

Texto do Seminário

Sistemas Inteligentes e Adaptativos no Suporte à Tomada de Decisão



Universidade de Trás-os-Montes e Alto Douro

Escola de Ciências e Tecnologia

Departamento de Engenharias

Ana Maria Dias Madureira Pereira

novembro 2021

Sistemas Inteligentes e Adaptativos no Suporte à Tomada de Decisão



Universidade de Trás-os-Montes e Alto Douro

Escola de Ciências e Tecnologia

Departamento de Engenharias

Sumário pormenorizado do seminário ou lição apresentado no âmbito das Provas de Agregação em Informática, de acordo com a alínea c), do número 2, do artigo 8º do Decreto-Lei nº239/2007 de 19 de Junho.

Ana Maria Dias Madureira Pereira

UTAD, novembro de 2021

Índice

ENQUADRAMENTO DO SEMINÁRIO	ix
1. INTRODUÇÃO	1
2. A OTIMIZAÇÃO E O PROBLEMA DE ESCALONAMENTO	3
2.1 OTIMIZAÇÃO	3
2.2 O PROBLEMA DE ESCALONAMENTO	4
2.3 CLASSIFICAÇÃO DOS PROBLEMAS DE ESCALONAMENTO	6
2.4 TÉCNICAS DE OTIMIZAÇÃO INSPIRADAS NA NATUREZA	7
2.5 SUMÁRIO	12
3. SISTEMAS INTELIGENTES E ADAPTATIVOS	13
3.1 SEPDINET - SISTEMA DE ESCALONAMENTO PARA PROBLEMAS DINÂMICOS NÃO-DETERMINÍSTICOS	13
3.2 MASDScheGATS - SISTEMA MULTI-AGENTE PARA ESCALONAMENTO DISTRIBUÍDO DA PRODUÇÃO COM ALGORITMOS GENÉTICOS E PESQUISA TABU (POCTI/EME/61229/2004)	15
3.2.1 <i>Arquitetura do sistema MASDScheGATS</i>	16
3.2.2 <i>Resultados</i>	17
3.3 AUTODYNAGENTS - AUTONOMIC AGENTS WITH SELF-MANAGING CAPABILITIES FOR DYNAMIC SCHEDULING SUPPORT IN A COOPERATIVE MANUFACTURING SYSTEM (PTDC/EME-GIN/66848/2006)	18
3.3.1 <i>Arquitetura do sistema AutoDynAgents</i>	18
3.3.2 <i>Modelo do sistema AutoDynAgents</i>	19
3.3.3 <i>Resultados</i>	20
3.4 ADSYS - SISTEMA DE APOIO À DECISÃO ADAPTATIVO E INTERATIVO PARA ESCALONAMENTO COM METACOGNIÇÃO E MODELAÇÃO DA EXPERIÊNCIA DO UTILIZADOR (PTDC/EME-GIN/109956/2009)	21
3.4.1 <i>Arquitetura do sistema ADSyS</i>	23
3.4.2 <i>Resultados</i>	28
3.5 SUMÁRIO	29

4. SISTEMAS INTELIGENTES NO SUPORTE À TOMADA DE DECISÃO: QUE FUTURO? .	31
4.1 TRANSFORMAÇÃO DIGITAL.....	31
4.2 INDÚSTRIA 4.0	32
4.2.1 <i>Pilares da Indústria 4.0</i>	33
4.2.2 <i>Tecnologias de suporte à Indústria 4.0</i>	34
4.3 SISTEMAS CIBER-FÍSICOS.....	35
4.4 IOT E TECNOLOGIAS RELACIONADAS	36
4.5 BLOCKCHAIN	36
4.6 INTELIGÊNCIA ARTIFICIAL	36
4.6.1 <i>Machine Learning</i>	38
4.6.2 <i>Industrial AI</i>	38
4.6.3 <i>Safe AI</i>	40
4.6.4 <i>Generalized AI</i>	40
4.7 SUMÁRIO	41
5. CONSIDERAÇÕES FINAIS.....	43
REFERÊNCIAS BIBLIOGRÁFICAS	45

Índice de Figuras

FIGURA 1 - PROBLEMA DE ESCALONAMENTO.....	5
FIGURA 2 - EVOLUÇÃO DAS TÉCNICAS DE OTIMIZAÇÃO INSPIRADAS NA IA.....	10
FIGURA 3 - SISTEMA DE ESCALONAMENTO DINÂMICO BASEADO EM META-HEURÍSTICAS (Madureira 2003).....	15
FIGURA 4 - ARQUITETURA DO SISTEMA MASDScheGATS (adaptado de Madureira et al. (2009a)).....	16
FIGURA 5 - MODELO DO SMA MASDScheGATS (Madureira et al., 2007b).....	17
FIGURA 6 - ARQUITETURA DO SISTEMA AUTODYNAGENTS (Madureira et al., 2014).....	19
FIGURA 7 - MODELO DO SISTEMA AUTODYNAGENTS (Madureira et al., 2014).....	20
FIGURA 8 - PARADIGMAS USADOS NO DESENVOLVIMENTO DO SISTEMA INTELIGENTE E ADAPTATIVO.....	22
FIGURA 9 - VISÃO GLOBAL DO SISTEMA ADSYS (Madureira et al., 2014).....	24
FIGURA 10 - ARQUITETURA DO SISTEMA ADSYS (Madureira et al., 2017).....	25
FIGURA 11 - MODELO DO SISTEMA MULTI-AGENTE (Madureira et al., 2017).....	26
FIGURA 12 - A EVOLUÇÃO ATÉ À INDÚSTRIA 4.0 (Xu et al., 2018).....	33
FIGURA 13- AS TECNOLOGIAS COM IMPACTO NA INDÚSTRIA 4.0 (Deloitte, 2020).....	35

