* (*data mining*) e indicadores de eficiência de sistemas industriais. As ferramentas desenvolvidas e implementadas foram integradas numa ferramenta informática desenvolvida para o efeito, cujas potencialidades serão descritas neste trabalho.

O desenvolvimento e implementação das ferramentas descritas ao longo deste trabalho foram realizados em ambiente industrial, na empresa Iber-Oleff – Componentes Técnicos em Plástico, S.A.. Qualquer dado ou resultado presente neste trabalho encontra-se descaracterizado, de forma a manter a confidencialidade dos sistemas produtivos da empresa, mantendo no entanto a validade das conclusões retiradas relativamente à ferramenta desenvolvida e avaliada. Toda a informação presente neste trabalho destina-se apenas à compreensão das ferramentas descritas e aos ganhos que estas permitem, não sendo seu objetivo a análise de resultados dos sistemas produtivos da empresa.

1.2 Organização

Este documento encontra-se estruturado em seis capítulos.

O presente capítulo introduz e contextualiza o trabalho desenvolvido, descrevendo como este está organizado e qual a motivação que lhe subjaz. O segundo capítulo oferece uma visão geral de algumas das ferramentas mais divulgadas na bibliografia nas áreas da modelação e previsão de sistemas indústrias. O terceiro capítulo descreve alguns dos fundamentos teóricos que serviram de base à descrição e compreensão do trabalho realizado. O quarto capítulo descreve a metodologia utilizada para a construção da ferramenta desenvolvida. No quinto capítulo são descritos alguns dos resultados observados durante a validação e avaliação do trabalho desenvolvido. No último capítulo são retiradas conclusões sobre o desenvolvimento e utilização da ferramenta descrita neste trabalho e possíveis trabalhos futuros.

2 ESTADO DA ARTE

A modelação de sistemas permite compreender e melhorar os processos no sentido do aumento da eficiência e da competitividade da indústria. Os modelos podem ser usados para o controlo de processos, análise dos sistemas, como ferramentas de previsão ou até mesmo como mecanismos de formação sobre o sistema real.

Hoje em dia existem algumas ferramentas comerciais e empresas dedicadas à modelação de sistemas industriais que apresentam como cartão-de-visita as vantagens inerentes a este tipo de ferramenta. Estas soluções comerciais estão muitas vezes suportadas por técnicas de modelação conhecidas da bibliografia com provas dadas na modelação de vários tipos de sistema.

Os sistemas industriais poderão ser muitas vezes interpretados como sistemas controlados (a industrialização assenta no controlo), mas este controlo poderá estar dependente de inúmeras variáveis desconhecidas ou não consideradas pelos gestores destes sistemas. Quanto maior o número de variáveis desconhecidas ou não consideradas, mais complexo será o sistema, isto é, a complexidade do sistema está relacionada com o conhecimento sobre o mesmo. Qualquer ferramenta de modelação necessita de informação coerente e relevante sobre o sistema real para que possa apresentar resultados que permitam retirar conclusões válidas sobre o sistema real. A escolha da ferramenta mais apropriada para cada sistema depende em muitos dos resultados do sistema e do tipo análise que se pretende efetuar, sendo por vezes uma tarefa complexa.

Este capítulo descreve algumas das ferramentas mais divulgadas na bibliografia nas áreas da modelação e previsão de sistemas indústrias. Esta descrição será feita de uma forma sucinta, apenas com o intuito de descrever as principais características de cada ferramenta e a sua aplicabilidade.

2.1 Séries Temporais

Os modelos de previsão baseados em Séries Temporais (SA) empregam propriedades estatísticas ao histórico dos resultados de um sistema para estimar parâmetros desconhecidos do modelo. Estes modelos são utilizados na previsão do comportamento (ou resultado) futuro do sistema e terão de ser adaptadas consoante o histórico do seu comportamento.

Estes modelos de previsão são muito usados devido à sua simplicidade de utilização e aos bons resultados que apresentam, dependendo do histórico do comportamento do sistema em questão. São normalmente desaconselhados em sistemas que apresentem padrões complexos nos resultados, podendo existir para estas situações outro tipo de ferramentas mais eficazes (como por exemplo, as redes neuronais).

Os modelos de previsão baseados em séries temporais são amplamente utilizadas em previsões da economia, previsões de vendas nas empresas, previsões da produção, previsão de cargas de trabalho, estudos de inventário, análise orçamental [3].

As series temporais também são utilizadas no controlo dos sistema de produção, isto é, através da previsão dos resultados futuros do sistemas de produção poderão ser tomadas várias decisões que beneficiem a eficiência do sistema [4].

Neste trabalho serão utilizadas séries temporais, pelo que estas serão descritas com mais detalhe no Capítulo 3.

2.2 Redes Neuronais

As Redes Neuronal (RN) podem ser descritas de uma forma simplista, como uma ferramenta de modelação matemática, baseada nas estruturas neuronais biológicas, com a capacidade de aprendizagem a partir de acontecimentos passados, podendo dar resposta a novos acontecimentos [5]. O conceito subjacente a esta ferramenta assenta no facto do

conhecimento ser adquirido pela rede a partir dos dados de entrada, recorrendo a um processo de aprendizagem.

Existem várias arquiteturas de RN sendo estas genericamente constituídas por um conjunto de elementos, designados neurónios (ou unidades de processamento), dispostos em várias camadas, concretamente, uma camada de entrada, uma ou mais camadas intermédias (ou ocultas) e uma de saída. Os neurónios estão geralmente ligados por canais de comunicação (sinapses) a cada um dos quais se pode associar um determinado peso. Estas ligações são utilizadas pela rede para armazenar o conhecimento adquirido durante o processo de aprendizagem.

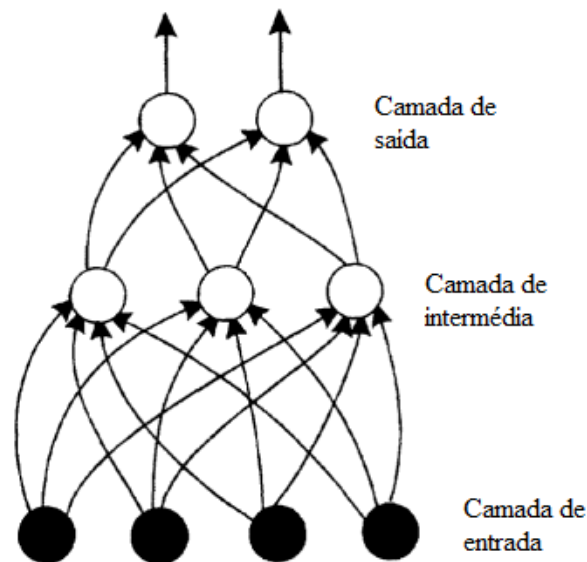


Figura 1 – Exemplo estrutura RN (adaptado de [5])

O processo de aprendizagem pode ser supervisionado (assistido) ou não supervisionado (não assistido). No processo de aprendizagem supervisionado, numa primeira fase, existe um conjunto de dados de treino e de valores alvo de saída do modelo que são fornecidos à rede, de modo a ajustar o peso de cada ligação entre neurónios, de forma a produzir a saída desejada. Este processo de ajuste, normalmente está associado a um determinado algoritmo de treino e necessita de uma filtragem e seleção de dados para uma aprendizagem criteriosa.

Esta ferramenta é particularmente utilizada em sistemas de modelação complexa onde existe uma forte variabilidade e ruído ou padrões complexos nos resultados conhecidos do sistema. Relativamente às desvantagens, verifica-se uma grande dificuldade em efetuar a escolha apropriada relativamente à arquitetura da rede, à filtragem e preparação dos dados de treino ou à verificação da sua qualidade, dependendo em grande medida da sensibilidade e das experiências realizadas pelo utilizador [6]. Uma outra crítica que se faz frequentemente às RN é a crítica da “caixa negra”, já que o modelo aprendido não é de fácil compreensão ou intervenção por parte do utilizador que controla o processo.

Relacionados com este trabalho, podem ser encontrados outros trabalhos e aplicações que descrevem a utilização das RN, na otimização de desempenho em sistemas flexíveis de produção através de modelos dos sistemas [7], em modelos de previsão em aplicações industriais relacionadas como a previsão do valor de variáveis do processo através da medição passadas de variáveis [8] e no controlo de sistemas industriais como é o exemplo de controlo de braços robotizados usando RN [9].

A forte dependência dos resultados das RN com a experiência e sensibilidade dos utilizadores invalidou a sua utilização neste trabalho, já que uma das premissas principais para a sua conceção é que fosse utilizado por terceiros, podendo estes ter fracas ou nenhuns conhecimentos sobre RN.

2.3 Algoritmos Genéticos

Os Algoritmos genéticos (AG) são ferramentas de modelação, inspiradas nos mecanismos de evolução de populações de seres vivos, que permitem modelar qualquer função dos sistemas, desde que estas sejam matematicamente representáveis.

Trata-se de uma ferramenta de busca e otimização que funciona de uma forma iterativa tentando várias soluções e utilizando a informação obtida neste processo de forma a encontrar soluções cada vez melhores.

Em termos de funcionamento genérico, o algoritmo é inicializado através da criação de uma população de possíveis respostas para o problema a ser tratado. Em seguida é feita

uma análise para que se estabeleça quão bem cada resposta selecionada (indivíduo da população) responde ao problema proposto (início do processo de evolução). Através desta análise são selecionados os indivíduos mais aptos e descartados os menos aptos. Os indivíduos selecionados podem sofrer modificações nas suas características fundamentais e ser recombinados, gerando novos indivíduos que poderão ser introduzidos na população. Este processo pode ser repetido (ao longo de gerações) até que uma solução satisfatória seja encontrada.

Os AG requerem um elevado poder computacional quando se pretende trabalhar com uma população muito grande e ao longo de muitas gerações, sendo normalmente aplicado em problemas complexos de natureza combinatória [10].

Relacionada com este trabalho, existe bibliografia que descreve a utilização de AG na modelação, otimização e controlo de sistemas indústrias de forma a diminuir a dependência e intervenção humana [11] e na otimização do controlo de equipamentos industriais [12].

Como já foi mencionado, os algoritmos genéticos necessitam de uma representação matemática do sistema para proceder à sua otimização. A representação matemática de um sistema industrial é normalmente uma tarefa complexa que implica conhecimento sobre o sistema ou a utilização de outras ferramentas de modelação. A dificuldade de representação matemática do sistema devido à sua complexidade invalidou a utilização desta ferramenta no trabalho realizado.

2.4 Redes de Petri

A rede de Petri (RdP) é uma ferramenta matemática e gráfica de modelação, representação e análise de sistemas de eventos discretos. Esta ferramenta tem sido desenvolvida e ramificada para várias aplicações, possuindo a particularidade de permitir modelar diversos sistemas, como é o caso de sistemas paralelos, concorrentes, assíncronos, não-determinísticos ou com partilha de recursos.

Esta ferramenta pode ser utilizada para a análise das propriedades comportamentais de um sistema e para a avaliação do seu desempenho, assim como para a construção de simuladores de eventos discretos e controladores para o sistema em questão. A sua funcionalidade de previsão está relacionada com o seu forte potencial de simulação.

Entre as várias áreas de aplicação da RdP, destacam-se aplicações típicas como: a automação industrial, a domótica, a avaliação de desempenho de sistemas, os protocolos de comunicação, a gestão de bases de dados ou o controlo e gestão da produção [13].

Esta ferramenta está amplamente divulgada na bibliografia, existindo exemplos da sua aplicação em sistemas industriais na área de modelação e análise de sistemas de produção industriais [14] [15] e automação e controlo flexível de sistemas [16].

Neste trabalho serão utilizadas RdP, pelo que estas serão descritas com mais detalhe no Capítulo 3.

3 FUNDAMENTOS TEÓRICOS

Neste capítulo são introduzidos alguns fundamentos teóricos, fundamentais à descrição e compreensão do trabalho realizado. Estes abrangem várias áreas de conhecimento e são descritos individualmente por secção.

3.1 Sistema

3.1.1 Definições

Para compreender este trabalho torna-se fundamental a noção de sistema. Trata-se de um conceito de fácil intuição, mas cuja definição terá que ser adaptada ao caso que se pretende descrever. Existem no entanto algumas definições de sistema que se podem adaptar de uma forma transversal à maioria dos casos:

- Combinação de elementos que interagem organizados para atingir um ou mais objetivos estabelecidos [17];
- Um conjunto de elementos interligados constituídos para atingir um determinado objetivo realizando uma função especificada [18];
- Um grupo de objetos separados no universo que têm relações mútuas [19].

Através das definições anteriores poderá ser formulada a seguinte definição:

- Um sistema é composto por elementos ou objetos, que interagem e têm relações entre si, no sentido de executar uma função.

Desde o início da sua existência a humanidade esforça-se por conhecer e descrever os sistemas, muitas das vezes no intuito de os poder controlar. O controlo de um sistema é baseado no seu conhecimento, sendo este conhecimento desenvolvido através de abstração, baseada na observação e, se possível, pela experimentação do sistema.

Para compreender e analisar um sistema, existem alguns termos que necessitam de ser definidos.

Uma **entidade** é um objeto de interesse no sistema, sendo um **atributo** uma propriedade de uma entidade. Se a entidade física tempo estiver incluída entre os objetos do sistema, poderão ser analisadas as propriedades temporais ou dinâmicas do sistema em questão. A dinâmica do sistema é determinada pelo comportamento dos objetos do sistema ao longo do tempo. A este comportamento dá-se o nome de **processo**.

O **estado** de um sistema é definido por um conjunto de variáveis que permitem descrever o sistema em qualquer momento (variáveis de estado). Um **evento** é definido como uma ocorrência instantânea que pode alterar o estado do sistema.

O termo **endógeno** é utilizado para descrever as atividades e os eventos que ocorrem dentro de um sistema. O termo **exógeno** é utilizado para descrever as atividades e eventos no universo que afetam o sistema.

No conceito de sistema muitas vezes os termos **entrada(s)** e **saída(s)** são mencionados, tratando-se de objetos do sistema. O sistema interage com o universo através de saídas e é possível interagir com o sistema através de entradas do sistema. Quando os objetos do sistema são variáveis mensuráveis, as entradas e saídas do sistema são normalmente designadas por **variáveis de entrada** e **variáveis de saída** [20].




Figura 2 – Saída(s) e entrada(s) de um sistema.

Outra noção importante é a distinção entre **sistema contínuo**, **sistema discreto** e **sistema híbrido**. Um sistema é contínuo quando é especificado por variáveis contínuas e funções contínuas e é discreto quando é especificado por variáveis/funções discretas ou por relações discretas. Um sistema híbrido é uma combinação de ambos.

A representação discreta de sistemas contínuos é obtida por amostragem de variáveis contínuas em pontos temporais discretos (sistemas de tempo discreto).

Analisando os sistemas discretos e o seu desenvolvimento dinâmico de estado, será importante distinguir os sistemas discretos que evoluem (mudando de estado), em função do tempo ou em função de um determinado evento.

Analisando a Figura 3, é possível observar o comportamento de um sistema de variável discreta “ q ” constituído por quatro estados (de q_1 a q_4), e três eventos (de e_1 a e_3). Os eventos ocorrem em pontos discretos do tempo e as mudanças de estado dependem apenas da ocorrência do evento, ou seja, a ocorrência do evento e a respetiva mudança de estado não estão necessariamente dependentes do tempo. Estes sistemas são denominados de **sistemas de eventos discretos dinâmicos** ou apenas **sistemas de eventos discretos**. A mudança de estados e a ocorrência de eventos são a essência do comportamento dinâmico dos sistemas de eventos discretos.




Figura 3 – Sistema de eventos discretos [19].

Os sistemas podem ser ainda classificados nos seguintes tipos:

- Sistemas Estáticos ou Dinâmicos;
- Sistemas Lineares ou não Lineares;
- Sistemas Variantes no Tempo ou Invariantes no Tempo;
- Sistemas Causais ou Não Causais;
- Sistemas Estáveis, Instáveis ou Criticamente Estáveis.

3.1.1.1 Sistemas Estáticos e Dinâmicos

As saídas de um Sistema Estático, em qualquer instante específico no tempo, são apenas função do estado (ou valor) das entradas nesse instante de tempo, não dependendo do estado das entradas no passado ou no futuro. Estes sistemas também são considerados sistemas sem memória [20].

Por sua vez, as saídas de um Sistema Dinâmico depende do estado das entradas nesse instante, ou nos instantes anteriores ou futuros.

3.1.1.2 Sistemas Lineares e não Lineares

Nos Sistemas Lineares prevalecem os princípios da proporcionalidade e da sobreposição, isto é: considere-se um sistema (neste caso de uma entrada e uma saída) submetido a dois ensaios específicos: um com entrada com valor u_1 e outro com entrada com valor u_2 . Então, sendo g a função que descreve matematicamente o sistema e a_1 e a_2 constantes, o sistema é linear se se verificar:

$$g(a_1u_1 + a_2u_2) = a_1g(u_1) + a_2g(u_2) \quad (1)$$

3.1.1.3 Sistemas Variantes no Tempo e Invariantes no Tempo

Um Sistema Invariante no Tempo é aquele cuja relação entradas-saídas não varia ao longo do tempo, em contraste com o acontece com o Sistema Variante no Tempo, ou seja, a relação entradas-saídas varia ao longo do tempo.

3.1.1.4 Sistemas Causais e Não Causais

Num Sistema Causal ou não antecipatório, a resposta do sistema a determinadas entradas não depende dos estados futuros dessas mesmas entradas. Se a resposta do sistema depender dos estados futuros das entradas do sistema, este é considerado Não Causal.

3.1.1.5 Sistemas Estáveis, Instáveis e Criticamente Estáveis

Um Sistema é Estável se, a uma entrada limitada, responder com uma saída limitada. É Instável se a saída for ilimitada mesmo que a entrada seja limitada. Quando o facto de a saída ser limitada não depende apenas do limite da entrada, um sistema diz-se Criticamente Estável.

3.2 Modelo Matemático de um Sistema

Um sistema físico real pode ser representado por um sistema denominado modelo matemático. Trata-se de uma descrição de um sistema por meio de equações e relações matemáticas, bem como de representações gráficas, baseadas em leis ou princípios físicos definidos pelo sistema, ou seja, o modelo é uma abstração do sistema original.

A vantagem da modelação é evidente, pois permite estudar o comportamento e a estrutura de um dado sistema através do seu modelo sem necessidade de intervir, perturbar ou construir o sistema real.

Na modelação de sistemas nem sempre é possível (ou viável) observar todos os objetos que influenciam o estado do sistema. Na maioria dos modelos apenas são considerados os objetos relevantes para o estudo. Por outro lado, o modelo deve ser suficientemente detalhado para permitir conclusões válidas sobre o sistema real.

3.3 Rede de Petri

Os sistemas de eventos discretos requerem linguagens e ferramentas de modelação específicas para o seu tratamento. Entre as diversas ferramentas existentes (máquinas de estados [19], autómatos híbridos [20], etc.) está a Rede de Petri.