Índice de Tabelas

TABELA 1 - ANALOGIA COM A NATUREZA.....	8
TABELA 2 - TECNOLOGIAS DE SUPORTE À INDÚSTRIA 4.0 (Büchi et al., 2020)	34

Enquadramento do Seminário

O sumário pormenorizado do seminário das provas de agregação de Ana Maria Dias Madureira Pereira, centra-se na área de desenvolvimento de Sistemas Inteligentes e Adaptativos para Escalonamento da Produção. Tal resulta da atividade de investigação da candidata e da sua contribuição na comunidade científica, conforme se pode verificar no seu curriculum vitae (CV), destacando-se os contributos na área de desenvolvimento de sistemas inteligentes no suporte à tomada de decisão, em particular, na resolução do problema de escalonamento em ambientes reais de produção.

O seu percurso como investigadora inicia-se em 1995, com o desenvolvimento dos trabalhos conducentes à realização da dissertação de Mestrado em Engenharia Eletrotécnica e de Computadores, na área de especialização em Informática Industrial, na FEUP, intitulada “Aplicação de Meta-Heurísticas a Problemas de Escalonamento de Uma Única Máquina”. As abordagens desenvolvidas incentivaram o interesse pela área científica e a sua continuidade no Doutoramento em Produção e Sistemas, na Escola de Engenharia da Universidade do Minho, com a tese intitulada “Aplicação de Meta-Heurísticas ao Problema de Escalonamento em Ambiente Dinâmico de Produção Discreta” concluída em 2003. Este trabalho surgiu da necessidade do desenvolvimento de sistemas inteligentes, eficazes e eficientes para a resolução de problemas reais de escalonamento em ambientes dinâmicos, numa perspetiva de suporte à decisão. Várias foram as perspetivas de desenvolvimento futuro. O que se considera importante dado que ao mesmo tempo que se encerra um ciclo, no qual novas ideias foram propostas e testadas, tendo sido extraídas conclusões relevantes, também se identificaram novas direções de investigação e a procura no sentido de novos desafios para os quais se considera importante dar contributos.

Os esforços desenvolvidos nesta área foram, entretanto, concretizados na aprovação de um projeto FCT em 2004 – **MASDScheGATS** (POCTI/EME/61229/2004). Deste projeto foi submetido e aprovado um pedido de registo de patente do sistema MASDScheGATS nos EUA (US patent nº 8606386). Mais tarde com a introdução de conceitos oriundos da área de *Autonomic Computing* no desenvolvimento de uma plataforma baseada em Sistemas Multi-Agentes (SMA) rentabilizou-se a ideia de que o desenvolvimento da nova geração de sistemas de informação pudesse ser conduzido pela convergência dos sistemas biológicos e dos sistemas de computação digitais, concretizada na proposta do projeto de I&D **AUTODYNAGENTS** (PTDC/EME-GIN/66848/2006) à FCT, aprovado em 2007. Com a aprovação do projeto **ADSyS** (PTDC/EME-GIN/109956/2009) no âmbito do concurso para Projetos de I&D realizado pela FCT em 2009, investigou-se a área de desenvolvimento de sistemas inteligentes para escalonamento, com recurso a aprendizagem por observação e interpretação da experiência ou por observação das decisões do perito. O sistema desenvolvido possui a capacidade de aumentar/definir a sua inteligência e o utilizador poderá ainda selecionar o nível de inteligência desejado de acordo com os objetivos de negócio e o perfil do utilizador. Mais

recentemente tem-se dedicado à aplicação de técnicas de otimização e de aprendizagem automática em diversas áreas de aplicação da gestão industrial, ao e-saúde, ao e-marketing e à robótica marinha, numa perspetiva de *Data Engineering*.

Os ambientes de fabrico apresentam um elevado nível de incerteza. Os processos de fabrico exigem requisitos específicos e detalhados e os objetivos de gestão podem ser diversos, dinâmicos e por vezes conflituosos. Perante este cenário, as iniciativas desenvolvidas tiveram como principal objetivo responder aos desafios colocados aos modernos sistemas de apoio à decisão e à realidade industrial, considerando os novos paradigmas tecnológicos e organizacionais e a necessidade de decidir de forma eficiente e robusta perante a concorrência e a natureza dinâmica do mercado.

A motivação deste seminário assenta na convicção de que ao compreendermos as soluções que a natureza emprega no dia a dia, podemos usar esse conhecimento adquirido para resolver problemas complexos com base em técnicas baseadas na Inteligência Artificial - Técnicas de Otimização, Técnicas de Aprendizagem Automática, Computação Autónoma (*Autonomic Computing*), Sistemas Multi-Agente (SMA), Interfaces Inteligentes e Modelação do Perfil do Utilizador - no sentido dos sistemas computacionais inteligentes. O principal desafio está em tirar partido da integração de diferentes técnicas ou paradigmas, na resolução de problemas existentes na realidade industrial de forma a especificar ferramentas que suportem o processo de tomada de decisão dos gestores/profissionais, nos procedimentos de controlo e planeamento do processo produtivo, e que sejam capazes de lidar com a natureza dinâmica da procura.