A rede de Petri (RdP) é uma ferramenta matemática e gráfica de modelação, representação e análise de sistemas de eventos discretos. Esta ferramenta deve o seu nome ao matemático Carl Adam Petri que, em 1962, introduziu o conceito RdP [21]. A RdP foi aí proposta para modelar a comunicação entre autómatos (modelos matemáticos de máquinas de estados [20]).

3.3.1 Conceitos Transversais RdP

O processo de modelação usando as RdP utiliza uma ferramenta gráfica que permite representar um conjunto de informação estrutural do sistema de uma forma intuitiva.

A definição formal de RdP é um tuplo, $PN = (P, T, F, W, M_0)$, onde [22]:

- $P = \{p_1, p_2, \dots, p_n\}$ é um conjunto finito, de lugares;
- $T = \{t_1, t_2, \dots, t_m\}$ é um conjunto finito de transições;
- $F \subseteq (P \times T) \cup (T \times P)$ é um conjunto de arcos;
- $W: F \rightarrow \{1, 2, 3, \dots\}$ é a função peso;
- $M_0: P \rightarrow \{0, 1, 2, 3, \dots\}$ é a marcação inicial;
- $P \cap T = \emptyset$ e $P \cup T \neq \emptyset$.

Como acontece com outras ferramentas de modelação, existem várias variantes do modelo de RdP proposto inicialmente. De uma forma transversal a todas as RdP poderemos definir alguns objetos (figuras geométricas) que permitem representar o sistema modelado.

Os **lugares** (representados por círculos): são usados para modelar o estado do sistema, isto é, correspondem às suas variáveis de estado. Podem ser interpretados como uma condição,

um estado parcial do sistema real, uma espera, um procedimento, um conjunto de recursos, um *stock*, um contador, etc.

As **transições** (representadas por barras, linhas ou retângulos): são os eventos que levam o sistema de um estado a outro. A cada transição está associado um peso (w), por omissão 1.

Os **arcos** (representados por setas): são usados para representar a relação de fluxo da rede. A cada um dos arcos está associado um peso, por omissão 1, representado por um número inteiro junto do arco.

As **marcas** (representadas por um ou mais pontos ou números, num lugar): são usadas para representar o valor das variáveis de estado do sistema.

A Figura 4 representa um exemplo de uma pequena linha de montagem modelada usando uma RdP. Os lugares (círculos) p_1 , p_2 e p_3 representam neste sistema a presença da peça A (p_1), presença da peça B (p_2) e montagem da peça A com a B (p_3). A presença da peça A é assinalada por uma marca (ponto) no lugar p_1 , o mesmo acontecendo com a peça B no lugar p_2 . De forma análoga, a ausência de marca no lugar p_3 indica que a montagem da peça A com a B não está a ser executada. No caso do exemplo da Figura 4, os lugares p_1 e p_2 representam a disponibilidade de um recurso, isto é, o número de marcas nestes lugares indica o número de recursos disponíveis.

A barra indicada como t_1 é chamada transição e simboliza um evento. Neste caso, é o início da operação de transferência das peças A e B para a zona de montagem. A distribuição das marcas descreve o estado real do sistema. O estado do sistema muda através de um “disparo” de transição. O disparo de transição é possível caso a condição de transição se verifique. Uma transição t poderá ser disparada se cada lugar ligado (através de arco) à transição contiver, pelo menos, um número de marcas igual ao peso dos arcos dirigidos para a transição. Um disparo de uma transição remove de cada lugar dirigido à transição, um número de marcas igual ao peso dos arcos dirigidos deste lugar para a transição. Quando uma transição é disparada, são representadas em cada lugar de saída da transição o número de marcas igual ao peso dos arcos dirigidos da transição para o lugar de saída. No sistema da Figura 4 o disparo da transição só ocorre quando os lugares p_1 e p_2

estão marcados (Figura 4a), depois da transição o lugar p_3 fica com uma marca (Figura 4) e as marcas dos lugares p_1 e p_2 são removidas.

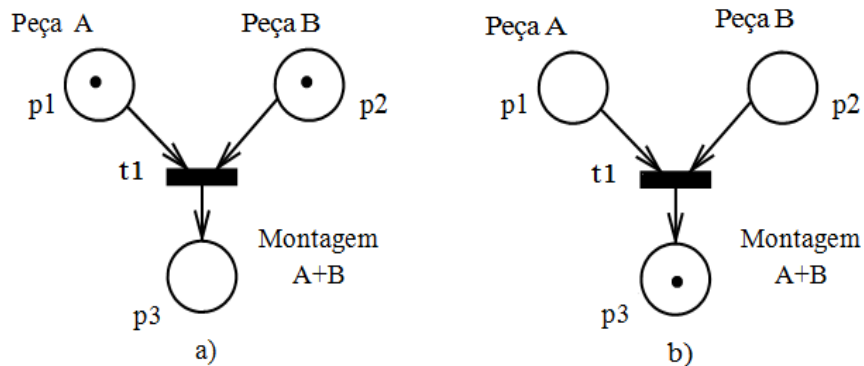


Figura 4 – Exemplo de RdP.

Um lugar é uma entrada para uma transição se existir um arco de ligação direcionado entre este lugar e a transição. Por outro lado, um lugar é uma saída de uma transição, se existir um arco de ligação dirigido da transição para este lugar.

Mencionando novamente o exemplo da linha de montagem, mas desta vez imaginando uma montagem final constituída por uma peça A e duas peças B, teríamos de alterar ligeiramente a representação do sistema, resultando na RdP ilustrada na Figura 5. Em termos de representação em RdP teriam de existir dois arcos a ligar o lugar p_2 à transição t_1 ou o arco que liga o lugar p_2 à transição t_1 teria de ter um peso de 2, isto é, $w(p_2, t_1) = 2$. Em termos práticos, o disparo da transição t_1 só ocorreria quando existissem, pelo menos, duas marcas no lugar p_2 e uma marca no lugar p_1 .

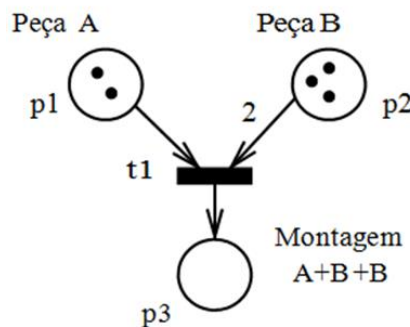


Figura 5 – Exemplo de RdP (Peso arco).

O estado do sistema modelado através da RdP é representado pela repartição de marcas nos lugares da RdP, podendo também ser representado pelo vetor $x_t = [x(p_1), x(p_2), \dots, x(p_n)]$, onde n é o número de lugares da RdP. No exemplo da Figura 5, o vetor x_0 descreve o estado atual (e inicial) do sistema. Neste caso $x_0 = [2, 3, 0]$, isto é, duas marcas no lugar p_1 , três no lugar p_2 e nenhuma no lugar p_3 .

No exemplo da Figura 6, o disparo de transições t_3 e t_6 representam um conflito. Uma marca no lugar p_7 permite o disparo da transição t_3 ou t_6 . Na modelação por RdP os disparos acontecem individualmente, ou seja, no caso da Figura 6 apenas uma transição pode acontecer pois, após a primeira transição se verificar, deixa de haver marcas em P_7 . A resolução de conflitos pode ser condicionada, associando um peso de disparo a cada uma das transições em causa. Na verdade, cada transição imediata tem um peso de disparo associado, mas normalmente o valor padrão é de 1. No caso da Figura 6 os pesos da transição t_3 e t_6 estão fixados em 7 e 3, respetivamente. Note-se, que estes valores geralmente não são mostrados no modelo gráfico. Estes pesos especificam a probabilidade de disparar uma transição em relação aos pesos de todas as outras transições conflitantes. Neste caso a transição t_3 dispara em média em 70% ($7 / (3 + 7)$) dos casos [23].




Figura 6 – Exemplo de RdP (Peso transição).

Uma das variantes da RdP é a Rede de Petri Temporizada, exemplo disto é a Rede de Petri Estocástica (GSPN) e a RdP com transição temporizada.

A GSPN permite dois tipos diferentes de transições no modelo, transições imediatas e transições temporizadas estocásticas. A transição temporizada dispara após um tempo aleatório, segundo uma distribuição exponencial, associado a esta quando habilitada. Na RdP com transição temporizada é associada uma duração temporal (constante) ao disparo da transição. Na Rede de Petri Temporizada as transições podem ser representadas tanto

por barras como por retângulos, para diferenciar transições com disparo imediato de ações com disparo temporizado, respetivamente.

As GSPN e RdP com transição temporizada não foram utilizadas neste trabalho mas torna-se importante mencioná-las no sentido de descrever a abrangência desta ferramenta de modelação assim como as suas potencialidades no contexto de trabalho futuro.

Uma das componentes de modelação das RdP que será importante mencionar, embora também não tenha sido usado neste trabalho, é o arco inibidor. O arco inibidor liga um local de entrada a uma transição e é representado graficamente por um arco que termina com um pequeno círculo (Figura 7). O arco inibidor permite testar se um lugar não está marcado. A presença de um arco inibidor ligado a uma transição muda as condições que permitem o disparo desta, isto é, uma transição não é ativada se um lugar de entrada, ligado através de arcos inibidores possuir marcas. A uma transição poderão estar ligados arcos inibidores e arcos normais, sendo as regras de transição a conjugação das regras de transição de arcos normais e arcos inibidores. Após o disparo da transição são removidas de cada lugar dirigido à transição, o número de marcas igual ao peso dos arcos normais dirigidos deste lugar para a transição, no entanto, não é alterada a marcação no lugar ligado à transição através de arco inibidor. A utilização de arcos inibidores não altera a capacidade de modelação da rede, apenas permite uma modelação mais compacta graficamente, sendo sempre possível criar uma rede equivalente sem arcos inibidores.




Figura 7 – Arco inibidor.

Como ferramenta matemática, as RdP podem ser usadas para criar equações de estado e outros modelos matemáticos que refletem o comportamento do sistema [22]. Isto possibilita a análise formal e funcional do modelo, permitindo que se execute uma verificação das propriedades relacionadas com o comportamento do sistema, como por exemplo as relações de precedência entre eventos, operações simultâneas, sincronização entre eventos ou as atividades repetitivas. Em RdP com transição temporizada e GSPNs pode ainda analisar-se o sistema relativamente a grandezas temporais, como frequência de falhas ou probabilidade de falhas por unidade de tempo [24]. O aumento inerente da complexidade da rede pela aleatoriedade dos eventos leva ao aumento da dificuldade de análise da mesma.

3.3.2 Exemplo de Modelação RdP

As RdP podem ser usadas para modelar propriedades dos sistemas, tais como atividades simultâneas, atividades sequenciais, sincronização, partilha de recursos, etc.

Considere-se um exemplo de um sistema de uma linha de montagem de automóveis, onde dois robôs antropomórficos realizam operações de soldadura num chassis de um veículo numa área de trabalho comum (existindo risco de colisão entre robôs, caso acedam à mesma zona do chassis em simultâneo). Para evitar a colisão, supõe-se que apenas um robô possa aceder ao espaço de trabalho de cada vez.

Neste modelo (ver Figura 8) os lugares p_1, p_2, p_3, p_4 , representam atividades efetuadas pelo robô 1 e os lugares p_5 e p_6 representam atividades do robô 2. O lugar p_7 representa a disponibilidade de um recurso, que neste sistema será o chassis do veículo. As transições t_1 e t_2 efetuam-se sequencialmente, t_2 pode disparar após a transição t_1 , ou seja, para que haja um disparo de t_2 será necessário um disparo de t_1 . As transições t_2 e t_5 estão associadas a atividades simultâneas dos robôs. Estas poderão disparar em paralelo ou assincronamente, representando movimentos ou tarefas que os robôs deverão atingir antes de efetuarem a soldadura no chassis (como por exemplo limpeza de ferramenta de soldadura). O acesso ao espaço de trabalho comum (lugar p_7) requer sincronização das atividades dos robôs, a fim de evitar a colisão. Esta sincronização é realizada pelo mecanismo de exclusão recíproca formado pelos arcos que ligam ao lugar p_7 . O disparo da transição t_3 desabilita a transição

t_6 e disparo da transição t_6 desabilita a transição t_3 , garantindo que apenas um robô poderá aceder ao chassis de cada vez. O disparo de t_4 ou t_7 volta a habilitar t_6 e t_3 .




Figura 8 – RdP com partilha de recurso.

Este processo de modelação garante também a versatilidade e adaptabilidade do sistema, permitindo que, caso um dos robôs seja mais lento numa determinada tarefa (como por exemplo na limpeza da ferramenta de soldadura), o tempo de ciclo de soldadura do chassis não seja fortemente afetado, já que, neste caso, o robô mais rápido iniciará a sua tarefa no chassis, libertando tempo adicional de limpeza para o robô mais lento.

3.4 Previsão

A previsão é importante em muitos aspetos da vida humana. Como indivíduos, tentamos prever o sucesso das nossas vidas pessoais, ocupações e investimentos. Da mesma forma, as organizações fazem grandes investimentos baseados em previsões de mercado.

A previsão pode ser entendida como uma predição de um evento futuro ou estado do sistema. Quando é possível calcular as equações que descrevam de forma determinística o comportamento dos sistemas, é possível efetuar previsões sobre o futuro do sistema.

Quando tal não é possível, procura-se determinar ou estimar o comportamento futuro do sistema a partir das observações do passado.

A necessidade de previsão está normalmente aliada a uma incerteza sobre o futuro. Quando não existe incerteza esta necessidade deixa de fazer sentido. Se todos os eventos do sistema podem ser controlados não existe incerteza sobre o futuro estado do sistema. Mas para muitos sistemas o controlo de todos os eventos não é possível.

O modelo de previsão pode ser desenvolvido usando todo o histórico de eventos e estados ou os resultados existentes sobre um determinado sistema (técnicas quantitativas). Pode também ser desenvolvido a partir das expectativas e opiniões de especialistas (técnicas qualitativas). Pode também ser construído através da combinação das duas técnicas (quantitativa e qualitativa).

As técnicas quantitativas partem do princípio de que as condições ou os acontecimentos que condicionaram o funcionamento do sistema no passado serão válidos no futuro, pelo menos aproximadamente. A aplicação destas técnicas implica a recolha de dados do sistema ao longo do tempo, o tratamento desses dados e a construção de modelos de previsão. A aplicabilidade do modelo de previsão dependerá dos resultados da previsão, isto é, da minimização do erro de previsão.

3.4.1 Séries Temporais

Uma série temporal é definida por uma sequência de observações de uma variável medida em pontos sucessivos no tempo ou ao longo de períodos sucessivos no tempo [25]. Os dados da série temporal podem apresentar padrões e expressar relações estáticas entre valores atuais e passados. Neste caso, é possível construir um modelo matemático de previsão que utiliza os padrões dos dados observados para projetar o futuro.

De forma a identificar mais facilmente padrões nos dados da série temporal, é comum a sua representação gráfica. Estes gráficos podem representar vários tipos de variáveis de diversos sistemas. Como exemplos destas representações pode ter-se a evolução temporal

do preço de um combustível, de uma taxa bancária, do número de peças produzidos numa linha de montagem, etc.

Os modelos de previsão baseados em séries temporais assumem que o futuro é função do passado (utilizam técnicas quantitativas). Estes aplicam propriedades estatísticas ao histórico dos dados de um sistema para especificar um modelo do seu comportamento, de forma a estimar parâmetros desconhecidos. Existem inúmeras técnicas quantitativas baseadas em séries temporais, usadas consoante a série temporal dos dados do sistema que se pretende modelar. De seguida serão mencionadas algumas daquelas que mais amplamente são utilizadas na indústria [26].

3.4.1.1 Média Móvel

A Média Móvel é mais utilizada quando o histórico dos dados do sistema não apresenta tendência ou sazonalidade, ou seja, está-se perante uma série temporal estacionária (a série desenvolve-se aleatoriamente em redor de uma média constante). Este modelo de previsão é construído calculando a média aritmética dos últimos N dados do histórico mais recente [25] (ver equação (2)).

$$P_t = \frac{1}{N} \sum_{i=0}^{N-1} D_{t-1-i} \quad (2)$$

Onde:

P_t = Previsão para o instante t

N = Número de dados mais recentes considerados para o cálculo da Média Móvel

D_{t-1-i} = Dado da série observado no instante $t - 1 - i$

Observe-se que de toda a série de dados apenas N dados mais recentes são considerados. O número de dados escolhidos (N) determina o grau de sensibilidade deste modelo em relação aos dados mais recentes. Quanto maior o valor de N , maior a importância que o passado terá para o cálculo da previsão.

3.4.1.2 Suavização Exponencial

À semelhança da Média Móvel, o modelo de previsão de Suavização Exponencial é normalmente apropriado para séries temporais estacionárias [25]. Este modelo considera todo o histórico do sistema, podendo ser alterado o peso dado a dados mais recentes em detrimento dos passados.

$$P_t = P_{t-1} + \alpha(D_{t-1} - P_{t-1}) \quad (3)$$

Onde:

P_t = Previsão para o instante t

P_{t-1} = Previsão para o instante $t - 1$

D_{t-1} = Dado da série observado no instante $t - 1$

α = Coeficiente de suavização ($0 \leq \alpha \leq 1$)

Trata-se de um modelo que parte da previsão anterior (instante $t-1$) para calcular a próxima previsão (instante t). Quanto maior o valor de α maior o peso dado aos dados mais recentes do sistema. O modelo de Suavização Exponencial requer uma estimativa inicial para P_{t-1} .

A utilização de um valor baixo de α (próximo de 0) implica que pesos maiores serão dados aos dados mais antigos e, conseqüentemente, a flutuação aleatória do presente terá menos impacto na previsão.

3.4.1.3 Suavização Exponencial de Holt

A Suavização Exponencial de Holt é aplicada na modelação de sistemas com histórico de dados que apresentam uma tendência linear (positiva ou negativa). Este método é similar ao método descrito anteriormente (Suavização Exponencial), apresentando a adição de uma nova constante de suavização para modelar a tendência da série.

$$L_t = \alpha D_t + (1 - \alpha)(L_{t-1} + T_{t-1}), \quad (4)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1}, \quad (5)$$

$$P_{t+i} = L_t + iT_t \quad (6)$$

Onde:

P_{t+i} = Previsão para o instante futuro $t + i$

D_t = Dado da série observado no período t

L_t = Valor do nível calculado no instante t

L_{t-1} = Valor do nível calculado no instante $t - 1$

T_t = Valor de inclinação calculado para o instante t

T_{t-1} = Valor de inclinação calculado para o instante $t - 1$

α = Coeficiente de suavização ($0 \leq \alpha \leq 1$)

β = Coeficiente de inclinação ($0 \leq \beta \leq 1$)

O modelo de Suavização Exponencial de Holt requer uma estimativa inicial para T_t e L_t . A previsão é feita adicionando-se ao valor básico de nível (L_t) a tendência (T_t) multiplicada pelo número de instantes futuros (i) que se deseja prever.

3.4.2 Cálculo e Análise de Erros de Previsão

A análise da adequação do modelo de previsão a um determinado sistema, pode ser estudada através da análise dos erros de previsão. Subtraindo o valor de um dado observado no sistema (num determinado instante, D_t) ao previsto pelo seu modelo (no mesmo instante, P_t), é possível calcular o erro da previsão do modelo do sistema para aquele instante. Genericamente, quanto menor o erro, mais precisa será a previsão.

Existem vários métodos utilizados para a análise global do modelo de previsão. De seguida descrevem-se os mais utilizados:

A Média Absoluta dos Erros (MAE) é uma medida de precisão de previsão que evita o problema de erros de previsão positivos e negativos, já que estes tendem a compensar-se se somados diretamente. A MAE é calculada através da média do valor absoluto do erro de previsão:

$$MAE = \frac{1}{n} \sum_{t=1}^n |D_t - P_t| \quad (7)$$

A Média do Quadrado dos Erros (MQE) também evita o problema de erros de previsão positivos e negativos dando ênfase a erros elevados de previsão. A MQE é calculada através da média do quadrado do erro de previsão:

$$MQE = \frac{1}{n} \sum_{t=1}^n (D_t - P_t)^2 \quad (8)$$

A Média Absoluta Percentual dos Erros (MAPE) é calculada sob forma de percentagem, permitindo comparar erros de previsão de séries distintas (com diferentes escalas e unidades).

$$MAPE [\%] = \frac{1}{n} \sum_{t=1}^n \left| \frac{(D_t - P_t)}{D_t} \times 100 \right| \quad (9)$$

3.5 OEE

O OEE (*Overall Equipment Effectiveness*), componente do conceito TPM (*Total Productive Maintenance*), surgiu no Japão na última metade do século passado. Trata-se de um método de medição de eficiência de um equipamento e/ou indústria, focado na gestão dos equipamentos e redução de perdas [27].

A principal razão da medição de eficiência nos processos industriais, é o diagnóstico das perdas e sua respetiva correção ou otimização, de forma a aumentar a eficiência dos equipamentos e/ou indústrias, minimizando os investimentos.

3.5.1 Conceito OEE

A forma mais simples de descrever o conceito OEE é através de um exemplo concreto. Será mencionado o exemplo de uma linha de montagem industrial para descrever este conceito.

Uma linha de montagem pode ser tratada como um sistema cuja função é produzir produtos de qualidade. Este produto de qualidade é aquele que o cliente está disposto a pagar (comprar). O conceito de qualidade, neste caso, está assente em determinadas especificações de produto que terão de ser cumpridas para que o produto seja aceite pelo cliente. Quando, numa linha de montagem, são produzidos produtos que não cumprem as especificações estabelecidas, estes são rejeitados e são classificados como não conformes.

O controlo de qualidade dos processos industriais está largamente documentado [28] [29] [30]. Um dos principais procedimentos deste controlo passa pela clara distinção dos pontos a controlar no produto e das suas especificações. Este procedimento permite classificar o produto rejeitado e discriminar quais as principais causas de rejeição. Ao estudar as principais causas de rejeição e o processo produtivo, será possível encontrar a(s) causa(s) raiz que origina(m) os principais defeitos no produto e atuar no processo corrigindo a(s) causa(s) que origina(m) esses defeitos [30].

A produção de produto não conforme pode ser classificada como **Perdas de Qualidade**. A percentagem de Perdas de Qualidade pode ser calculada através da relação percentual entre o total de produto não conforme e a quantidade máxima teórica de produto que seria possível produzir no tempo planeado de produção.

$$\text{Perdas de Qualidade [\%]} = \frac{\text{Total de produto não conforme}}{\text{Total máximo teórico de produto}} \times 100$$

A percentagem de **Produto com Qualidade** pode ser calculada através da relação percentual entre o total de produto com qualidade e a quantidade máxima teórica de produto que seria possível produzir no tempo planeado de produção.

$$\text{Produto com Qualidade [\%]} = \frac{\text{Total de produto com qualidade}}{\text{Total máximo teórico de produto}} \times 100$$

Um dos aspetos mais importantes da gestão da produção é o desempenho da produção. Para qualquer linha de montagem deverá ser possível determinar a cadência ideal ou teórica a que o produto é produzido, ou seja, deverá ser possível estimar o tempo ideal ou

teórico para a execução do produto (executado a uma velocidade ideal ou teórica). Quando uma linha de montagem está a produzir a um tempo acima do tempo ideal ou teórico de execução por produto, existirá um decréscimo no número de produtos produzidos. O produto não produzido devido ao não cumprimento do tempo ideal ou teórico de produção pode ser classificado como **Perdas de Desempenho** (ou **Perdas de Velocidade**).

A produção numa linha de montagem só é possível caso estejam reunidos todos os recursos para que tal aconteça (operadores especializados, componentes em quantidades necessária, equipamentos operacionais, etc.). Estas condições reúnem-se em determinados intervalos de tempo tornando possível planejar a produção para esses períodos. Quando uma produção se inicia, esta deverá decorrer durante um determinado período de tempo previamente planeado. Caso a produção tenha de ser interrompida durante o período em que era suposto estar a produzir (paragem não planeada), existirá uma perda no número de produtos produzidos. Isto poderá acontecer devido a uma avaria de um equipamento, falta de componentes, falhas de energia, etc. O produto não produzido devido a paragens não planeadas pode ser classificado como **Perdas de Disponibilidade**.

A percentagem de Perdas de Disponibilidade pode ser calculada através da relação percentual entre o total de produto não produzido devido a paragens não planeadas e a quantidade máxima teórica de produto que seria possível produzir no tempo planeado de produção.

$$\text{Perdas de Disponibilidade}[\%] = \frac{\left(\frac{\text{Tempo total de paragem não planeado}}{\text{Tempo ideal ou teórico}}\right)}{\text{Total máximo teórico de produtos}} \times 100$$

As Perdas por Desempenho podem ser calculadas através da contabilização do produto que idealmente deveria ter sido produzido e não foi contabilizado nem como produto com qualidade, nem fora de especificação, nem perdido por paragens não planeadas.

$$\begin{aligned} \text{Perdas por Desempenho}[\%] &= 100\% - \text{Produto com Qualidade} [\%] \\ &\quad - \text{Perdas de Disponibilidade}[\%] - \text{Perdas de Qualidade} [\%] \end{aligned}$$

Nesta abordagem são definidas três categorias de perdas que poderão ser tratadas também como indicadores de eficiência global do sistema: indicadores de Qualidade, Desempenho e de Disponibilidade.

O indicador de **Qualidade** pode ser calculado através da relação percentual entre a quantidade de produtos produzidos com qualidade e a quantidade total de produtos produzidos. Uma Qualidade de 100% indica que não existe produto rejeitado por problemas de qualidade.

$$Qualidade[\%] = \frac{\textit{Total de produtos produzidos com qualidade}}{\textit{Total de produtos produzidos}} \times 100$$

O indicador de **Disponibilidade** pode ser calculado através da relação percentual entre o tempo total de operação e o tempo planeado de produção. O tempo total de operação é contabilização através do tempo em que o sistema está efetivamente em produção (uma parte do tempo planeado de produção). Uma Disponibilidade de 100% indica que o sistema está a funcionar sem paragens não planeadas. A Disponibilidade nunca será superior a 100%, já que o tempo total de operação nunca poderá ser superior ao tempo planeado de operação.

$$Disponibilidade[\%] = \frac{\textit{Tempo total de operação}}{\textit{Tempo planeado de operação}} \times 100$$

O indicador de **Desempenho** fornece informação sobre o cumprimento do tempo ideal ou teórico de operação por produto (velocidade nominal por produto). Pode ser calculado através da relação percentual entre o tempo ideal total de operação (tempo total necessário para efetuar o total de produto produzido, cumprindo o tempo ideal ou teórico de operação) e o tempo total de operação. Um Desempenho de 100% indica que o sistema está a produzir produto, cumprindo o tempo ideal de operação.

$$Desempenho[\%] = \frac{\textit{Tempo ideal de operação}}{\textit{Tempo total de operação}} \times 100$$

O **OEE** mede a performance do sistema e resulta da fusão dos indicadores de Qualidade, Desempenho e Disponibilidade. Matematicamente pode ser calculado através da multiplicação destes três. Desta forma, o OEE indica se o sistema está produzir produto de qualidade à velocidade nominal, cumprindo o planeamento.

$$OEE = Disponibilidade \times Desempenho \times Qualidade$$

O estudo dos vários indicadores envolvidos no cálculo do OEE permite uma fácil deteção das principais perdas do processo. Esta abordagem permite efetuar otimizações nos sistemas, melhorando assim a sua eficiência.

3.6 Carta de Controlo

A Carta de Controlo (CC) é uma ferramenta de controlo estatístico do processo (*Stochastic Process Control – SPC*) que permite monitorizar a variabilidade dos processos e estimar os seus parâmetros [31]. Esta representa uma determinada característica ou variável mensurável do processo e indica se o processo se encontra sob controlo estatístico. Esta ferramenta utiliza para tal limites de controlo permitindo conclusões em tempo real sobre o processo.




Figura 9 – Exemplo de CC (adaptado de [31]).

As variáveis analisadas podem seguir vários tipos de distribuição, sendo a mais comum a distribuição Normal [31]. A imprevisibilidade do tipo de distribuição que seguem as variáveis analisadas do processo, dificulta a análise estatística dos processos e o estabelecimento de limites de controlo.

A maioria das ferramentas de SPC utiliza o teorema do limite central [31], que enuncia que a soma de subgrupos de n variáveis independentes se aproximará a uma distribuição Normal, independentemente do tipo de distribuição das variáveis individuais (esta aproximação melhorará com o aumento do tamanho da amostra). O mesmo princípio é válido para a média de n variáveis independentes. Na maioria das aplicações [31], a CC é construída através da média de subgrupos de amostras da variável analisada pois, independentemente da distribuição dos valores individuais da variável, a distribuição da média desses subgrupos aproximar-se-á a uma distribuição Normal.

3.6.1 Carta de Controlo de Média e Amplitude

Uma das CC mais utilizada é a de Média e Amplitude, permitindo monitorizar a tendência central do processo (através da média) e a sua dispersão ou variabilidade (através da amplitude). Estas CC são preparadas aos pares existindo uma CC para a média e outra para a amplitude.

As CC Média e Amplitude são construídas através de uma amostra contendo observações da característica que se pretende monitorizar. Estas amostras são divididas em m subgrupos de n observações de uma mesma variável e é calculada a média de cada subgrupo.

$$\bar{X} = \frac{X_1 + X_2 + \dots + X_n}{n} \quad (10)$$

Cada média calculada é representada por ordem de medição na CC de médias, através de um ponto, sendo depois ligadas entre si através de uma linha. A linha central da CC das médias é calculada através da média das médias.

$$LC = \bar{\bar{X}} = \frac{\bar{X}_1 + \bar{X}_2 + \dots + \bar{X}_m}{m} \quad (11)$$

De seguida, são calculadas as amplitudes médias, que serão utilizadas para a estimativa do desvio-padrão da distribuição. Assim, para cada subgrupo de tamanho n é calculada a amplitude R .

$$R = X_{max} - X_{min} \quad (12)$$

Cada amplitude calculada é representada por ordem de medição na CC de amplitudes, através de um ponto, sendo ligadas entre si através de uma linha. A linha central da CC de amplitudes é calculada através da média das amplitudes, \bar{R} .

$$\bar{R} = \frac{R_1 + R_2 + \dots + R_m}{m} \quad (13)$$

Para o cálculo dos limites de controlo da CC das médias será necessário estimar o desvio-padrão. Considerando três desvios-padrão (segundo a distribuição normal compreende 99.73% dos valores das médias dos subgrupos), os limites de controlo para a CC das médias poderão ser calculados diretamente através das equações (14) e (15), já que pode ser provado que o desvio-padrão desta distribuição depende apenas da amplitude média e do tamanho do subgrupo n [31]. O valor da constante A_2 depende do número de elementos dos subgrupos n (ver Tabela 1).

$$LSC = \bar{\bar{X}} + A_2 \times \bar{R} \quad (14)$$

$$LIC = \bar{\bar{X}} - A_2 \times \bar{R} \quad (15)$$

Os limites de controlo para a CC de amplitudes poderão ser calculados diretamente através das equações (16) e (17). O valor das constantes D_3 e D_4 também depende do número de elementos dos subgrupos n (ver Tabela 1).

$$LSC = D_4 \times \bar{R} \quad (16)$$

$$LIC = D_3 \times \bar{R} \quad (17)$$

Esta ferramenta é tipicamente utilizada em amostras que permitam construir entre 20 a 25 subgrupos de tamanho n (tipicamente n está entre 2 e 5). É possível trabalhar com menos dados, porém os limites de controlo poderão não ser confiáveis [31].

n	A_2	D_3	D_4
2	1,880	0	3,267
3	1,023	0	2,574
4	0,729	0	2,282
5	0,577	0	2,114
6	0,483	0	2,004
7	0,419	0,076	1,924
8	0,373	0,136	1,864
9	0,337	0,184	1,816
10	0,308	0,223	1,777
11	0,285	0,256	1,744
12	0,266	0,283	1,717
13	0,249	0,307	1,693
14	0,235	0,328	1,672
15	0,223	0,347	1,653

Tabela 1 – Valores das constantes A_2 , D_3 , D_4 [31].

3.6.2 Análise de Carta de Controlo

Num processo analisado através de CC é esperado que a distribuição seja aleatória nos limites de controlo superior e inferior calculados. Poderemos concluir que o processo está fora de controlo estatístico quando [31]:

1. Um ou mais pontos não se encontram dentro dos limites de controlo calculados;
2. Dois de três pontos consecutivos são maiores que dois desvios-padrão do mesmo lado da linha central;

3. Quatro de cinco pontos consecutivos são maiores que um desvio-padrão do mesmo lado da linha central;
4. Existem oito pontos consecutivos no mesmo lado da linha central;
5. Existem seis pontos consecutivos, com tendência crescente ou decrescente;
6. Existem quinze pontos consecutivos entre a linha central e um desvio-padrão do mesmo lado da linha central (todos os pontos estão acima ou estão abaixo da linha central);
7. Existem catorze pontos consecutivos, alternando acima e abaixo da linha central;
8. Existem oito pontos consecutivos maiores que um desvio-padrão a partir da linha central (acima ou abaixo da linha central).

Na Figura 10 é possível observar um exemplo da violação da terceira regra enunciada, isto é, existem quatro pontos consecutivos maiores que um desvio-padrão do mesmo lado da linha central (parte positiva).




Figura 10 – Exemplo de violação da regra 3 (adaptado de [31]).

3.7 K-means Clustering

A prática de classificar os objetos de acordo com semelhanças existentes entre eles, é uma prática à muito utilizada numa ampla variedade de domínios de aplicação. Este tipo de classificação permite organizar estes objetos em conjuntos de objetos semelhantes

(*clusters*). Esta prática é classificada na bibliografia por *clustering* (agrupamento). A classificação dos objetos é conseguida por um conjunto de variáveis mensuráveis ou por relações entre objetos.

A análise de *clusters* potencia a compreensão sobre os objetos de tal forma que os objetos agrupados num *cluster* são mais semelhantes entre si, do que o são em relação a objetos em outros *clusters*.

O K-means é uma das técnicas de *clustering* mais antigas e mais utilizadas. A pesquisa sobre K-means teve o seu início a meio do século passado e tem sido realizada por vários investigadores de diferentes áreas [32].

O K-means é um algoritmo usado para dividir automaticamente um conjunto de objetos em *clusters* de k de objetos, sendo sempre matematicamente convergente [33]. A forma mais simples de descrever o funcionamento deste algoritmo é através de um exemplo e da análise do seu fluxograma de funcionamento (Figura 14).

Considerem-se quatro objetos dispostos num plano e que é possível classifica-los através das suas coordenadas cartesianas x e y . A representação dos objetos e das suas respetivas coordenadas pode ser observada na Tabela 2.

	Coordenada x [m]	Coordenada y [m]
Objeto A	1	1
Objeto B	2	1
Objeto C	3	2
Objeto D	4	2

Tabela 2 – K-means – Coordenadas dos objetos.

A representação gráfica dos objetos no plano pode ser observada na Figura 11. Esta representação facilita a compreensão da dinâmica do algoritmo.

Numa fase inicial é necessário definir o número de *clusters*, k , que se deseja (normalmente menor que o número total de objetos existentes). Após a escolha do valor k , é atribuído a cada *cluster* um conjunto de características (coordenadas, neste exemplo) com valor aleatório. Esta inicialização estocástica influencia os resultados do algoritmo, logo o resultado apresentado pode ser diferente a cada aplicação.

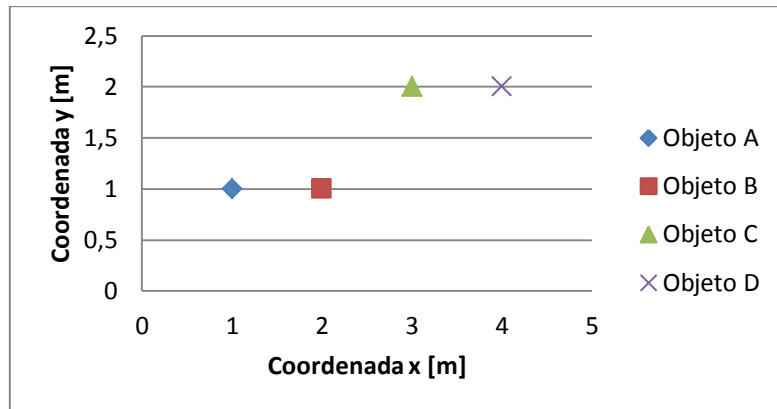


Figura 11 – K-means – Representação dos objetos no plano.

Para o exemplo mencionado é estabelecido o valor k igual a dois, isto é, são definidos dois *clusters* e inicializados aleatoriamente com as coordenadas do objeto A e do objeto B, respetivamente. Após a inicialização dos *clusters* é calcula a distância de cada objeto a cada *cluster* (neste exemplo é calculada a distância euclidiana). O cálculo de cada distância para este exemplo é apresentado na Tabela 3.

	Cluster 1	Cluster 2
Objeto A	0 m	1 m
Objeto B	1 m	0 m
Objeto C	2.24 m	1.41 m
Objeto D	3.16 m	2.24 m

Tabela 3 – Exemplo do cálculo de distâncias para o algoritmo K-means.

Através da análise das distâncias calculadas, cada objeto é atribuído ao *cluster* mais próximo, ou seja, o objeto A irá ser atribuído ao *Cluster* 1 e os objetos B, C e D ao *Cluster* 2.

Conhecendo os membros de cada *cluster*, são calculados os centróides destes. O *Cluster 1* tem um elemento, logo o seu centróide será coincidente com o seu elemento. O *Cluster 2* possui três elementos e o seu centróide será a média aritmética das coordenadas dos seus elementos.




Figura 12 – K-means - Resultado da primeira iteração do exemplo.

A partir deste ponto é novamente calculada a distância de cada objeto ao centróide de cada *cluster*, repetindo-se o ciclo até não existir alteração na atribuição de objetos a cada *cluster*, face à última iteração. No caso deste exemplo o algoritmo acabará por agrupar o objeto A e B no *Cluster 1* e o objeto C e D no *Cluster 2* (Figura 13).




Figura 13 – K-means - Resultado final do exemplo.