Pretende-se com este seminário abordar a problemática do processo de especificação e desenvolvimento de abordagens/ferramentas de otimização ditas inteligentes, particularmente quando inseridas em sistemas computacionais em que se procura explorar as sinergias da interação humano – computador numa perspetiva de suporte à decisão.

Neste seminário, serão abrangidos tópicos de áreas científicas e tecnológicas como a Inteligência Artificial, as Técnicas de Otimização baseadas na Natureza, as Técnicas de Aprendizagem Automática, a Modelação do perfil do Utilizador, entre outras. Mas também equacionados os desafios emergentes e associados à Transformação Digital e Indústria 4.0. Temas cujo estudo aprofundado pode ser inserido, total ou parcialmente, na unidade curricular (UC) de *Otimização de Sistemas (OTSIS)* no curso de Mestrado em Engenharia Informática (MEI) do ISEP/P.PORTO. Trata-se de uma UC opcional, que pode ser frequentada no 1º ano do MEI, da área de especialização “Tecnologias do Conhecimento e Decisão”, com a qual se pretende dotar os diplomados de competências necessárias para planear, desenhar, implementar, gerir e explorar o desenvolvimento de ferramentas baseadas na utilização de técnicas da Inteligência Artificial na resolução de problemas reais de otimização numa perspetiva de suporte à decisão. O seminário poderia ainda ser enquadrado no âmbito de uma aula aberta, a decorrer no final do semestre, no Mestrado em Engenharia Informática e no Mestrado em Engenharia da Inteligência Artificial (MEIA) do ISEP/P.PORTO. Poderia também ser enquadrado no âmbito do Mestrado em Engenharia Informática, bem como no Plano Doutoral do curso de Doutoramento em Informática da Escola de Ciências e Tecnologias da UTAD. Por outro lado, tendo em vista a dinamização de atividades de âmbito internacional, quer ao nível da captação de estudantes internacionais para o curso de mestrado quer para projetos de investigação e para prosseguimento de estudos ao nível do 3º ciclo, o seminário é normalmente oferecido a convite, destacando-se as seguintes palestras, proferidas pela candidata em diferentes eventos nacionais e internacionais:

1. “AI for Intelligent Scheduling Systems”, IEEE CI Lectures, IEEE Computational Intelligence Society Chapter, 12 de maio de 2021, Portugal (online).
2. “Técnicas Emergentes de Otimização baseadas na IA para o Suporte à Tomada de Decisão”, Talk @ ISLab Series, no âmbito do Perfil em Sistemas Inteligentes do Mestrado Integrado em Engenharia Informática e do Mestrado em Engenharia Informática da

Universidade do Minho, 2 de maio de 2016.

3. “Desenvolvimento de Sistemas Inteligentes para Escalonamento”, Semana da Gestão Industrial, Gestão Industrial com Passado, Presente e Futuro, com Industry 4.0, Escola de Engenharia, Campus de Azurém, Universidade do Minho, 24 a 28 de outubro 2016.
4. “Intelligent and Adaptive Systems for Scheduling”, 8th European Conference on Data Mining (ECDM) conference, 15 a 17 de julho de 2014, Lisboa, <https://datamining-conf.org/oldconferences/2014/keynote-speakers>.
5. “Escalonamento de Ordens de Fabrico em Ambiente Dinâmico através de Meta-Heurísticas”, Seminários ISE’s - Inteligência Artificial, Instituto Superior de Engenharia de Coimbra (ISEC), maio de 2005.
6. “Aplicação de Meta-Heurísticas ao Problema de Escalonamento em Ambiente Dinâmico de Produção Discreta”, Seminários ISE’s - Inteligência Artificial, Instituto Superior de Engenharia de Lisboa (ISEL), março de 2005.
7. “Aplicações de Pesquisa Tabu e Algoritmos Genéticos em Problemas de Sequenciamento”, apresentadas na disciplina Sistemas Baseados em Conhecimento do CESE em Engenharia Informática Industrial e na disciplina Engenharia do Conhecimento do CESE em Sistemas de Informação, DEI-ISEP, 1998.
8. “Aplicação de Meta-Heurísticas na resolução do Problema de Minimização da Soma Pesada dos Atrasos”, DEI, ISEP, no âmbito da disciplina Inteligência Artificial do 4º ano da licenciatura em Engenharia Informática, DEI-ISEP, 1998.
9. “Aplicações de Meta-Heurísticas na Resolução Automática de Problemas de Sequenciamento”, DEI, ISEP, no âmbito da disciplina Sistemas Baseados em Conhecimento do CESE em Engenharia Informática Industrial e na disciplina Engenharia do Conhecimento do CESE em Sistemas de Informação, DEI-ISEP, 1997.