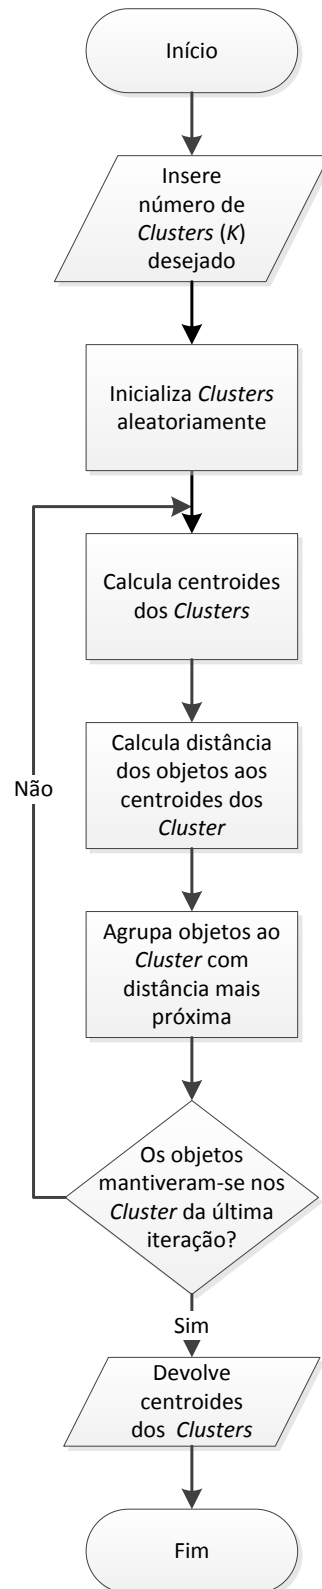


Figura 14 – Fluxograma do algoritmo K-means.

4 METODOLOGIA DESENVOLVIDA

Neste capítulo é descrita a metodologia utilizada para a construção da ferramenta informática desenvolvida para a modelação, previsão e análise de sistemas produtivos industriais.

A ferramenta informática desenvolvida está suportada por automação industrial desenvolvida para o efeito que permite a recolha de dados do sistema de uma forma automática. A aplicação informática desenvolvida para a modelação, previsão e análise de sistemas produtivos foi desenvolvida na linguagem C# e manipula dados armazenados em base de dados (BD) através da linguagem SQL.

As figuras apresentadas neste capítulo foram retiradas da ferramenta informática desenvolvida.

4.1 Descrição do Sistema

Uma linha de montagem industrial pode ser tratada como um sistema, sendo a sua função a montagem (produção ou fabrico) de produtos. Este sistema é normalmente constituído por máquinas (ou equipamentos) e trabalhadores que operam conjuntamente, transformando e/ou integrando componentes e/ou materiais, com o objetivo de produzir produtos de qualidade. O conceito qualidade, neste caso, está assente no cumprimento de especificações de produto para que este possa ser aceite pelo cliente. Por sua vez, o cumprimento das especificações de produto está dependente de todos os objetos do sistema.

A linha de montagem (o sistema) interage com o universo através de saídas, e é possível interagir com a linha de montagem através de entradas. As saídas e entradas poderão ser mensuráveis e poderão ser tratadas como variáveis de saída e entrada. Como variáveis de saída podemos considerar a quantidade de peças produzidas com qualidade, a quantidade de peças produzidas sem qualidade, o número de peças que não foram produzidas devido a uma avaria de um equipamento, etc. Como variáveis de entrada do sistema poderemos

considerar os trabalhadores (operadores) que trabalham na linha num determinado instante, o número de horas que um determinado equipamento efetuou desde a última manutenção, a origem do lote dos componentes ou materiais que estão a ser transformados e/ou integrados na linha, etc.

A alteração do valor das variáveis de entrada poderá afetar a(s) saída(s) do sistema, ou seja, as saída(s) do sistema são função do valor da(s) sua(s) variáveis entrada(s) (e em alguns sistemas, função do estado do sistema).

Nesta fase é importante salientar alguns aspetos importantes sobre os objetos do sistema e os seus limites de interação. Muitos dos componentes, materiais transformados e/ou integrados pelas linhas de montagem são provenientes de outros sistemas, podendo estes conter problemas que irão afetar o produto final. Suponha-se que a linha de montagem integra no produto um parafuso, fornecido por um produtor de parafusos. Por sua vez este fornecedor possui um equipamento que tem um mau funcionamento durante as primeiras duas horas de funcionamento do dia e produz parafusos fora de especificação. A integração de um parafuso fora de especificação, pela linha de montagem, causa um problema no produto produzido. Neste caso, o resultado das saídas do sistema depende de variáveis externas ao sistema, ou seja, a qualidade do produto à saída da linha de montagem depende da qualidade do parafuso que é fornecido à linha (atividade exógena). Assim, as variáveis que influenciam o funcionamento da máquina que produz parafusos são entradas do sistema, já que interagem com este.

Por outro lado, se entre os objetos dos sistemas estiverem seres humanos (operadores), estes são suscetíveis a várias influências externas ao sistema. O desempenho de cada indivíduo na execução de uma determinada tarefa está sujeito a várias influências externas ao sistema que integram. O número de horas de descanso, o seu conforto térmico, o seu estado de saúde e estado de espírito, entre outros fatores, poderão afetar o seu desempenho na execução de uma determinada tarefa. No entanto, se estes indivíduos pertencem ao conjunto de objetos do sistema, quando estão a trabalhar numa linha de montagem, as variáveis que afetam o seu desempenho passam a ser variáveis de entradas desse sistema.

Será importante também salientar a avaliação das especificações ou qualidade do produto. Alguns dos produtos fornecidos para a indústria automóvel dependem de uma avaliação “sensorial” humana (*haptic* [34]), como por exemplo, a sensação de toque do produto, a força de atuação de um elemento mecânico, o ruído provocado pela atuação de um botão, etc. A avaliação destas especificações de produto está sujeita a uma análise humana para a aceitação de produto e depende dos critérios do operador que a está a fazer. No limite, o mesmo produto pode estar no limiar da aceitação para um determinado operador e no limiar da rejeição para outro operador distinto. Isto faz com que o sistema possa ser caracterizado como tendo um comportamento diferente consoante o operador que faz a análise.

Para qualquer sistema existirá um número finito de entradas que tem a capacidade de interagir com o sistema, sendo por vezes difícil a sua identificação. A identificação destas entradas requer conhecimento sobre o sistema que se pretende modelar e, caso este conhecimento seja pobre, existirão variáveis importantes para a modelação que não serão contempladas afetando o detalhe do modelo e os seus resultados.

4.2 Modelo do Sistema

Numa linha de montagem, poderá ser definida uma quantidade de produtos (com qualidade ou sem qualidade) que será possível produzir numa hora, estando a linha a funcionar à velocidade máxima. Esta quantidade máxima de produtos por hora pode ser tratada como capacidade máxima horária.

Através do conceito OEE, a produção horária da uma linha de montagem pode ser descrita através do seu modelo e representada através de uma RdP, como no exemplo da Figura 15. O modelo apresentado representa o sistema para uma determinada hora considerando quatro variáveis de saída do sistema, sendo estas a quantidade de peças (produto) produzidas com qualidade, a quantidade de peças não produzidas por perdas por desempenho, a quantidade de peças não produzidas por perdas por disponibilidade e a quantidade de peças produzidas mas que se encontram fora da especificação (perdas por qualidade).

O exemplo da Figura 15 representa o modelo do sistema para uma hora de produção analisada, isto é, 90,26% da capacidade máxima dessa hora seria produto com qualidade, 5,68% da capacidade máxima seria produto não produzidas por perdas por desempenho, 1,81% da capacidade máxima seria produzido por perdas por disponibilidade e 2,25% da capacidade máxima seria produto produzido fora da especificação. Estas percentagens estão modeladas através do peso das transições T2, T3, T4, T5.

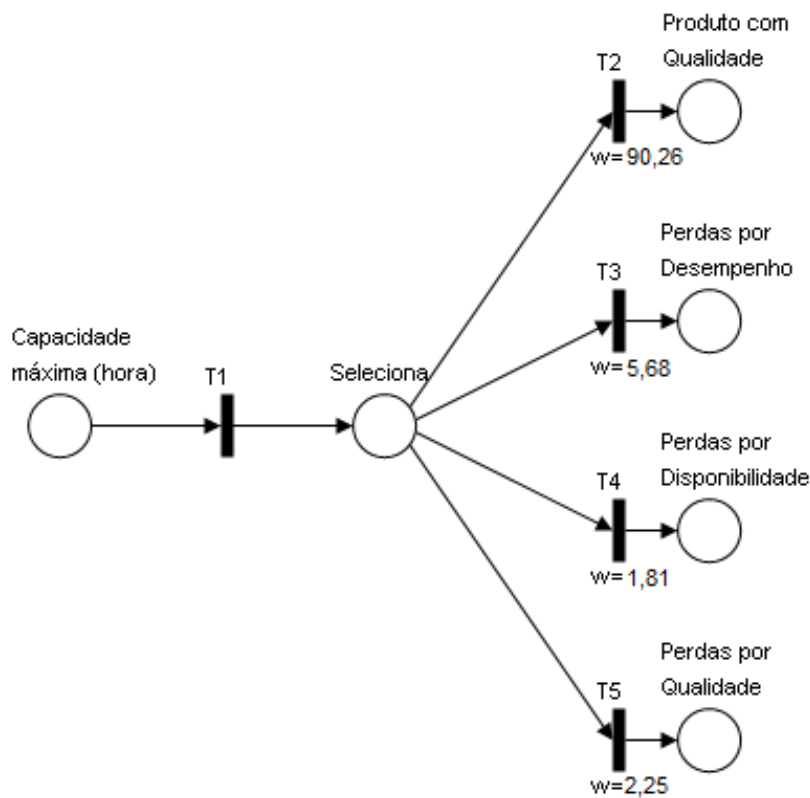


Figura 15 – RdP Modelo horário do sistema.

O exemplo seguinte descreve a metodologia utilizada para a criação do modelo horário de um sistema, considerando-se como sistema uma linha de montagem com capacidade máxima horária de 267 peças.

Numa primeira fase, será necessário calcular as percentagens de cada saída do sistema, para cada hora de produção (amostragem horária). Para tal, foi analisada uma hora de produção com um planeamento de produção que ocupava todo o tempo de análise (3600 segundos). Nesta hora foram produzidas 241 peças com qualidade, 6 peças fora de

especificação e existiu uma paragem não planeada de 65 segundos, devido a uma avaria de um equipamento.

A partir da capacidade máxima horária é possível calcular o tempo ideal ou teórico, para a produção de uma peça.

$$\text{Tempo ideal ou teórico}[s] = \frac{3600 \text{ segundos}}{267 \text{ peças}} = 13,48 \text{ segundos}$$

Ou seja, para uma paragem não planeada de 65 segundos, poderá calcular-se o número de peças não produzidas:

$$\text{Perdas por Disponibilidade} = \frac{65 \text{ segundos}}{13,48 \text{ segundos}} = 4,82 \text{ peças}$$

Analisando os resultados obtidos poderão retirar-se as seguintes percentagens:

$$\text{Produto com Qualidade}[\%] = \frac{241 \text{ peças}}{267 \text{ peças}} \times 100\% = 90,26\%$$

$$\text{Perdas por Qualidade}[\%] = \frac{6 \text{ peças}}{267 \text{ peças}} \times 100\% = 2,25\%$$

$$\text{Perdas por Disponibilidade}[\%] = \frac{4,82 \text{ peças}}{267 \text{ peças}} \times 100\% = 1,81\%$$

$$\text{Perdas por Desempenho}[\%] = 100\% - 90,26\% - 2,25\% - 1,81\% = 5,68\%$$

A linha de montagem pode ser descrita, na hora em análise, através do seu modelo e representada na RdP da Figura 15.

A hora analisada poderá ser caracterizada pelo estado das entradas do sistema durante o período de análise. Por exemplo, a hora de análise poderá ter sido a oitava hora do dia de uma segunda-feira de Maio, os operadores que estiveram a trabalhar na linha foram o

“Operador A” e o “Operador C”, foi produzida a referência de produto “Produto Azul”, o lote de parafusos proveio da máquina 1 do “Fornecedor E”, etc. Quanto mais discriminativa for a identificação dos objetos que interagem com o sistema, mais detalhada será a caracterização da hora.

As entradas do sistema poderão ser tratadas como variáveis lógicas e poderão ser construídas várias tabelas para representar o estado destas, durante a hora de análise.

Dia da Semana	Segunda-feira	Terça-feira	Quarta-feira	Quinta-feira	Sexta-feira	Sábado	Domingo
Estado	Verdadeiro	Falso	Falso	Falso	Falso	Falso	Falso

Tabela 4 – Combinação de estados das entradas (Dias da Semana).

Mês do Ano	Janeiro	Fevereiro	Março	Abril	Maio	Junho	...
Estado	Falso	Falso	Falso	Falso	Verdadeiro	Falso	...

Tabela 5 – Combinação de estados das entradas (Mês do Ano).

Hora do Dia	...	Hora 8	Hora 9	Hora 10	Hora 11	Hora 12	...
Estado	...	Verdadeiro	Falso	Falso	Falso	Falso	...

Tabela 6 – Combinação de estados das entradas (Hora do dia).

Operador	Operador A	Operador B	Operador C	Operador D	Operador E	Operador F	...
Estado	Verdadeiro	Falso	Verdadeiro	Falso	Falso	Falso	...

Tabela 7 – Combinação de estados das entradas (Operador).

Referência	Produto Verde	Produto Azul	Produto Branco	Produto Vermelho	Produto Cinza	Produto Amarelo	...
Estado	Falso	Verdadeiro	Falso	Falso	Falso	Falso	...

Tabela 8 – Combinação de estados das entradas (Referência).

Fornecedor de Parafusos	Fornecedor A	Fornecedor B	Fornecedor C	Fornecedor D	Fornecedor E	Fornecedor F	...
Estado	Falso	Falso	Falso	Falso	Verdadeiro	Falso	...

Tabela 9 – Combinação de estados das entradas (Fornecedor de Parafusos).

Para uma determinada hora analisada teremos um conjunto de entradas do sistema que estarão no estado “Verdadeiro” (ou “ativas”) e outras que estarão no estado “Falso”. Para caracterizar o dia da semana existirão sete entradas lógicas (uma para cada dia da semana), doze para o mês do ano, vinte e quatro para a hora do dia e a mesma lógica para as restantes. Estas variáveis de entrada também poderão ser agrupadas, ou seja, “Dia da semana”, “Mês do ano”, “Hora do Dia”, “Operador”, etc.

As variáveis de saída consideradas para o modelo que representa o sistema, na hora analisada, poderão ser associadas a uma combinação dos estados das variáveis de entrada do sistema durante o período de análise e guardados em BD, ou seja, para cada hora analisada serão guardados os resultados obtidos nas saídas do sistema e o estado em que se encontravam as variáveis de entrada. Esta associação de resultados permitirá efetuar um estudo de sensibilidade ao sistema e desenvolver ferramentas de previsão dos resultados futuros das saídas do sistema, que serão descritos ao longo deste trabalho.

Na ferramenta informática desenvolvida, apenas são analisadas e recolhidas para a BD horas de produção com, no mínimo, cinquenta minutos planeados de produção (mínimo de tempo planeado de produção definido para construção de um modelo horário). A verificação das variáveis de entrada ativas no sistema, a cada hora, é efetuado de uma forma automática através de automação industrial desenvolvida para o efeito. O cálculo dos pesos das transições da RdP do modelo horário do sistema e o respetivo armazenamento em BD, com associação da combinação dos estados das variáveis de entrada, também é efetuado de uma forma automática através de um IPC (computador industrial) a cada hora analisada.

Uma das principais motivações para a utilização de linhas de montagem é a produção em quantidade e com qualidade, minimizando os custos [35]. Será então espectável que uma

linha de montagem seja interpretada (quando possível) como um sistema estático (sem memória), isto é, o produto que está a sair da linha num determinado instante depende unicamente do estado das variáveis de entrada do sistema nesse preciso instante. Se uma linha de montagem se encontrar com uma percentagem de rejeição elevada, num determinado instante, existirão objetos no sistema que estão a provocar este desempenho. No instante em que conseguimos interagir com o sistema e alterar o estado desses objetos a percentagem de rejeição irá alterar-se.

Durante a análise de cada hora de produção, tendencialmente poderá haver casos em que a hora analisada possa ter a mesma combinação do estado de entradas, que uma hora analisada no passado. Como exemplo, se apenas tiverem sido consideradas três variáveis de entrada para o sistema, sendo estas o dia da semana, a hora do dia e operador que está a operar na linha, existirão algumas horas com a mesma combinação do estado das entradas, ou seja, o “Operador A” vai produzir na oitava hora do dia em várias segundas-feiras. Nestes casos, seria pressuposto que os resultados das saídas do sistema fossem iguais aos registados no passado (já que o sistema é interpretado como estático) quando a mesma combinação dos estados das variáveis de entrada se verificasse. Este pressuposto peca pela falta de identificação de entradas do sistema, isto é, como apenas foram consideradas três variáveis de entrada do sistema, poderão existir muitas mais que afetam o estado do sistema que não foram consideradas na análise. Neste exemplo pode existir uma acentuada variação nos resultados das saídas, para a mesma combinação do estado das entradas, devido ao défice de variáveis de entradas consideradas para o sistema.

O resultado das saídas para horas distintas, mas com a mesma combinação do estado das entradas, previsivelmente será igual ou similar, caso tenham sido identificadas as entradas do sistema que mais variações provocam nos resultados das saídas. Caso a similaridade entre resultados não se verifique, tal pode significar que existem entradas do sistema que não foram identificadas e deverão ser consideradas na análise.

A existência de variação nos resultados obtidos, para a mesma combinação do estado das entradas, poderá também ser reflexo de comportamentos de aprendizagem ou evolução do processo produtivo. Um comportamento de aprendizagem poderá ser exemplificado pelo facto de um ou mais operadores (entradas do sistema) melhorarem o desempenho na

execução de uma tarefa ao longo do tempo. O comportamento evolutivo poderá dever-se à melhoria contínua do processo produtivo [36] levando à melhoria dos resultados obtidos no processo para a mesma combinação do estado de entradas ao longo das horas analisadas. O comportamento evolutivo e de aprendizagem normalmente provocam uma tendência crescente ou decrescente no resultado das saídas do sistema ao longo das horas analisadas. O gráfico da Figura 16 demonstra este tipo de comportamento: para a mesma combinação do estado das entradas, os resultados da saída Produto com Qualidade apresenta uma tendência linear crescente ao longo das várias horas analisadas. Estes comportamentos podem ser identificados através da análise dos resultados das saídas do sistema.

Considere-se que esta tendência crescente nos resultados se deve unicamente à melhoria de desempenho do “Operador A” (comportamento de aprendizagem) na execução das suas tarefas na linha de montagem. Neste caso, deverá ser contemplada uma variável de entrada do sistema que é o número de horas que o operador já despendeu no desempenho da mesma função da linha (tempo de treino). No decorrer do tempo, chegará um instante em que o tempo de treino do operador já não causa qualquer impacto nos resultados das saídas do sistema, porque o operador já não consegue melhorar mais o seu desempenho. Quando um operador chega ao “máximo” do seu desempenho será expectável que a saída do sistema se mantenha estável. Isto demonstra como uma entrada do sistema poderá ter impacto na saída durante um determinado conjunto de horas e deixar de ter qualquer relevância para o sistema nas horas seguintes.




Figura 16 – Exemplo de tendência.

Do exemplo anterior podemos também concluir que o conjunto de resultados das saídas mais recentes, para a mesma combinação do estado das entradas, são aqueles que mais próximo irão estar dos resultados que o sistema irá apresentar na próxima hora que apresente a mesma combinação do estado das entradas.

Esta abordagem permite-nos construir uma ferramenta de previsão de resultados futuros do sistema através do comportamento registado pelos seus modelos horários, isto é, assumindo que é possível prever quais as variáveis de entrada que vão estar no estado “Verdadeiro” e “Falso” para uma hora futura. Então, será possível estimar o valor das saídas do sistema para essa hora, caso exista histórico de informação do sistema que nos permita obter conclusões válidas. Para que tal seja possível, será necessário estudar e tratar toda a informação guardada em BD com a mesma combinação do estado das entradas que prevemos ter na hora futura, incluindo a sequência de variações destas combinações.

4.3 Modelo de Previsão

Como ilustração, considere-se que, para a combinação de estados das entradas do sistema representadas da Tabela 4 à Tabela 9, se registou no passado em 10 horas distintas os resultados nas saídas do sistema presentes na Tabela 10. Estes resultados demonstram que, para esta combinação de estados das entradas do sistema, existiu uma variação nos resultados obtidos nas saídas ao longo das várias horas analisadas. Esta variação poderá ter sido originada por algum dos comportamentos descritos anteriormente (comportamento evolutivo e de aprendizagem) ou simplesmente causada por variáveis de entrada do sistema que não foram consideradas na análise. Caso esta variação não existisse seria previsível que os resultados das saídas do sistema para a próxima hora, com a mesma combinação de estados das entradas, fossem semelhantes aos registados no passado já que todo o histórico dos resultados do sistema assim o indicava. Esta variação dos resultados registados no passado origina incerteza sobre o futuro e promove a utilização da previsão para estudar os resultados futuros do sistema.

Hora Analisada	Produto com Qualidade [%]	Perdas por Desempenho [%]	Perdas por Disponibilidade [%]	Perdas por Qualidade [%]
1	91	3,9	1,1	4
2	91,5	4,6	0	3,9
3	91,6	2,6	2	3,8
4	91,6	4,5	0	3,9
5	92	4,5	0	3,5
6	92,3	4,4	0	3,3
7	92,5	4,5	0	3
8	91,7	4,2	1	3,1
9	92,6	4,6	0	2,8
10	92,3	4,8	0	2,9

Tabela 10 – Resultados de 10 horas distintas (mesma combinação de estados das entradas).

De forma a construir um modelo de previsão, que fornece previsões dos resultados das saídas para horas futuras, foram testadas as séries temporais. Estas empregam técnicas quantitativas, analisando as propriedades estatísticas do histórico dos resultados do sistema para estimar resultados das saídas do sistema para horas futuras, isto é, verificam a evolução ou tendência dos resultados ao longo do tempo permitindo construir um modelo matemático de previsão que utiliza padrões nos dados recolhidos para projetar o futuro.

A escolha do método de previsão mais adequado está relacionada com o comportamento do histórico dos resultados do sistema. Para uma boa modelação do sistema (em termos de entradas) será expectável que, para a mesma combinação de estados das entradas, os resultados se apresentam numa série estacionária, ou que apresentem ligeiras tendências durante curtos períodos de tempo (comportamento evolutivo e de aprendizagem).

Nesta seção descreve-se a implementação de dois modelos de previsão adequados a séries temporárias estacionárias: Média Móvel e Suavização Exponencial. Estes modelos também se adaptam a séries que apresentem ligeiras tendências, no entanto não são adequados a

séries que apresentem tendências consideráveis ou sazonalidade. Geralmente estes modelos oferecem uma boa precisão para previsões de curto alcance, como uma previsão para o próximo período de tempo [25].

Para auxiliar a descrição dos modelos de previsão utilizando Média Móvel e Suavização Exponencial, irá utilizar-se como exemplo a previsão do resultado da próxima hora 8 da saída percentagem de Produto com Qualidade, para a combinação de estados das entradas representadas da Tabela 4 à Tabela 9. O histórico em BD dos resultados da combinação do estado das entradas do sistema será o apresentado na Tabela 10.

4.3.1 Previsão com Média Móvel

Aplicando o método de previsão Média Móvel, descrito matematicamente na equação (2), será necessário escolher o valor de N (número de resultados mais recentes considerados para o cálculo da Média Móvel). A alteração do valor N determina o grau de sensibilidade deste método em relação aos resultados mais recentes, influenciando o resultado da previsão. O melhor valor de N será aquele que minimiza o erro de previsão do modelo.

Se testarmos o método de previsão da Média Móvel para os valores de N iguais a 2, 3 e 4, respetivamente, obtemos os resultados descritos na Tabela 11. Relembrando que N igual a 1 representa um período de análise de uma de produção com uma determinada combinação de estados das entradas.

O resultado da previsão para a próxima hora 8 do sistema (com a mesma combinação de estados das entradas) é de 92,45 % usando um N de 2, 92,20 % usando um N de 3 e de 92,28 % usando um N de 4. Uma das formas de podermos testar a precisão da previsão do modelo é aplicá-lo a todo o histórico do sistema e calcular os erros de previsão.

Para o cálculo do erro de previsão foram usadas a MAE (equação (7)), MQE (equação (8)) e MAPE (equação (9)). Os resultados são mostrados na Figura 18 onde, independentemente do método de cálculo do erro de previsão, a Média Móvel com N igual a 2 foi a que mais minimizou o erro de previsão para o exemplo analisado. Isto indica que os resultados observados nas últimas duas horas de produção (com a mesma combinação

de estado das entradas) são aqueles que apresentam menor erro de previsão quando usados na previsão do resultado próximo hora 8 de produção (utilizando o modelo de previsão Média Móvel).

Horas Analisadas	Produto com Qualidade Observadas [%]	Previsão com Média Móvel (2) [%]	Previsão com Média Móvel (3) [%]	Previsão com Média Móvel (4) [%]
1	91			
2	91,5			
3	91,6	91,25		
4	91,6	91,55	91,37	
5	92	91,6	91,57	91,43
6	92,3	91,8	91,73	91,68
7	92,5	92,15	91,97	91,88
8	91,7	92,4	92,27	92,10
9	92,6	92,1	92,17	92,13
10	92,3	92,15	92,27	92,28
11 (Hora Futura)		92,45	92,20	92,28

Tabela 11 – Previsão usando Média Móvel.




Figura 17 – Gráfico Previsão Média Móvel.

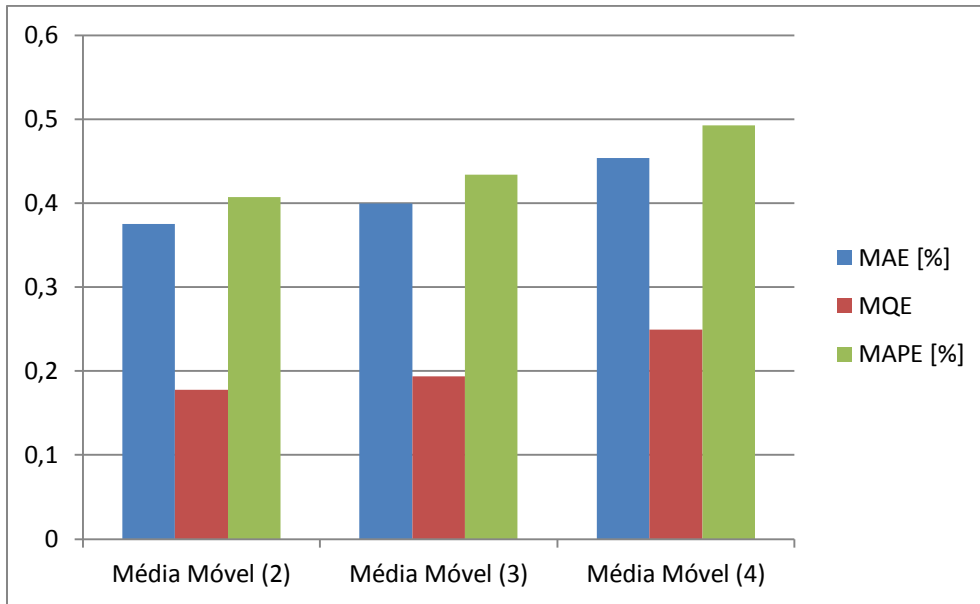


Figura 18 – Erros Médios de Previsão (Média Móvel).

A ferramenta informática desenvolvida efetua o cálculo da previsão do resultado futuro utilizando vários valores de N , de 2 a $p-1$ (sendo p o número de períodos registados na série com a mesma combinação de estados das entradas) de uma forma incremental, testando o modelo de previsão a todo o histórico registado. O N escolhido para a previsão do próximo resultado será aquele que mais minimizou o MQE. A utilização do MQE permite determinar em que medida o modelo de previsão não se ajustou aos dados, dando ênfase a erros elevados de previsão (é calculado utilizando o quadrado do erro). Descrevendo a previsão e os resultados observados num gráfico de linhas (Figura 17), é possível, através do MQE, determinar qual dos modelos de previsão apresentou resultados com maior semelhança aos observados (comparação de gráficos de linhas). Um MQE de zero indica que o modelo prevê resultados com precisão perfeita.

4.3.2 Previsão com Suavização Exponencial

Aplicando o método de previsão Suavização Exponencial, descrito matematicamente na equação (3), será necessário escolher o valor de α (coeficiente de suavização) podendo variar entre 0 e 1. A alteração do valor α determina o grau de sensibilidade deste método em relação aos resultados mais recentes, influenciando o resultado da previsão. O melhor valor de α é aquele que minimiza o erro de previsão do modelo.

A Suavização Exponencial requer uma estimativa inicial para P_{t-1} , sendo a média aritmética da série de resultados observados uma boa estimativa inicial neste tipo de modelo de previsão [37].

Se testarmos o método de previsão Suavização Exponencial para os valores de α iguais a 0,2, 0,5 e 0,8 respectivamente obtemos os resultados da Tabela 12.

A aplicação desenvolvida efetua o cálculo da previsão do resultado futuro utilizando vários valores de α (de 0.01 a 0.99 com a resolução de 0.01), testando o modelo de previsão ao histórico registrado. À semelhança do que acontece com o modelo de previsão Média Móvel, o valor de α escolhido para a previsão do valor futuro será aquele que minimizou o MQE.

Horas Analisadas	Produto com Qualidade Observadas [%]	Previsão com Suavização Exponencial (0.2) [%]	Previsão com Suavização Exponencial (0.5) [%]	Previsão com Suavização Exponencial (0.8) [%]
1	91			
2	91,5	91,73	91,46	91,18
3	91,6	91,68	91,75	91,44
4	91,6	91,67	91,61	91,57
5	92	91,65	91,66	91,59
6	92,3	91,72	91,82	91,92
7	92,5	91,84	91,96	92,22
8	91,7	91,97	92,11	92,44
9	92,6	91,92	91,77	91,85
10	92,3	92,05	92,33	92,45
11 (Hora Futura)		92,10	92,04	92,33

Tabela 12 – Previsão usando Suavização Exponencial.

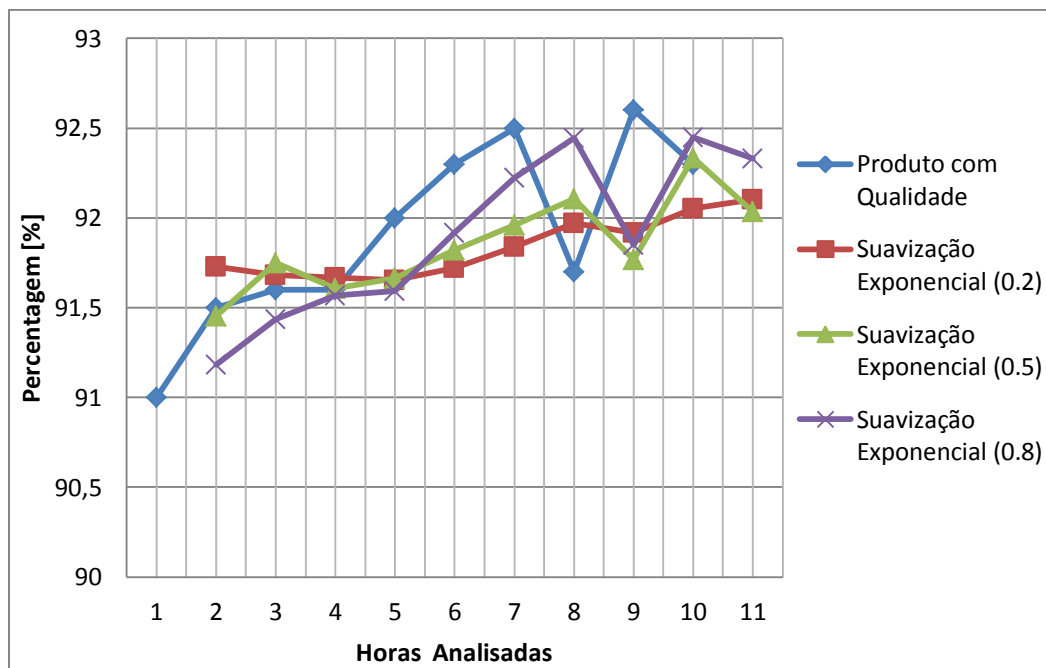


Figura 19 – Gráfico Previsão Suavização Exponencial.

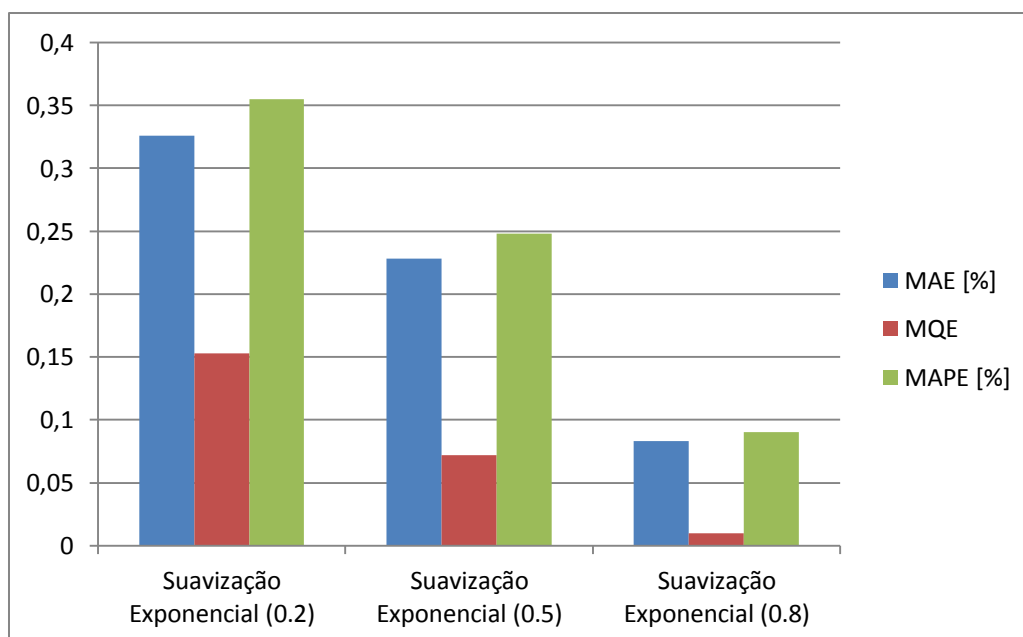


Figura 20 – Erros Médios de Previsão (Suavização Exponencial).

4.3.3 Seleção do Modelo de Previsão

A seleção do modelo de previsão a utilizar dependerá dos resultados do sistema modelado. Será sempre necessário continuar a avaliar a sua adequabilidade ao longo do tempo para as condições presentes e futuras.

O MAE mostrou-se um bom indicador para a obtenção da margem de erro da previsão. Usando o MAE, poderemos interpretar o resultado da previsão afetado de uma tolerância \pm MAE. Para o exemplo de uma previsão de 90% de produto com qualidade e de um MAE de 1%, pode considerar-se que a previsão de produto com qualidade estará compreendida em média entre 89% e 91%.

4.3.4 Previsão Cumprindo Restrições

Nos exemplos apresentados para a utilização dos modelos de previsão apenas foi considerado o cálculo da saída do modelo Produto com Qualidade, mas na realidade o modelo contempla quatro saídas que apresentam uma restrição, isto é, a soma do resultado das quatro saídas será sempre 100%. Esta restrição obriga o modelo de previsão a efetuar previsões que cumpram esta premissa. Uma das formas de garantir esta restrição, é efetuar o cálculo da previsão para as saídas Perdas por Desempenho, Perdas por Disponibilidade e Perdas por Qualidade utilizando o mesmo valor de N ou α que mais minimizou o MQE na previsão do resultado futuro da saída Produto com Qualidade. A utilização destes valores de N ou α garante a restrição considerada, mas não garante necessariamente os melhores resultados de previsão para todas as saídas do sistema.

A utilização de N ou α que mais minimizou o MQE na previsão do resultado futuro da saída Produto com Qualidade, para cálculo da previsão de todas as saídas do sistema só encontra explicação matematicamente aceitável se interpretarmos o conceito série temporal e o significado dos valores de N e α . Os valores N e α regulam o grau de sensibilidade do modelo de previsão em relação aos resultados mais recentes da série temporal. O valor N ou α reflete quais os períodos da série temporal que apresentam maior relevância na previsão do próximo resultado futuro. Assim, considerando que a saída Produto com Qualidade é a mais importante do modelo de previsão (e do sistema produtivo), fará então

sentido considerar os mesmos períodos (o mesmo valor o N ou α) utilizados para a previsão da saída Produto com Qualidade no cálculo da previsão das restantes saídas do modelo.

Caso se considere outra saída do modelo como a mais importante para a previsão, esta poderá ser seleccionada para tal, sendo a mesma lógica mencionada anteriormente aplicada à de previsão.

4.4 Perdas por Qualidade

As perdas por qualidade são um dos principais alvos de melhoria dos processos produtivos das empresas. Embora podendo muitas vezes não ser a principal causa de perdas no processo produtivo, são tratadas com prioridade face a outros tipos de perdas. O motivo desta abordagem deve-se ao risco inerente de fornecimento de produto fora de especificação ao cliente. O fornecimento de produto fora de especificação é um procedimento intolerável em alguns tipos de indústria (caso da indústria automóvel) podendo originar coimas e sanções prejudiciais para as empresas fornecedoras.