A experiência adquirida nesta linha de investigação permitiu alcançar uma visão holística desta área do conhecimento e sua aplicação em problemas de otimização industrial. O conteúdo do seminário resulta do conhecimento adquirido e construído tendo por base projetos e trabalhos de investigação, na área do desenvolvimento de sistemas inteligentes para o problema de escalonamento com recurso a técnicas da IA. A candidata tem desenvolvido a sua atividade de investigação, orientando/(co)orientando teses de doutoramento, bolsas de investigação, e dissertações de mestrado, participando e coordenando projetos de I&D, que contribuirão para o conhecimento acumulado na área de otimização e desenvolvimento de sistemas inteligentes para escalonamento, nomeadamente:

1. ADSyS - Sistema de Apoio à Decisão Adaptativo e Interactivo para Escalonamento com Metacognição e Modelação da Experiência do Utilizador (PTDC/EME-GIN/109956/2009), aprovado no âmbito do concurso para Projetos de I&D realizado pela FCT em 2009, com um financiamento de 90 000 €, que decorreu entre abril de 2011 e setembro de 2014.
2. AutoDynAgents - Agentes Autónomos com capacidade de autogestão para apoio ao escalonamento dinâmico (PTDC/EME-GIN/66848/2006), aprovado no âmbito do concurso para Projetos de I&D realizado pela FCT em 2006, com um financiamento de 80 000 €, que decorreu entre julho de 2007 e julho 2011.
3. MASDScheGATS - Sistema Multi-Agente para Escalonamento Distribuído da Produção com Algoritmos Genéticos e Pesquisa Tabu (POCTI/EME/61229/2004), aprovado no âmbito do

concurso para Projetos de I&D realizado pela FCT em 2004, financiamento de 62 000 €, que decorreu entre julho de 2005 e julho 2008.

Neste contexto, foi registada uma patente nos EUA nesta área do conhecimento: Ana Maria Dias Madureira Pereira, Patente do sistema “Multi-Agent System for Distributed Manufacturing Scheduling with Genetic Algorithms and Tabu Search”, US patent nº 8606386, outubro 2013.

A candidata orientou 3 teses de doutoramento concluídas:

1. BRUNO MIGUEL ALMEIDA CUNHA, “Escalonamento Inteligente com Recurso a Aprendizagem por Reforço”, Doutoramento em Informática, Escola de Ciências e Tecnologia da Universidade de Trás-os-Montes e Alto Douro, fevereiro de 2021. Este trabalho de doutoramento foi coorientado pelo Doutor Benjamim Fonseca.
2. ANDRÉ BORGES GUIMARÃES SERRA E SANTOS, “Auto-Parametrização de Meta-Heurísticas para Problemas de Escalonamento em Ambiente Industrial”, Doutoramento em Engenharia Industrial e Sistemas, Departamento de Produção e Sistemas, Universidade do Minho, julho de 2020. Este trabalho de doutoramento foi coorientado pela Doutora Maria Leonilde Varela.
3. IVO PEREIRA, “Aprendizagem por Observação para Escalonamento Interativo”, Doutoramento em Engenharia Eletrotécnica e de Computadores, Escola de Ciências e Tecnologia da Universidade de Trás-os-Montes e Alto Douro, 2015. Este trabalho de doutoramento foi coorientado pelo Doutor Paulo Barroso de Moura Oliveira.

Orientou 16 teses de mestrado concluídas:

1. ÂNGELA CAROLINA ANDRADE CARNEIRO MENDONÇA TAVARES, “Metodologias para a avaliação de usabilidade” no Mestrado em Engenharia Informática - Sistemas e Tecnologias Multimédia do ISEP, 2019/2020.
2. SAMUEL DOMINGUES SANTOS COSTA CARVALHO, “Heurística auxiliada por Aprendizagem Automática aplicada a problemas de Escalonamento”, no Mestrado em Engenharia Informática - Sistemas de Informação e Conhecimento do ISEP, 2016/2017.
3. MARISA DANIELA DE CAMPOS FERREIRA DA SILVA, “Análise de Performance de Técnicas de Otimização”, no Mestrado em Engenharia Informática - Sistemas de Informação e Conhecimento do ISEP, 2016/2017.
4. NELSON JOSÉ FERREIRA DA SILVA, “Análise de Desempenho de Técnicas de Otimização Swarm Intelligence”, no Mestrado em Engenharia Informática do ISEP, 2015/2016.
5. BRUNO MIGUEL ALMEIDA CUNHA, “Scalable Intelligence for Scheduling Systems”, no Mestrado em Engenharia Informática do ISEP, 2014/2015.
6. ANDRÉ BORGES GUIMARÃES SERRA E SANTOS, “Análise de Desempenho de Técnicas de Otimização no Problema de Escalonamento”, no Mestrado em Engenharia Mecânica do ISEP, 2014/2015.
7. JOSÉ ALEJANDRO DE SOUSA MARQUES, “Heurísticas de Pesquisa Local para Problemas de Máquina Única”, no Mestrado em Engenharia Eletrotécnica e de Computadores do ISEP, 2014/2015.

8. SÍLVIA RAQUEL PINTO GOMES, “Selection Constructive based Hyper-heuristic for Dynamic Scheduling” no Mestrado em Engenharia Informática do ISEP, 2013/2014.
9. DIAMANTINO FERNANDO MADUREIRA FALCÃO, “Híper-Heurísticas com Aprendizagem”, no Mestrado em Engenharia Informática do ISEP, 2013/2014.
10. ANDRÉ BORGES G. S. E SANTOS, “Afetação de Recursos em Sistema de Produção”, no Mestrado em Engenharia Eletrotécnica e de Computadores - Sistemas e Planeamento Industrial do ISEP, 2012/2013.
11. LUIS TEIXEIRA, “Simulador de sistema de fabrico em ambiente real”, no Mestrado em Engenharia Eletrotécnica e de Computadores do ISEP, 2011/2012.
12. PAULO TAVEIRA, “Edição Gráfica de Layout Fabril no Apoio ao Planeamento e Controlo da Produção”, no Mestrado em Engenharia Informática - Sistemas e Tecnologias Multimédia do ISEP, 2011/2012.
13. JESUS EDUARDO PIAIRO, “Interfaces com o utilizador Inteligentes e Adaptativos”, no Mestrado em Multimédia da Faculdade de Engenharia da Universidade do Porto, 2011/2012.
14. BRUNO MIGUEL FERNANDES MAGALHÃES, “Auto-regulação na Gestão de Conflitos em Retalho”, no Mestrado em Engenharia Informática - Tecnologias do Conhecimento e Decisão do ISEP, 2009/2010.
15. IVO ANDRÉ SOARES PEREIRA, “Aspectos de Otimização em Aprendizagem”, no Mestrado em Engenharia Informática - Tecnologias do Conhecimento e Decisão do ISEP, 2008/2009.
16. NUNO MIGUEL FERNANDES GOMES, “Desenvolvimento de Sistema Multi-Agente para o problema de escalonamento distribuído”, no Mestrado em Investigação Operacional e Engenharia de Sistemas do Instituto Superior Técnico - Universidade Técnica de Lisboa, 2005/2008.