Neste trabalho a classificação de cada causa de rejeição será descrita como “defeito”, isto é, cada ponto a controlar no produto que pode causar uma rejeição irá ser classificado como “defeito n ”. Por exemplo, um produto pode ser rejeitado por não cumprir a especificação dimensional (largura do produto), caso esse em que será rejeitado devido ao defeito 1, ou poderá ser rejeitado por apresentar um problema de montagem (por exemplo um mau encaixe entre dois componentes) e, neste caso, será rejeitado devido ao defeito 14. A cada tipo de rejeição equivalerá um defeito.

Para cada hora analisada será possível construir uma RdP semelhante à representada na Figura 21. A interpretação desta RdP permite concluir que, para a hora analisada, do “Total de Produto Produzido” (total de peças produzidas com ou sem qualidade), 7,07 % das peças foram rejeitadas (devido a problemas de qualidade no produto). Destas rejeições, 21,43% devem-se ao defeito 1, 14,29% ao defeito 5, 7,14% ao defeito 7 e 57,14% ao defeito 14. As peças rejeitadas poderão ser recuperadas, isto é, os problemas que foram

detetados no produto poderão ser reparados ou corrigidos para que possa estar dentro de especificação de qualidade. Caso isso não seja possível o produto será destruído (*scrap*).

A contabilização e a classificação de defeitos, para cada hora analisada, permitem ao modelo de previsão tratar cada defeito como uma saída do modelo horário do sistema e associá-la a uma combinação do estado das entradas do sistema. Desta forma, torna-se possível efetuar a previsão da percentagem de defeitos para uma determinada combinação do estado das entradas (Figura 22). O histórico em BD dos resultados de cada defeito é tratado como uma série temporal sendo possível aplicar os modelos de previsão na Secção 4.3. Para tal foram adicionadas novas saídas ao modelo de previsão que irão corresponder à previsão da percentagem de ocorrência de cada defeito contemplado.

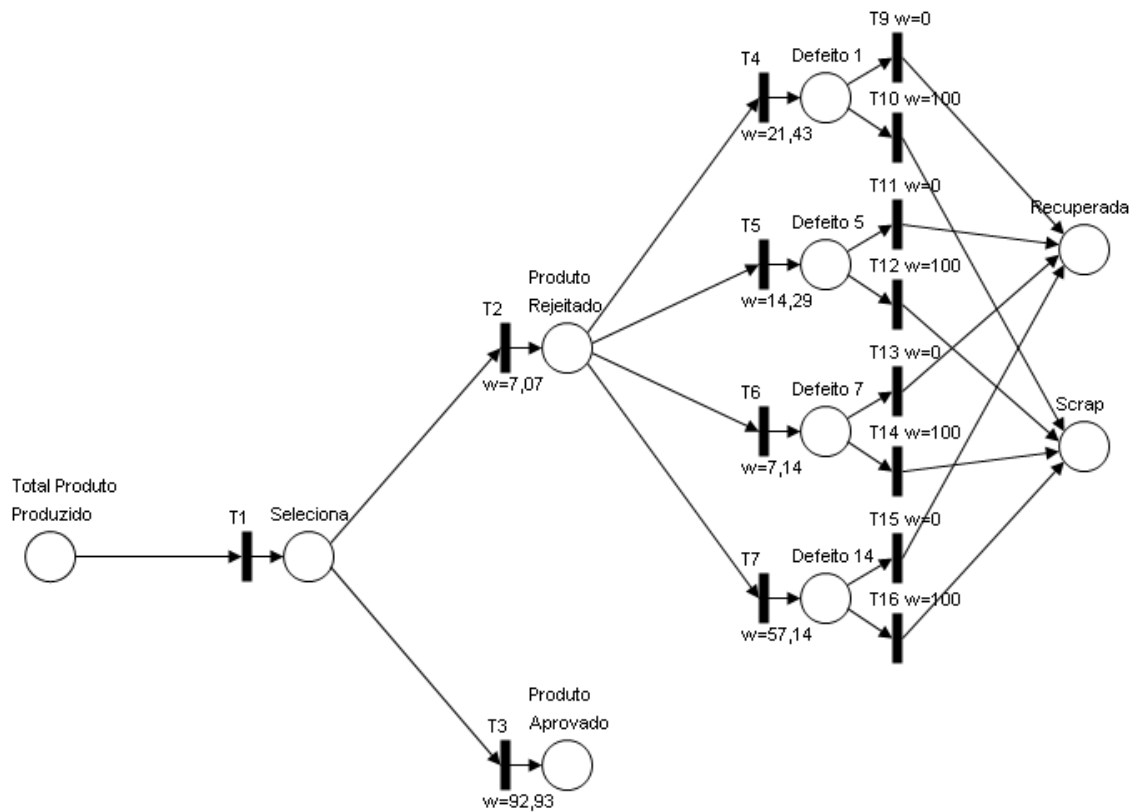


Figura 21 – RdP que modela as Perdas por Qualidade.

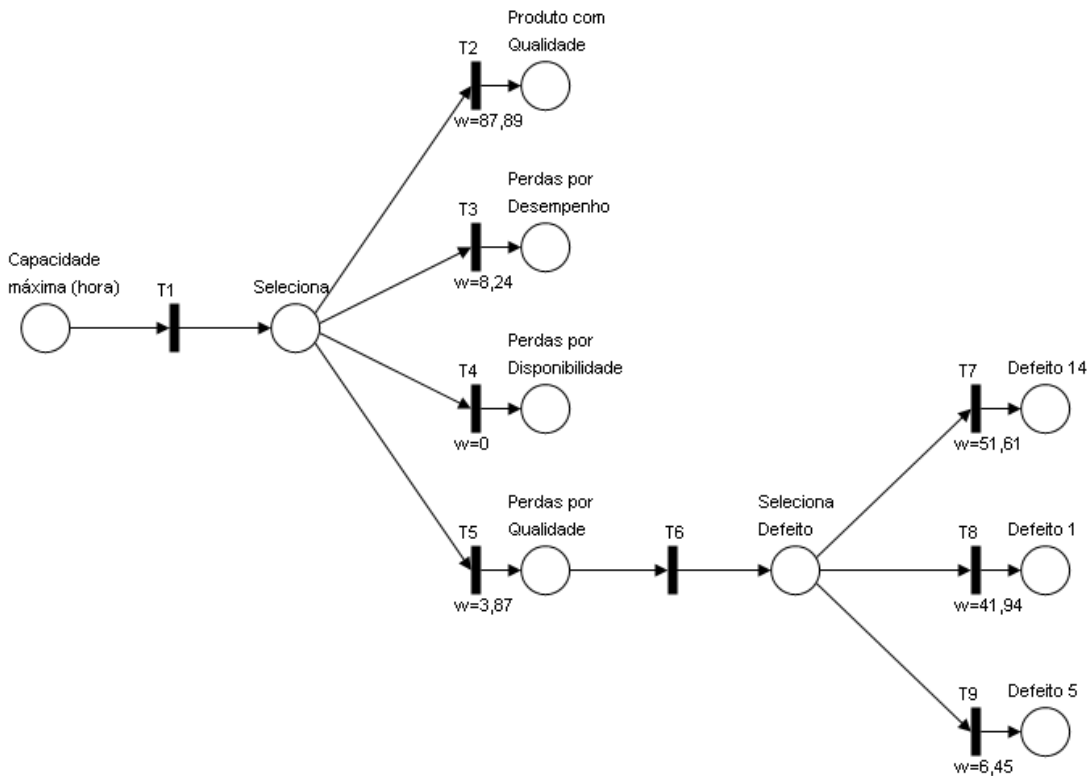


Figura 22 – RdP do modelo horário do sistema com defeitos.

4.4.1 Estudo do Comportamento de Rejeição

A percentagem de defeitos registados nas várias horas analisadas poderá apresentar padrões e similaridades. Se a rejeição de uma hora analisada incidir num defeito ou combinação de defeitos, será previsível que na hora seguinte (se nenhuma das variáveis de entrada mudar de estado) se mantenham os mesmos tipos de rejeição. Um bom exemplo para ilustrar este acontecimento será o caso de um lote de produção com problemas. Quando existe um lote de produção com produto fora de especificação causado por determinados tipos de defeitos, será esperado um determinado “comportamento de rejeição” para as várias horas analisadas com produto do lote com problemas. O comportamento de rejeição irá refletir-se em percentagem de defeitos para as horas analisadas muito idênticos ou com a mesma tendência. Se este lote causar rejeições por defeito 3 será expectável que a percentagem de rejeição, para as várias horas analisadas com o lote de produção com problemas, incida neste defeito.

Estes acontecimentos enquadram a utilização de algoritmos de *clustering* (classificação de objetos de acordo com semelhanças existentes) ao histórico de rejeição horária registado no sentido de estudar os comportamentos de rejeição do sistema. O objetivo será transformar as várias percentagens de cada defeito que ocorrem a cada hora e transformá-las num comportamento de rejeição, agrupando o comportamento ocorrido numa hora a outros comportamentos (registados noutras horas) que apresentem características muito idênticas, criando assim *clusters* de rejeição.

Suponha-se que ocorreu no passado um comportamento de rejeição de 4% de peças rejeitadas, sendo 51% devido ao defeito 1 e 49 % ao defeito 3, e que a última hora analisada apresenta 4% de peças rejeitadas, sendo 50% devido ao defeito 1 e 50 % ao defeito 3. Analisando os dois comportamentos pode concluir-se que o comportamento ocorrido no passado é idêntico ao ocorrido na última hora analisada. Neste caso pode então criar-se um *cluster* que junta os dois comportamentos registados e que apresenta 4% de peças rejeitadas, sendo 50,5% devido ao defeito 1 e 49,5 % ao defeito 3.

$$\text{Cluster (centroide defeito 1)} = \frac{51\% + 50\%}{2} = 50,5\%$$

$$\text{Cluster (centroide defeito 3)} = \frac{49\% + 50\%}{2} = 49,5\%$$

O *cluster* criado irá substituir os dois comportamentos registados no estudo do comportamento de rejeição do sistema, simplificando assim o modelo sem afetar de forma significativa a previsão.

Neste trabalho foram efetuadas algumas alterações ao algoritmo de *clustering* K-means (Secção 3.7) no sentido de alterar os critérios de *clustering* do algoritmo original (Figura 23). Ao contrário da versão K-means original em que o número de *clusters* desejado é um parâmetro de entrada do algoritmo, o algoritmo desenvolvido para este trabalho efetua *clusters* de acordo com uma restrição, sendo esta uma distância máxima do objeto ao centróide do *cluster*.

Numa fase inicial o número de *clusters* será igual ao número de objetos registados (comportamentos de rejeição registados no histórico) e é definida uma distância euclidiana máxima do objeto ao seu *cluster*. Esta distância poderá ser interpretada como a tolerância máxima admitida para que um objeto pertença a um *cluster*. Os *clusters* são inicializados com as características (percentagens de defeito) de um objeto distinto (a cada *cluster* pertencerá um objeto distinto). No fim da primeira iteração os objetos irão manter-se no seu *cluster* de inicialização já que o número de objetos é igual ao número de *clusters*. Nesta fase, a distância calculada do objeto ao seu *cluster* será zero, já que cada cluster apenas possui um objeto. Assim, se a distância euclidiana máxima definida for maior que zero, o algoritmo continuará para a próxima iteração. Ao passar para a próxima iteração é eliminado um *cluster*, sendo para tal medida a distância euclidiana entre *clusters*, e eliminado um *cluster* dos dois *clusters* mais próximos entre si. Este procedimento irá forçar o objeto pertencente ao *cluster* eliminado a agrupar-se a outro *cluster*. Assim, no final da segunda iteração, a distância calculada do objeto ao seu *cluster* poderá não ser zero, já que existe um *cluster* que possui dois objetos. Caso a distância euclidiana máxima definida não seja menor a nenhuma das distâncias calculadas dos objetos aos seus *clusters*, o algoritmo continuará a iterar e a eliminar *clusters*. Caso a restrição seja violada serão apresentados os *clusters* e os centróides calculados na iteração anterior à violação da restrição. Esta dinâmica do algoritmo está resumida no fluxograma da Figura 23.

A escolha da distância euclidiana máxima definida influenciará o número de *clusters* criados e as características de cada *cluster*. Esta distância deverá ser escolhida consoante o grau de similaridade que o utilizador pretende entre os objetos e o seu *cluster*. Uma distância de zero indicará que os objetos pertencentes a cada *cluster* possuem características iguais à do seu *cluster*.

Um bom método para a escolha desta distância será o estudo do comportamento de rejeição de várias horas consecutivas com mesma combinação de estados das entradas (à exceção da variável de entrada hora). Estas horas deverão, em teoria, apresentar comportamentos de rejeição idênticos, logo o comportamento de rejeição registado nestas horas tendencialmente pertencerá ao mesmo *cluster*. Assim a distância mínima que garanta este *cluster* poderá ser usada no algoritmo.

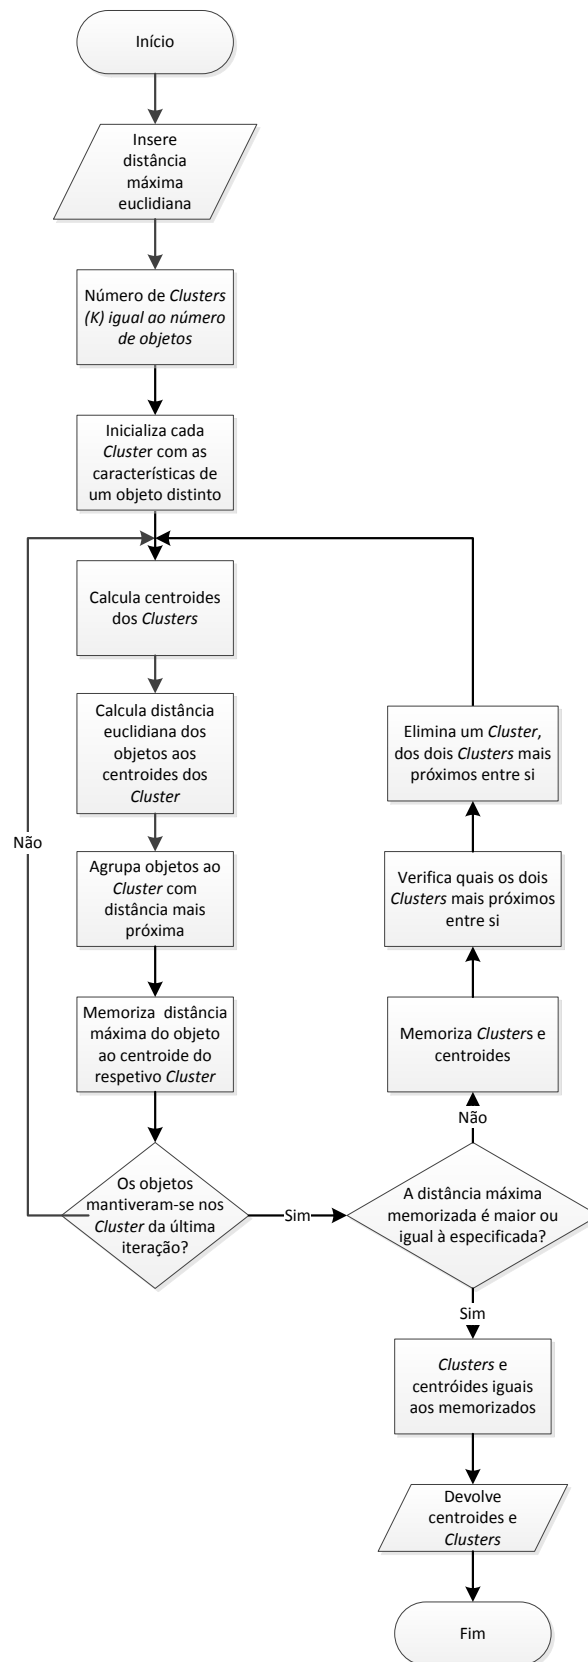


Figura 23 – Fluxograma K-means (alterado).

A Figura 24 mostra graficamente um exemplo de um *cluster* (*Cluster 12*) criado através do algoritmo descrito anteriormente. Este *cluster* é constituído por dois objetos (Modelo 55 e Modelo 56) que são dois comportamentos de rejeição registados em duas horas consecutivas.




Figura 24 – Exemplo *Cluster 12*.

Sendo um *cluster* um agrupamento de comportamentos de rejeições, registados em várias horas analisadas, será possível analisar o histórico registado em BD e recolher a informação relativa ao comportamento de rejeição registado na hora seguinte ao registo de um comportamento de rejeição pertencente a um *cluster*.

A RdP da Figura 25 mostra o histórico da informação do sistema relativamente à hora seguinte de produção após o registo de um comportamento de rejeição pertencente ao *Cluster 12*. Ao analisar a rede, é possível concluir que, baseado no histórico dos resultados de rejeição do sistema, quando o sistema se encontrou no comportamento de rejeição pertencente ao *Cluster 12*, em 50% dos casos manteve-se neste comportamento na hora de produção seguinte e noutros 50% dos casos mudou o comportamento de rejeição para um

comportamento pertencente ao *Cluster 4*. O comportamento desejável para o gestor de produção da linha de montagem, seria que o comportamento de rejeição do sistema mudasse para o *Cluster 4*, já que a percentagem de rejeição deste *cluster* (valor “Rejeitado” escrito entre parênteses junto ao lugar do *cluster*) é bastante mais favorável.

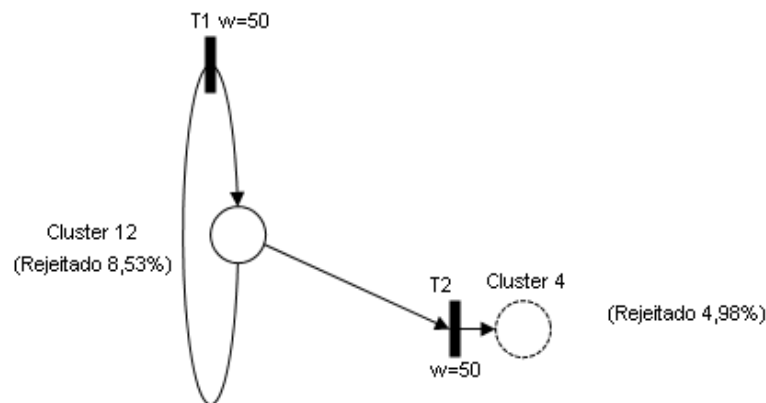


Figura 25 – Cluster 12 (próxima hora de produção).

A RdP da Figura 26 ilustra outro exemplo do estudo dos comportamentos de rejeição do sistema. Neste exemplo, é possível descrever uma das principais potencialidades deste tipo de estudo e desta ferramenta. Estando o sistema num comportamento de rejeição pertencente ao *Cluster 5* (rejeição de 6,6%), o histórico de informação do sistema indica que existiu uma mudança de comportamento de rejeição do sistema que provocou um aumento de rejeição de 1,9% na hora de produção seguinte.




Figura 26 – Cluster 5 (próxima hora de produção).

Ao existir a possibilidade da projeção dos resultados da rejeição da hora de produção seguinte através do diagnóstico do comportamento de rejeição atual do sistema e do seu

histórico, será possível tomar medidas reativas de forma a alterar o estado atual do sistema e o seu comportamento de rejeição. Isto é possível analisando o estado das variáveis de entrada do sistema durante o registo de um comportamento de rejeição pertencente a um *cluster*.