Divulgação de resultados em mais de 40 publicações em conferências nacionais e internacionais e 18 publicações em revistas científicas internacionais WOS e *Scopus* das quais se destacam as seguintes:

1. Bruno Cunha, Ana Madureira, Benjamim Fonseca, João Matos, “Intelligent Scheduling with Reinforcement Learning”, *Appl. Sci.*, 11(8), 3325, 2021, MDPI, DOI: <https://doi.org/10.3390/app11083710>.
2. Ivo Pereira, Ana Madureira, Eliana Costa e Silva, Ajith Abraham, “A Hybrid Metaheuristics Parameter Tuning Approach for Scheduling through Racing and Case-Based Reasoning”, *Appl. Sci.*, 11(8), 3325, 2021, MDPI, DOI: <https://doi.org/10.3390/app11083325>.
3. Bruno Cunha, Ana Madureira, Benjamim Fonseca, “Reinforcement Learning Environment for Job Shop Scheduling Problems”, *International Journal of Computer Information Systems and Industrial Management Applications*, pp. 231–238, 2020, EID: 2-s2.0-85087957489.
4. Ana Madureira, I. Pereira, P. Pereira, A. Abraham, “Negotiation mechanism for self-organized scheduling system with collective intelligence”, *Neurocomputing*, Volume 132, pp. 97–110, Elsevier, 2014, DOI: <https://doi.org/10.1016/j.neucom.2013.10.032>.
5. Ivo Pereira, Ana Madureira, “Self-Optimization module for Scheduling using Case-based Reasoning”, *Applied Soft Computing*, volume 13(3), pp. 1419-1432, Elsevier, ISSN 1568-4946, 2013, DOI: <https://doi.org/10.1016/j.asoc.2012.02.009>.
6. André S. Santos, Ana Madureira, Maria Leonilde R. Varela, “The Influence of Problem

- Specific Neighborhood Structures in Metaheuristics Performance”, Journal of Mathematics, vol. 2018, Hindawi, 2018. DOI: <https://doi.org/10.1155/2018/8072621>.
7. André Santos, Ana Madureira, Leonilde Varela, “A neighborhood search technique for the unrelated parallel-machines scheduling”, Romanian Review Precision Mechanics, Optics and Mechatronics, Bucharest 48, pp. 74-80, 2015.
 8. Ana Madureira, Joaquim Santos, Ivo Pereira, “MASDSheGATS – Scheduling System for Dynamic Manufacturing Environments”, MultiAgent Systems, S. Ahmed, M. N. Karsity (eds) In-Tech, ISBN: 978 3 902613-51-6, 2009.
 9. Ana Madureira, Carlos Ramos, Silvio Carmo Silva, “Resource-oriented scheduling for real world manufacturing systems”, Proceedings of the IEEE International Symposium on Assembly and task Planning (ISATP2003), IEEE, 2003, DOI: <https://doi.org/10.1109/ISATP.2003.1217201>.
 10. Ana Madureira, Carlos Ramos, Silvio Carmo Silva, “A coordination mechanism for real world scheduling problems using Genetic Algorithms”, Proceedings of the 2002 IEEE Congress on Evolutionary Computation, IEEE World Congress on Computational Intelligence (WCCI2002), Honolulu, Hawaii (USA), Vol.1 and 2, pp. 175-180, IEEE, DOI: <https://doi.org/10.1109/CEC.2002.1006229>, maio 2002.

Este documento é composto por duas partes: na primeira, designada Enquadramento do Seminário, descreve-se a contextualização e a motivação subjacente; a segunda, corresponde ao sumário pormenorizado do seminário.

O documento apresentado visa o cumprimento parcial dos requisitos das provas de Agregação em Informática, na Universidade de Trás-os-Montes e Alto Douro, de acordo com a alínea c), artigo 5º do Decreto-Lei nº239/2007 de 19 de junho de 2007. É necessária a apresentação de um “Sumário pormenorizado do seminário ou lição a que se refere a alínea c) do artigo 5º”.

Organização do seminário

O seminário está organizado em 5 capítulos: No capítulo, 1 é sistematizada a motivação, os objetivos, e as áreas científicas e do conhecimento relacionadas com o desenvolvimento de Sistemas Inteligentes (SI) no suporte à Tomada de Decisão. O capítulo 2, descreve o enquadramento da problemática da Otimização e o Problema de Escalonamento em ambientes reais, apresenta uma sistematização não exaustiva da classificação, tipos e procedimentos de resolução do problema de escalonamento, identificando o contexto de aplicação das Técnicas de Otimização Inspiradas na Natureza - Meta-Heurísticas - e uma perspetiva histórica da sua evolução. No capítulo 3, é descrita a linha de investigação concretizada e sistematizada informação sobre os principais paradigmas que suportam a área de desenvolvimento de sistemas inteligentes e adaptativos, descritos os resultados obtidos nos projetos de I&D coordenados, com os quais se pretendeu articular e integrar os tópicos e áreas científicas identificadas. No capítulo 4 é realizada uma sistematização da atual conjuntura técnico-científica e das oportunidades e desafios colocados pelos paradigmas associados à Transformação Digital e Indústria 4.0. Finalmente, no capítulo 5, são sistematizadas algumas considerações finais e sintetizadas as principais contribuições do seminário, incluindo a identificação de tópicos/áreas de investigação com impacto no processo de Tomada de Decisão a nível global.

Sumário pormenorizado do Seminário

1. Introdução

A pandemia COVID-19 acelerou o processo de transformação digital em curso e incrementou a importância das Tecnologias de Informação (TI) e influência na mitigação dos grandes problemas colocados pela pandemia e suas consequências a nível económico e social. As organizações devem aproveitar ao máximo esta oportunidade para transformar a crise em oportunidades de desenvolvimento tecnológico e científico, contribuindo para a promoção e implementação de novas estratégias no sentido da transformação digital, e desenvolver iniciativas na procura de soluções em termos de inovação no respetivo modelo negócio no sentido de um desenvolvimento económico sustentável.

Tem sido referida como Economia Digital, 4ª Revolução Industrial ou Indústria 4.0. Diferentes designações para uma mesma realidade: uma nova dimensão de interconectividade, de pessoas e máquinas; uma rede global, capaz de produzir uma quantidade massiva de dados, tornando visíveis padrões até agora impossíveis de processar pela mente humana; constituída por máquinas e sistemas capazes de aprender, comunicar entre si e tomar decisões (CIP, 2018).

Os Sistemas de Produção são um domínio complexo que tem passado por vários desafios de evolução, onde a necessidade de inovação em termos de produtos, serviços e processos de produção é uma constante. O planeamento de um sistema produtivo envolve frequentemente a resolução de problemas de escalonamento com um impacto significativo no desempenho das organizações. Tais problemas consistem, basicamente, em determinar a utilização ao longo do tempo, de um dado conjunto de recursos, genericamente designado por máquinas, de modo a processar múltiplas tarefas independentes ou inter-relacionadas, com vista à satisfação de objetivos de natureza económica e operacional.

A resiliência e manutenção preditiva surgem neste contexto, como um tópico onde muitas organizações/sistemas apresentam fragilidades e dificuldades em se adaptarem rapidamente às variações e condições do mercado, o que levou em alguns casos ao insucesso. É identificada como uma propriedade procurada para os próprios sistemas/métodos baseados em Inteligência Artificial para fazer face a problemas de manutenção, problemas de escalabilidade ou operação interrompida na presença de distúrbios externos de modo a serem capazes de lidar com a natureza dinâmica da procura e das condições de funcionamento.

Diversas abordagens têm sido usadas na resolução deste problema. O recurso a cada uma delas depende, na prática, da complexidade e das características particulares de cada classe de problemas em que o problema de escalonamento se pode desdobrar.

Os desafios associados à Indústria 4.0 são fatores responsáveis pelo fomento da investigação e desenvolvimento de novas abordagens para a resolução dos problemas de escalonamento. A competitividade contribui também para o aparecimento de sistemas de escalonamento, novos e sofisticados, motivados pelo acesso crescente e facilitado a sistemas inteligentes, adaptativos e resilientes.

A otimização, no âmbito da Indústria 4.0, assume um aspeto fortemente interdisciplinar relacionando-se com a necessidade de integração de diferentes técnicas e paradigmas na resolução de problemas reais complexos. Surgem neste contexto, as Meta-Heurísticas (MH), também designadas Técnicas de Otimização Inspiradas na Natureza, cujo interesse principal está no facto de produzirem geralmente boas soluções para um pequeno esforço computacional. São, na maioria das vezes, procedimentos suficientemente flexíveis de modo a serem capazes de lidar com restrições específicas complexas, ultrapassando assim uma das principais limitações dos métodos tradicionais (Madureira, 2009).

Os ambientes de fabrico apresentam um elevado nível de incerteza. Os processos exigem requisitos específicos e detalhados e os objetivos de gestão podem ser diversos, dinâmicos e por vezes conflituosos. Neste contexto, torna-se importante responder aos desafios colocados aos modernos sistemas de produção e à realidade industrial, considerando os novos paradigmas tecnológicos e organizacionais - Indústria 4.0 - e a necessidade de decidir de forma mais eficiente e robusta perante a concorrência e a natureza dinâmica do mercado.

A motivação para este tipo de sistemas surge da necessidade no desenvolvimento de abordagens que sejam capazes de controlar, coordenar e otimizar de forma adaptativa e resiliente a resolução dos diferentes desafios em ambientes reais de produção.

É neste contexto que o seminário deverá proporcionar uma sistematização de conhecimentos que visam desencadear a melhoria do processo de tomada de decisão, abordar a problemática do processo de especificação e desenvolvimento de abordagens/ferramentas de otimização ditas inteligentes, ágeis e resilientes, particularmente quando inseridas em sistemas computacionais em que se procura desenvolver a capacidade de adaptação, comportamento auto-organizado e explorar as sinergias da interação homem – computador numa perspetiva de suporte à decisão.