Um exemplo do estudo do estado das variáveis de entrada na ocorrência de um comportamento de rejeição é o presente na Tabela 13. Analisando o estado das variáveis de entrada do sistema durante o registo de um comportamento de rejeição pertencente ao *Cluster 17* pode detetar-se que todas as ocorrências dos comportamentos de rejeição ocorridos no passado, pertencentes a este *cluster*, ocorreram na hora de produção 10 e na Referência 1. Neste exemplo resta estudar o sistema de produção e perceber quais os tipos de defeitos e respetivas percentagens, contempladas no *Cluster 17*, e tentar diagnosticar o que promove o estes comportamento de rejeição na hora 10 e na Referência 1.

Variáveis de entrada	Percentagem de ocorrências [%]
Quarta	50
Quinta	50
Hora 10	100
Referência 1	100
Operador 1	25
Operador 2	25
Operador 5	25
Operador 6	25

Tabela 13 – Estado das variáveis de entrada - *Cluster 17*.

4.5 Planeamento e Previsão da Produção

O planeamento da produção é uma tarefa do gestor de produção e assume uma função muito importante nos resultados do sistema produtivo. Os sistemas de produção são normalmente constituídos por inúmeros recursos e produtos que deverão ser geridos de

forma a assegurar as responsabilidades logísticas da empresa (entrega do produto ao cliente na data estabelecida).

A previsão não deve ser confundida com planeamento. O planeamento diz-nos como deveria acontecer e a previsão diz-nos o que é previsível acontecer face ao planeado. Se os gestores de produção dispuserem de ferramentas que lhes permitam efetuar a previsão da produção, estes poderão prever os resultados e alterar o planeamento. Se os resultados da previsão não forem satisfatórios, o planeamento poderá ser alterado e poderão ser obtidas novas previsões, repetindo o processo até os resultados da previsão serem satisfatórios [38].

A ferramenta desenvolvida neste trabalho tem o intuito de ajudar o gestor de produção a prever a produção de um sistema desde que seja possível prever o estado das entradas do sistema no decorrer da produção.

Uma linha de montagem é um recurso com uma capacidade máxima de produção, a qual pode ser estabelecida por hora. Embora o equipamento tenha a capacidade de produzir n peças por hora (no melhor dos cenários), será necessário que o gestor de produção efetue um planeamento de produção (para a linha de montagem) que garanta todos os recursos necessários ao sistema produtivo, para que este possa obter bons resultados. Estes recursos poderão ser operadores especializados, componentes, equipamentos auxiliares, energia, etc. Um das variáveis mais importantes no planeamento da produção é a variável tempo.

O planeamento de produção normalmente engloba paragens planeadas de produção. Estas paragens são destinadas a descanso de operadores, trocas de ferramentas, mudança de referência de produto, manutenção programada de equipamentos, etc. Qualquer paragem de produção que tenha sido prevista na altura da elaboração do planeamento e que ocorra durante o tempo de produção poderá ser classificada como paragem planeada de produção.

O tempo planeado de produção poderá ser descrito como o tempo reservado para a produção (não incluído tempo de paragens planeadas de produção).

A Figura 27 ilustra o cronograma de um planeamento de 450 peças para uma linha de montagem com capacidade máxima horária de 267 peças. O gestor de produção planeou o início da produção para às 9:00 de 15 de Janeiro e considerou uma paragem planeada de produção de dez minutos das 10:00 às 10:10 (assinalada com barra vermelha no cronograma) destinada ao lanche dos operadores.

Dada a capacidade máxima desta linha de montagem, esta necessitaria de 101 minutos e 7,4 segundos de tempo planeado de produção para satisfazer a produção planeada (assinalada com barra verde no cronograma). Considerando o tempo da paragem planeada de produção, 10 minutos, a linha acabaria a produção 111 minutos e 7,4 segundos após o seu início (a produção finalizaria às 10:51:07).

Na Figura 27 também é possível observar a capacidade da produção da linha de montagem para cada hora planeada de produção. Da hora 9 à hora 10 foi planeada toda hora de produção, logo a capacidade máxima da hora será 267 peças (capacidade máxima horária da linha de montagem). Da hora 10 à hora 11 apenas foram contemplados 41 minutos e 7,4 segundos de tempo planeado de produção (68,54% da hora), logo a capacidade máxima da hora neste caso será de 183 peças (68,54% da capacidade máxima horária da linha de montagem).

Cronograma da Produção




Figura 27 – Exemplo Planeamento.

Ao efetuar o planeamento da produção e ao alocar recursos para que essa produção se realize, é possível prever o estado de algumas variáveis de entrada do sistema durante o período de produção. Para o planeamento descrito no exemplo, o gestor de produção sabe qual o tipo de produto que irá produzir (referência), quando irá produzir, quanto necessita de produzir, quais os operadores que irão trabalhar na linha durante a produção, os lotes de componentes que irão integrar com o produto final, etc.

Ao prever os estados das variáveis de entrada para uma hora de produção, poderá aplicar-se o modelo de previsão (descrito na Secção 4.3) para prever os resultados de cada hora de produção planeada, tendo em conta o histórico dos resultados do sistema combinado com o estado das variáveis de entrada.

Para a previsão do estado das variáveis de entrada, efetuada pelo utilizador na ferramenta informática desenvolvida, o modelo de previsão aplica o método de Suavização Exponencial à serie temporal construída a partir da BD do histórico de resultados do sistema, prevendo os resultados ilustrados na Figura 28.

Cronograma da Produção

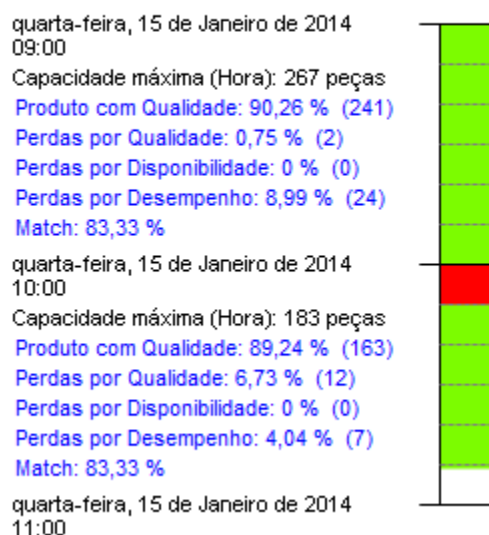


Figura 28 – Exemplo de Planeamento e Previsão (resultados por hora).

Interpretando os resultados da previsão (valores escritos a azul na Figura 28) foi previsto, para a primeira hora de produção, que, das 267 peças possíveis (capacidade máxima da hora), 90,26 % (241 peças) serão produto com qualidade, 0,75% (2 peças) serão produto fora de especificação (Perdas por qualidade) e 24 peças (8,99%) não serão produzidas por perdas por desempenho. O mesmo raciocínio é seguido para a previsão dos resultados da segunda hora de produção.

A percentagem *match* indica que, para a combinação de variáveis de entrada ativas (estado “verdadeiro”) previstas para hora, apenas foi encontrado histórico de informação onde 83,33% destas entradas apresentavam o estado previsto. Considere como exemplo que apenas tinham sido contemplados três grupos de variáveis de entrada, sendo estas o dia da semana, a hora do dia e o operador, e a realização da produção foi prevista para quarta-feira na hora 9 e com o “Operador A”. Se só tiverem existido produções no passado, realizadas à quarta-feira na hora 9 e com o “Operador A”, a percentagem de *match* da previsão será de 100%. Caso só tenham existido produções no passado, realizadas à quarta-feira na hora 9 e com o “Operador B”, o modelo de previsão devolverá uma percentagem de *match* 66,67%. Neste caso, a série temporal usada para previsão irá ser construída com todo o histórico dos resultados realizadas à quarta-feira na hora 9, isto é, a previsão é efetuada na mesma embora não exista histórico em BD que combine o estado das três variáveis de entrada.

Os resultados totais previstos (englobando as duas horas de produção) para a produção planeada poderão ser observados na Figura 29, assim como a previsão da incidência dos defeitos das perdas por qualidade.

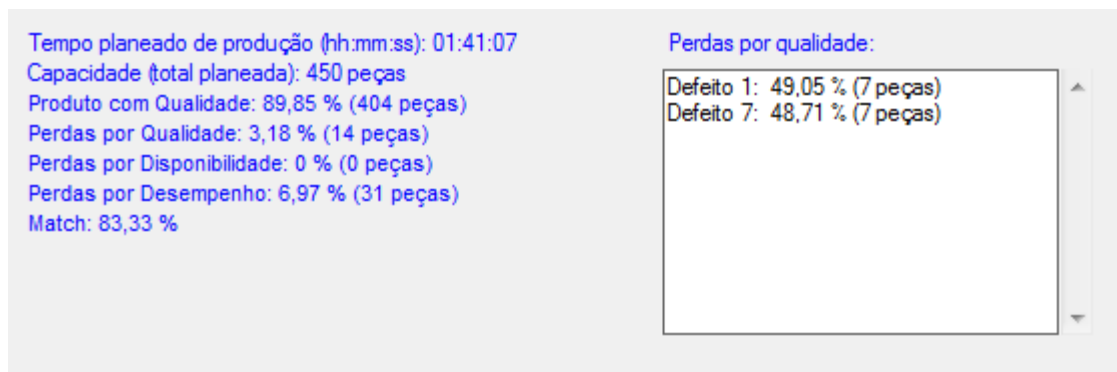


Figura 29 – Exemplo de Planeamento e Previsão (resultados totais).

Uma das vantagens desta ferramenta será a comparação de cenários e previsões tendo em vista a melhoria dos resultados da produção. Alterando o planeamento da Figura 28 para iniciar às 8:00, e mantendo a mesma previsão do estado nas restantes variáveis de entrada do sistema, os resultados da previsão seriam bastante diferentes (Figura 30). Ao comparar os resultados nota-se um decréscimo de Produto com Qualidade (menos 55 peças).

A produção tem como objetivo a satisfação das necessidades de fornecimento de produto aos clientes, sendo o produto produzido em excedente um custo para a empresa produtora, já que não se sabe quando o produto será vendido. Este produto terá custos de armazenamento e cada dia que passe a mais nas instalações da empresa produtora resulta num custo acumulado. A produção de produto em excedente poderá também ser interpretada como um consumo de recursos que poderão ser necessários noutras áreas produtivas da empresa (exemplo da mão-de-obra). Um bom planeamento e previsão da produção serão sempre uma mais-valia para o gestor da produção.

Cronograma da Produção

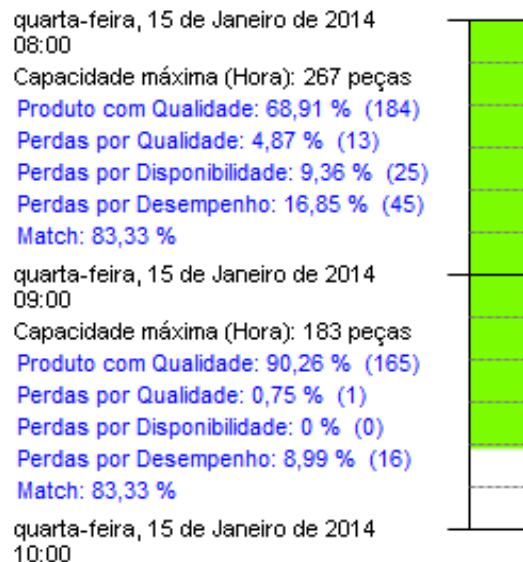


Figura 30 – Exemplo de Planeamento e Previsão (resultados por hora).

A análise do MAE da previsão permite calcular a margem de erro a aplicar à previsão calculada. Um MAE elevado poderá indicar que existe uma grande variabilidade no sistema produtivo para uma determinada combinação de estados das entradas.

4.6 Análise de Variabilidade e Sensibilidade

Um dos principais objetivos que leva à modelação de um sistema passa pelo estudo do seu comportamento e da sua estrutura. Até ao momento, neste trabalho, a modelação do sistema produtivo tem sido utilizada para prever resultados futuros do sistema, mas será também útil estudar outro tipo de informação que possibilite a melhoria do desempenho do sistema.

Será desejável que qualquer sistema produtivo industrial apresente um comportamento estável nos seus resultados produtivos, cenário este que poderá ser indicador de que o sistema está controlado.

Neste trabalho, o sistema produtivo é interpretado como um sistema estático, isto é, o resultado das saídas do sistema num determinado instante depende unicamente do estado das variáveis de entrada do sistema nesse preciso instante. Neste caso, será possível estudar a influência de cada entrada ou combinação de entradas nos resultados das saídas do sistema.

Como exemplo, irá estudar-se o histórico dos resultados da saída Produto com Qualidade. Numa primeira fase constrói-se um histograma que permite analisar a distribuição estatística dos resultados desta saída (Figura 31) independentemente do estado das entradas do sistema.

Ao analisar o histograma da Figura 31, observa-se que os resultados da saída não se apresentam (claramente) sob forma de distribuição estatística conhecida (poderá aproximar-se a uma distribuição assimétrica à esquerda). Neste caso pode-se construir uma CC de Média e Amplitude (Secção 3.6) para estudar os resultados da saída.

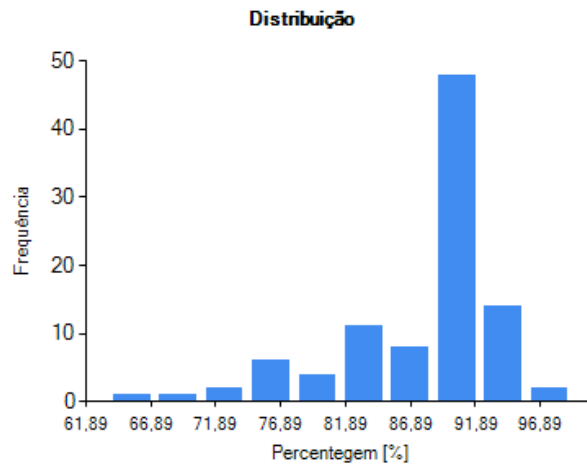


Figura 31 – Histograma da saída Produto com Qualidade.

Ao construir uma CC de Média e Amplitude com n igual a 2 e m igual a 20 (devido à quantidade de dados presente na BD), obtêm-se as cartas da Figura 32. Ao analisar estas cartas conclui-se que o sistema esteve fora de controlo estatístico nas primeiras horas analisadas e que tende para o controlo estatístico nas últimas horas observadas, isto é, a variabilidade da saída Produto com Qualidade apresenta um padrão nas últimas horas observadas. A média das médias (linha central da CC de Médias) calculada é de 89,38% e o desvio-padrão é de 1,423 %.

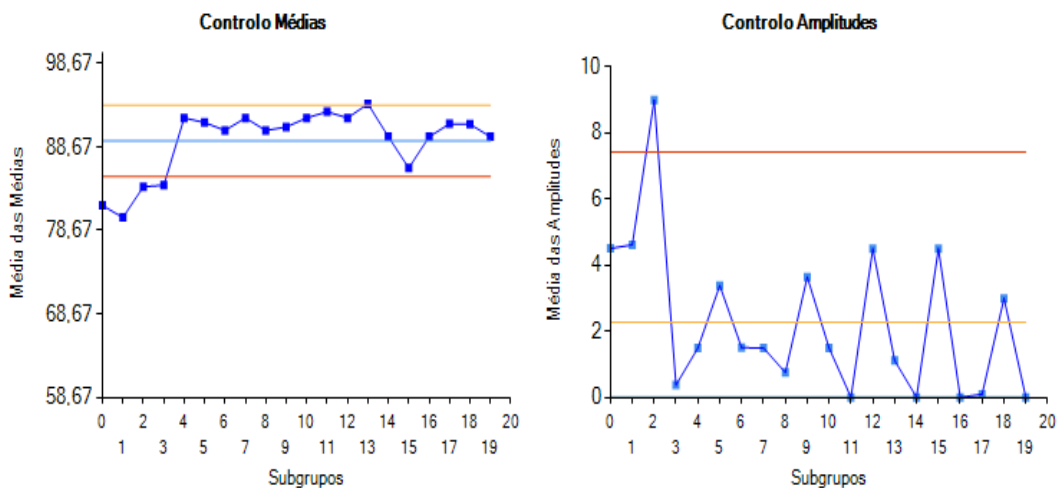


Figura 32 – CC média e amplitude Produto com Qualidade.

No intuito de estudar a influência da entrada Operador 5 nos resultados da saída, construiu-se outra CC com os resultados da saída, registados em BD quando esta variável se

encontrou ativa. Neste caso a quantidade de resultados presentes na BD só permite construir uma CC com m igual a 17 (Figura 33).

Ao analisar-se a carta construída da Figura 33, pode-se observar que o sistema se encontrou fora de controlo estatístico quando a variável Operador 5 se encontrou ativa no sistema e que a média das médias calculada é de 85,64% e o desvio-padrão é de 2,317%.




Figura 33 – CC média e amplitude entrada Operador 5.

Ao comparar a CC da Figura 32 com a da Figura 33 pode-se concluir que, quando a variável de entrada Operador 5 se encontrou ativa no sistema, a média das médias é mais baixa 3,74% e os resultados da saída apresentam uma dispersão maior face à média das médias de todos os resultados desta saída. Isto poderá ser um indicador que o sistema é sensível à variável Operador 5 e esta provoca uma redução na percentagem de produto com qualidade do sistema. É óbvio que estas conclusões não se poderão obter de uma forma tão imediata, mas será sempre um bom ponto de partida para um estudo estrutural ao sistema. A próxima análise a efetuar seria a de procurar qual das restantes variáveis mais influencia a saída do sistema quando a variável Operador 5 está ativa.

A análise de sensibilidade e variabilidade fornece uma imagem do sistema, permitindo estudar a sua estrutura e auxiliando na melhoria do seu desempenho. A ferramenta informática desenvolvida permite efetuar análises de uma forma individual às quatro saídas consideradas no modelo do sistema (Produto com Qualidade, Perdas por Desempenho, Perdas por Disponibilidade e Perdas por Qualidade).

5 RESULTADOS

Neste capítulo são descritos alguns dos resultados observados durante a validação e avaliação da ferramenta informática desenvolvida para modelação, previsão e análise de sistemas produtivos industriais.

De forma a manter a confidencialidade dos sistemas produtivos da empresa Iber-Oleff, os exemplos descritos encontram-se descaracterizados. Contudo, esta descaracterização permite manter a compreensão da aplicabilidade e das vantagens da ferramenta desenvolvida. Os exemplos descritos de seguida resultam da análise de resultados observada durante o teste e validação da ferramenta desenvolvida.

5.1 Análise de Equipamentos Idênticos

Uma linha de montagem pode ser constituída por vários equipamentos dedicados à execução ou auxílio de tarefas específicas. Algumas linhas são compostas por estações de trabalho com as mesmas funções e com equipamentos semelhantes, tendo em vista o aumento de produtividade. Em termos físicos será muito difícil fabricar vários equipamentos “iguais”, embora possam ter as mesmas características e especificações. Equipamentos idênticos poderão apresentar resultados diferentes e até influenciar os resultados do sistema de forma distinta.