Neste seminário, pretende-se sistematizar as áreas científicas e do conhecimento relacionadas com o desenvolvimento de Sistemas Inteligentes (SI), ágeis e resilientes. Os sistemas descritos pretendem responder aos desafios colocados aos Sistemas de Produção em ambiente dinâmico, de destacar a capacidade de aumentar/definir a sua inteligência e o utilizador poder ainda seleccionar o nível de inteligência desejado de acordo com os objetivos de negócio, e desafios colocados pela Indústria 4.0, inerentes ao processo de Transformação Digital, nas organizações considerando os seus pilares: pessoas, processos, tecnologia, meio ambiente.

2. A Otimização e o Problema de Escalonamento

O planeamento de produção envolve frequentemente a resolução de problemas de escalonamento (“*scheduling*”) com um impacto importante no desempenho das organizações. Tais problemas consistem basicamente em, dado um conjunto limitado de recursos, genericamente designados por máquinas ou processadores, determinar a sua utilização ao longo do tempo, de modo a processar um conjunto de tarefas independentes ou inter-relacionadas, com vista à satisfação de objetivos de natureza económica e operacional. Neste capítulo, é inicialmente realizado o enquadramento da problemática da Otimização e o Problema de Escalonamento e sistematizadas algumas classificações de problemas, tipos e procedimentos de resolução do problema de escalonamento.

2.1 Otimização

Considerando a atual conjuntura económica e financeira, a competitividade global requer que as organizações adotem técnicas ágeis de planeamento, escalonamento e tomada de decisão estratégica. A modelação das decisões a serem realizadas e as restrições impostas, de forma que estas representem as necessidades de todos os intervenientes, tem sido uma área de interesse crescente em termos de investigação académica e industrial.

Os ambientes reais de produção apresentam um nível elevado de incerteza, os processos apresentam requisitos específicos e detalhados, e os objetivos de gestão são diversos, dinâmicos e, por vezes, conflituosos. Neste tipo de ambientes de produção, é importante a capacidade de eficaz e eficientemente, se poder afetar tarefas a máquinas, sujeitas a restrições. Este problema de Otimização Combinatória designa-se genericamente por problema de Escalonamento (Madureira, 2003).

No mercado global atual e altamente competitivo, as empresas devem estar conscientes de oportunidades momentâneas de mercado, e serem capazes reagir de forma eficiente e corretamente aos pedidos dos clientes. A capacidade para lidar com um grande número de encomendas de pequenas quantidades aumenta a complexidade do processo de escalonamento. Encontrar boas soluções para os problemas de escalonamento torna-se muito importante para os sistemas reais de produção dado que a taxa e os custos de produção são muito dependentes dos planos de escalonamento usados para controlar o fluxo de trabalho através do sistema de fabrico.

Os problemas de Otimização Combinatória surgem quando existe a necessidade de se selecionar, de um conjunto de dados discreto e finito, o melhor subconjunto que satisfaz determinados critérios de natureza económica-operacional. O grande desafio destes problemas passa por produzir, em tempo competitivo, soluções o mais próximo possível das soluções ótimas. O problema de Escalonamento é classificado como problema de Otimização Combinatória sujeito a restrições, com uma natureza dinâmica e de resolução muito complexa, sendo classificados, na teoria da Complexidade e na Teoria de Escalonamento, como NP-difíceis.

De entre as várias abordagens de resolução de problemas de Otimização Combinatória, onde se inclui o problema de Escalonamento, salientam-se os métodos de aproximação, nos quais o objetivo passa por encontrar soluções satisfatórias em tempos de execução aceitáveis. Incluem-se nesta categoria as Meta-heurísticas, muitas das quais consistem em métodos inspirados na natureza para pesquisa de soluções o mais próximo possível do ótimo global. As Meta-Heurísticas têm vindo a ganhar popularidade e são cada vez mais usadas em domínios cuja complexidade e necessidade de tomada de decisão em tempo útil tornou o uso de técnicas exatas incomportável. Uma das tarefas cruciais para alcançar um bom desempenho no uso de Meta-Heurísticas é a especificação e afinação dos seus parâmetros.

2.2 O Problema de Escalonamento

O quotidiano de uma organização envolve frequentemente a resolução de uma grande quantidade e diversidade de problemas de otimização, com um impacto significativo no desempenho das organizações. O planeamento de produção e distribuição, o planeamento de transportes, a afetação de recursos (matérias-primas, mão-de-obra ou disponibilidades temporais em máquinas) e a calendarização de tarefas constituem classes de problemas de otimização combinatória comuns na realidade industrial. Infelizmente nem sempre é possível adotarmos a solução ótima: primeiro porque devido à sua natureza e complexidade, a resolução à otimalidade, em tempo aceitável para a tomada de decisões, é normalmente impraticável; segundo, em muitos problemas a realidade ser de tal forma dinâmica que quando vamos executar a solução as características do problema já terem mudado, já não sendo esta a solução ótima para o novo problema (Madureira, 2009).

Apesar das observações realizadas anteriormente o processo de otimização é essencial sobretudo se esta for entendida como a procura por uma boa solução, no limite a ótima, para ser adotada em tempo aceitável.