No exemplo de uma linha com dois equipamentos de marcação laser [39] idênticos, que executam a mesma tarefa de marcação num componente plástico, será importante perceber qual dos dois equipamentos produz mais peças defeituosas e que tipo de defeitos é que cada laser provoca. Esta análise auxiliará a equipa de manutenção na identificação de possíveis problemas nos equipamentos, permitindo a sua correção ou melhoria de desempenho.

Para a modelação do exemplo anterior teriam de ser adicionadas duas variáveis de entrada, uma para cada laser (por exemplo variáveis laser 1 e laser 2). Como os dois lasers efetuam a mesma função a produção horária da linha de montagem será dividida (idealmente) pelos

dois lasers. Nesta caso a linha de montagem será modelada com dois modelos horários, um para a produção efetuada pelo laser 1 e outra para a produção efetuada pelo laser 2. Isto pode ser interpretado como uma divisão do sistema em dois, um que possui o laser 1 e outro o laser 2. Esta divisão torna-se necessária porque a ferramenta desenvolvida efetua uma amostragem horária do sistema e em cada hora analisada as peças produzidas são repartidas por cada laser.

Na Figura 34 é possível visualizar um exemplo de análise e deteção deste tipo de características do processo, através da ferramenta desenvolvida. Selecionando a variável do processo que pretendemos analisar (lado esquerdo da janela) é possível efetuar uma previsão para uma qualquer hora de produção, independentemente do estado das restantes variáveis do modelo. Neste caso a previsão é efetuada através de todos os resultados em BD que tenham a variável Laser 1 ativa. Através da previsão efetuada a ferramenta constrói uma RdP que representa o modelo horário do sistema para uma qualquer hora de produção. A comparação do modelo horário gerado através da seleção da variável Laser 1 com o gerado com a seleção variável Laser 2, poderá permitir retirar conclusões sobre a eficiência de ambos os equipamentos e a sua influência no processo.

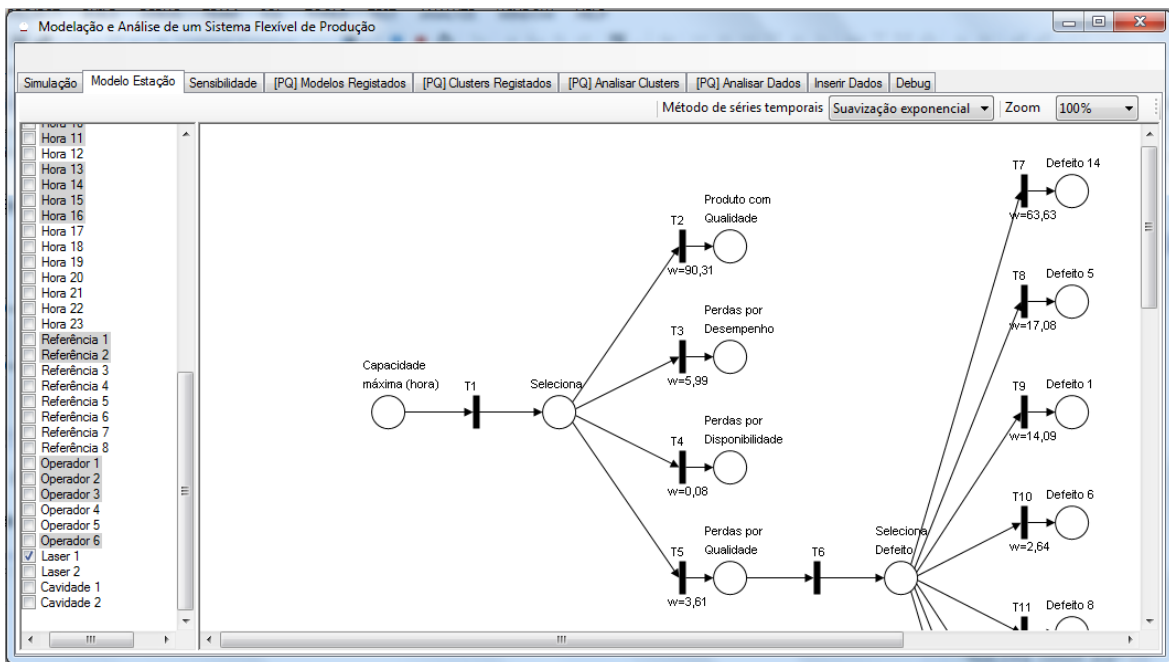


Figura 34 – Exemplo de análise equipamentos idênticos (janela da ferramenta).

Através da percentagem de Perdas por Qualidade (peso da Transição T5 da Figura 34) e a comparação entre a percentagem de cada defeito e o tipo de defeitos entre os modelos gerados, poderemos verificar, por exemplo, se um tipo de defeito provocado pela marcação laser acontece mais quando o produto é processado por um determinado equipamento.

A análise descrita também poderá ser efetuada através de combinações de variáveis, isto é, poderá ser analisado o modelo horário do sistema quando duas ou mais variáveis estão ativas. Para o exemplo dos equipamentos de marcação laser poderiam ser comparados os resultados do sistema para as primeiras horas de produção, com um determinado equipamento laser, com os das últimas horas de produção. Neste caso poderiam ser comparados os resultados de marcação laser após paragens prolongadas (primeiras horas de produção) com os resultados de marcação laser após várias horas de produção.

A análise das Perdas por Desempenho também poderá ser indicadora de problemas de cadência dos equipamentos. Poderão existir no processo equipamentos que processem o produto a uma velocidade inferior, aumentando as Perdas por Desempenho.

5.2 Análise de Componentes Idênticos

Na indústria de injeção de componentes técnicos em plástico é comum o uso de ferramentas de moldação (moldes) que produzem vários componentes plásticos “iguais” a cada moldação. Estas ferramentas de moldação são normalmente designadas de multicavidade, sendo cada cavidade usada para moldar um componente plástico [40]. Em termos dimensionais, os componentes produzidos poderão ter ligeiras diferenças entre cavidades já que tecnicamente é inexecutável o fabrico de várias cavidades exatamente iguais. Estas diferenças dimensionais deverão estar compreendidas dentro das tolerâncias especificadas para o componente.

O produto final a ser entregue ao cliente (e produzido pela linha de montagem) será constituído por um conjunto de componentes, como por exemplo componentes plásticos, molas, circuitos elétricos, parafusos, etc. A integração de um componente plásticos de várias cavidades poderá influenciar as características do componente final, já que entre cavidades existem ligeiras diferenças dimensionais.

Considerando um exemplo de um produto final, com um movimento cinemático, cuja força tem de estar dentro de um intervalo especificado. Este produto é constituído por um componente plástico produzido num molde de duas cavidades. Os componentes produzidos na cavidade 1 provocam uma força no movimento cinemático que segue uma distribuição normal com média mais baixa que na cavidade 2, mas em ambos os produtos a média está dentro de especificação. Conhecendo estas características do produto será espectável que existam mais rejeições por forças baixas no produto com o componente da cavidade 1 do que da cavidade 2. Em termos de processo industrial será importante baixar a dispersão de forças do produto final e aproximar as forças do produto produzido ao valor um valor nominal de forças [37], de modo a baixar a probabilidade de rejeição por forças fora de especificação. Estas características não são detetadas de uma forma simples no processo e podem ser alteradas ao longo do tempo devido, por exemplo, a problemas em alguma das cavidades de moldação. A deteção deste tipo de características no produto pode levar ao planeamento de intervenções (reparações ou correções) nas cavidades que moldem componentes plásticos com características mais desvantajosas para o processo.

Em termos de logística da produção os componentes plásticos produzidos em ferramentas multicavidade são separados por cavidade e colocados em linha de uma forma planeada. Desta forma é possível modelar o este sistema com mais duas variáveis de entrada, uma para componentes da cavidade 1 e outra para componentes da cavidade 2. A modelação vai permitir comparar resultados de rejeição e previsões da produção por cavidade e retirar conclusões válidas sobre o produto com componentes da cavidade 1 e o produto com componentes da cavidade 2.

À semelhança do que foi descrito na secção anterior, a análise deste tipo de características do processo poderá ser efetuada comparando os modelos horários gerados através da seleção das variáveis Cavidade 1 e Cavidade 2 na ferramenta desenvolvida (ver Figura 34).

5.3 Análise das Perdas

A diminuição das perdas dos processos produtivos é um objetivo constante das organizações com sistemas de produção. Estas perdas equivalem a rendimento que está a

ser perdido pela organização afetando a sua competitividade. O aumento de eficiência dos processos é assim uma tarefa que requer trabalho contínuo.

Através da utilização da ferramenta desenvolvida foi possível detetar algumas das causas (variáveis ou combinações de variáveis de entrada consideradas no modelo) originadoras de perdas no processo. A eliminação destas causas de forma a incrementar a eficiência do processo pode ser uma tarefa complexa, mas a deteção da causa raiz de um problema acaba sempre por ser um bom ponto de partida para a sua resolução.

5.4 Erros de Previsão

A otimização do modelo de previsão mais apropriado ao sistema requer algum tempo de avaliação. Para tal é necessário testar o modelo ao longo do tempo, de forma a verificar se o modelo permite retirar conclusões válidas sobre o sistema real. A qualquer momento poderão existir variáveis de entrada, não consideradas na modelação do sistema, que poderão afetar os resultados do mesmo.

Durante o teste e validação da ferramenta desenvolvida observou-se que o erro de previsão acaba por ser um bom indicador da qualidade do detalhe da modelação, isto é, erros de previsão que se mostram inconstantes e aleatórios ao longo das várias previsões são um bom indicador que existem variáveis de entrada do sistema que necessitam de ser consideradas no modelo do sistema.

O modelo de previsão utilizando Suavização Exponencial foi aquele que melhores resultados apresentou para a maioria das previsões analisadas neste tipo de sistemas.

Os resultados do modelo de previsão dependem do conhecimento que se consiga adquirir do sistema real (variáveis que influenciam o processo produtivo). O excesso de detalhe do modelo pode torná-lo de análise complexa, daí a necessidade de uma análise criteriosa na seleção das variáveis de entrada.

CONCLUSÕES

Este trabalho teve como principal objetivo o desenvolvimento e validação de uma ferramenta de modelação, previsão e análise para sistemas produtivos industriais, tendo em vista o aumento do conhecimento sobre estes sistemas e possível melhoria do desempenho destes.

A utilização e desenvolvimento de várias ferramentas, conceitos, metodologias e fundamentos teóricos conhecidos da bibliografia, permitiram uma maior versatilidade da ferramenta desenvolvida.

O desenvolvimento deste trabalho sofreu algumas alterações no decorrer da modelação do sistema, sendo a metodologia apresentada resultado da aplicação e avaliação de várias abordagens. O critério de simplicidade de utilização e de interpretação dos resultados do modelo do sistema foram algumas das premissas principais para a conceção do trabalho descrito, dado que se pretende que seja utilizado por terceiros. Em termos de análise foram utilizadas representações com forte componente gráfica no intuito de simplificar de interpretação dos resultados do modelo.

Os sistemas produtivos industriais podem ser influenciados por inúmeras variáveis que têm a capacidade de interagir com o sistema, sendo por vezes difícil a sua identificação. A construção de um modelo de previsão preciso depende do conhecimento sobre o sistema real (das variáveis que influenciam o processo produtivo). O excesso de detalhe do modelo pode torná-lo de análise complexa, daí a necessidade de uma análise criteriosa na seleção das variáveis que influenciam o processo. A identificação das variáveis que têm a capacidade de interagir com o sistema depende em muito do grau de conhecimento que o utilizador da ferramenta desenvolvida possui (ou venha a possuir) sobre o sistema. Um fraco conhecimento sobre o sistema pode originar um fraco desempenho do modelo de previsão.

O modelo de sistemas produtivo industriais poderá ser alvo de reestruturações periódicas pois a qualquer momento poderão ser adicionadas outras variáveis de entrada, não consideradas na modelação do sistema, que poderão afetar os resultados do mesmo.

Analisando e interpretando a informação resultante do comportamento passado do sistema, poderá ser possível melhorar a eficiência dos sistemas. A ferramenta de modelação, previsão e análise para sistemas produtivos industriais desenvolvida e descrita neste trabalho, mostrou-se capaz de auxiliar na deteção e interpretação das causas que influenciam os resultados do sistema produtivo e originam perdas em casos reais.

A experiência adquirida através do estudo dos modelos dos sistemas de produção poderá auxiliar no desenvolvimento de novos projetos de forma a torná-los mais eficientes e robustos desde a sua conceção.

A análise dos sistemas produtivos pode potenciar ganhos evidentes para as organizações. Contudo, a reatividade na resolução dos problemas detetados acaba por ser um fator chave para que estes se concretizem. Em termos de trabalho futuro será importante trabalhar a ferramenta no sentido do controlo do sistema, isto é, dependendo do estado atual do sistema, a ferramenta poderá intervir (ou informar) em tempo real de forma a melhorar os seus resultados, baseada no seu conhecimento sobre o sistema e processo modelados.

REFERÊNCIAS

- [1] J. Morrell, *How to Forecast: A Guide for Business*, Gower Publishing, Ltd., 2001.
- [2] A. Porter, A. T. Roper, T. Mason, F. Rossini e J. Banks, *Forecasting and Management of Technology*, John Wiley & Sons, 1991.
- [3] J. S. Armstrong, *Principles of Forecasting: A Handbook for Researchers and Practitioners*, Springer, 2001.
- [4] C. Chatfield, *The Analysis of Time Series: An Introduction, Sixth Edition*, Chapman & Hall / CRC, 2013.
- [5] K. Gurney, *An Introduction to Neural Networks*, CRC Press, 2003.
- [6] G. P. Zhang, *Neural Networks in Business Forecasting*, Idea Group Inc (IGI), 2004.
- [7] L. C. Jain e V. R. Vemuri, *Industrial Applications of Neural Networks*, CRC Press, 1998.
- [8] S. Ablameyko, *Neural Networks for Instrumentation, Measurement and Related Industrial Applications*, IOS Press, 2003.
- [9] M. A. Ashi, *Robotic Manipulator Control Using Neural Networks: A Research Case Study Onto a 2-DOF Robotic Arm*, LAP Lambert Academic Publishing, 2014.
- [10] S. Sivanandam e S. N. Deepa, *Introduction to Genetic Algorithms*, Springer, 2007.
- [11] G. Rigatos, *Modelling and Control for Intelligent Industrial Systems: Adaptive Algorithms in Robotics and Industrial*, Springer, 2011.
- [12] C. T. Leondes, *Intelligent Systems: Technology and Applications, Six Volume Set*, CRC Press, 2002.
- [13] M. Diaz, *Petri Nets: Fundamental Models, Verification and Applications*, ISTE, 2009.
- [14] M. Zhou, *Modeling, Simulation, and Control of Flexible Manufacturing Systems: A Petri Net Approach*, World Scientific, 1999.
- [15] J. Gonçalves, *Modelação e Análise de um Sistema Flexível de Produção*, Leiria: Tese Mestrado em Engenharia Electrotécnica, Escola Superior de Tecnologia e Gestão, 2014.
- [16] M. Zhou, *Petri Nets in Flexible and Agile Automation*, Springer US, 2012.

- [17] 12207-2008 - ISO/IEC/IEEE (Standard for Systems and Software Engineering - Software Life Cycle Processes), Institute of Electrical and Electronics Engineers, 2008.
- [18] ANSI/IEEE Std 488.1-1987 (IEEE Standard Digital Interface for Programmable Instrumentation), Institute of Electrical and Electronics Engineers, 1988.
- [19] B. Hruz e M. Zhou, Modeling and Control of Discrete-event Dynamic Systems with Petri nets and other tools, London: Springer, 2007.
- [20] C. Cassandras e S. Lafortune, Introduction to Discrete Event Systems, Kluwer Academic Publishers, 2008.
- [21] C. Petri, Kommunikation mit Automaten, Bonn: Schriften des IIM Nr.2, Institut für Instrumentelle Mathematik, 1962.
- [22] M. Tadao, Petri nets: properties, analysis and applications, Proceedings of the IEEE, 4, 541–580., 1989.
- [23] A. Zimmermann, Stochastic Discrete Event Systems: Modeling, Evaluation, Applications, Springer Science & Business Media, 2008.
- [24] J. Velagic, E. Drljevic e M. Mehanovic, Functional and temporal analysis of flexible manufacturing system with generalized stochastic Petri net, John Wiley & Sons, 2003.
- [25] D. Anderson, D. Sweeney, T. Williams, J. Camm e J. Cochran, Quantitative Methods for Business, Cengage Learning, 2012.
- [26] S. Gupta e M. Starr, Production and Operations Management Systems, CRC Press, 2014.
- [27] H. C. Robert, Overall Equipment Effectiveness, New York: Industrial Press, Inc., 2001.
- [28] Y. Monden, Toyota Production System: An Integrated Approach to Just-in-time, CRC Press, 2012.
- [29] H. S. Gitlow, Quality Management Systems: A Practical Guide, CRC Press, 2000.
- [30] P. F. Wilson, L. D. Dell e G. F. Anderson, Root Cause Analysis: A Tool for Total Quality Management, ASQ Quality Press, 01/01/1993 - 216 páginas, 1993.
- [31] D. C. Montgomery, Introduction to Statistical Quality Control, 6th Edition, John Wiley & Sons, Inc., 2009.

-
- [32] S. Basu, I. Davidson e K. Wagstaff, *Constrained Clustering: Advances in Algorithms, Theory, and Applications*, CRC Press, 2008.
- [33] J. Wu, *Advances in K-means Clustering: A Data Mining Thinking*, Springer, 2012.
- [34] M. Grunwald, *Human Haptic Perception: Basics and Applications*, Springer, 2008.
- [35] B. Rekiek e A. Delchambre, *Assembly Line Design: The Balancing of Mixed-Model Hybrid Assembly Lines with Genetic Algorithms*, Springer, 2006.
- [36] E. Ries, *The Lean Startup: How Today's Entrepreneurs Use Continuous Innovation to Create Radically Successful Businesses*, Random House LLC, 2011.
- [37] D. C. Montgomery, C. L. Jennings e M. Kulahci, *Introduction to Time Series Analysis and Forecasting*, New Jersey: John Wiley & Sons, Inc, 2008.
- [38] S. K. Mukhopadhyay, *Production planning and control:Text and control*, PHI Learning Pvt. Ltd., 2007.
- [39] C. E. Webb e J. D. C. Jones, *Handbook of Laser Technology and Applications: Applications*, CRC Press, 2004.
- [40] D. V. Rosato, D. V. Rosato e M. G. Rosato, *Injection Molding Handbook*, Springer Science & Business Media, 2000.
- [41] M. A. Pedro e T. C. Clélia, *Análise de Séries Temporais*, Editora Blucher, 2006.
- [42] S. Salivahanan, A. Vallavaraj e C. Gnanapriya, *Digital Signal Processing*, Tata McGraw-Hill Education, 2000.
- [43] A. Attoui, *Real Time and Multi-agent Systems*, Springer, 2000.
- [44] T. Rao, S. Rao e C. Rao, *Time Series Analysis: Methods and Applications*, Elsevier, 2012.