Refere-se genericamente que o processo de otimização envolve a análise de sistemas complexos, a construção de modelos que descrevam as relações entre as variáveis do sistema, e a sua resolução, que se traduz na procura das melhores soluções de forma eficiente. Os resultados fornecidos pelos modelos permitem compreender e prever o comportamento dos sistemas, e servem para apoiar os gestores no processo de tomada de decisões e respetiva execução. Destaca-se o papel fundamental na gestão de recursos usados em operações e processos e na melhoria da produtividade, tendo um campo privilegiado de aplicação em diversas áreas científicas, como a Engenharia, a Gestão, a Economia, a Matemática, e muitas outras.

Devido à sua natureza intrinsecamente dinâmica, os problemas reais de escalonamento são de resolução muito complexa, sendo conhecidos em termos da teoria da complexidade como NP difíceis (“*NP-hard*”), tendo dificuldade não polinomial, para os quais o tempo requerido para a determinação de um plano ótimo ou sub-ótimo aumenta exponencialmente com o tamanho do problema (Morton e Pentico, 1993).

Note-se que, na literatura surgem normalmente os conceitos de sequenciamento (“*sequencing*”) que consiste na definição da ordem pela qual as operações são executadas, e de escalonamento (“*scheduling*”) que se refere conjuntamente à afetação dos recursos no tempo e ao sequenciamento das operações. A sequência determina habitualmente o plano de escalonamento (“*schedule*”), desde que se convencie que cada tarefa seja iniciada tão cedo quanto possível e que estejam satisfeitos determinados pressupostos não muito restritivos (Madureira, 2003).

Pode considerar-se que o Escalonamento é constituído por duas fases: a afetação ou atribuição das operações das tarefas aos recursos do sistema e o respetivo sequenciamento e calendarização (Figura 1). Estas fases podem ser tratadas separadamente ou numa forma integrada, dependendo do tipo e dimensão do sistema e da estratégia de escalonamento adotada.

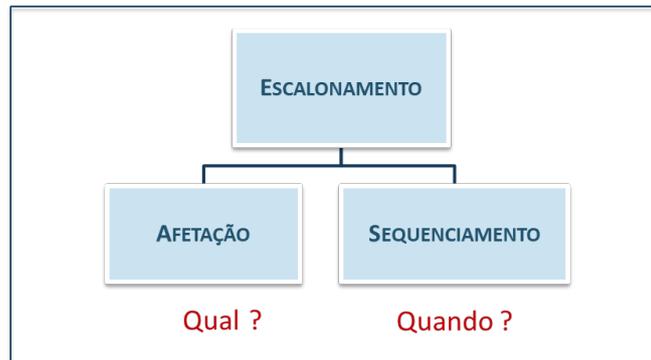


Figura 1 - Problema de Escalonamento

Assim sendo, pode-se dizer que o escalonamento visa a afetação no tempo de recursos escassos designados máquinas, a atividades ou tarefas (“jobs”), sujeitas às restrições básicas de que em qualquer instante nenhuma máquina processa mais do que uma tarefa, e nenhuma tarefa é processada em simultâneo em mais do que uma máquina. Como textos de referência sobre escalonamento referem-se (Conway, 1967), (Baker, 1974), (French, 1982), (Morton e Pentico, 1993), (Pinedo, 2016).

Tradicionalmente, os métodos de escalonamento foram desenvolvidos tendo como referência a resolução de problemas de natureza industrial, no fabrico de bens. Por este facto tornou-se corrente a utilização de vocabulário associado à produção industrial (Conway, 1967), (Baker, 1974) e (French, 1982). No entanto, a sua aplicação pode ser igualmente considerada para a área de prestação de serviços, como por exemplo, em problemas de tratamento de doentes num hospital, de atendimento de clientes numa livraria, num supermercado ou num restaurante, da reparação de automóveis numa garagem, ou da organização e controle de tráfego aéreo. Os recursos e as tarefas podem assumir diferentes formas, conforme o ambiente em que estão inseridos. Assim, os recursos podem ser máquinas num ambiente fabril, pistas em aeroportos, quartos em hotéis, médicos, enfermeiros e salas em hospitais, professores e salas em escolas, unidades de processamento em computadores, etc. Por tarefas pode entender-se os processos de fabrico de produtos num ambiente fabril, descolagens e aterragens em aeroportos, estadas em hotéis, tratamentos em hospitais, aulas em escolas e execução de programas em computadores, para além de outros. As tarefas a escalonar são caracterizadas por diferentes parâmetros, tipicamente o tempo de processamento, a data de entrega e a data de lançamento. Os objetivos podem ser distintos tais como a minimização do tempo de conclusão ou do número de tarefas em atraso e a maximização da utilização dos recursos.

O escalonamento de operações define em que ordem as operações das ordens de fabrico serão processadas nas máquinas. O escalonamento é considerado um processo de tomada de decisão relacionado com a afetação de recursos limitados a recursos competitivos ao longo do tempo, com restrições e objetivos de otimização económica e tecnológica. Neste contexto, pretende-se dar resposta a duas questões:

- ***Como distribuir as tarefas entre as máquinas disponíveis para maximizar o desempenho?***
- ***Em que sequência devem ser processadas as tarefas para maximizar o desempenho?***

Neste documento, considera-se que a afetação ou atribuição das operações às respetivas máquinas já foi previamente realizada, sendo o objetivo definir uma abordagem que realize o melhor escalonamento possível das operações nas máquinas, recorrendo a Técnicas de Otimização Inspiradas na Natureza – Meta-Heurísticas.

Assim, pode afirmar-se que o problema de escalonamento visa a afetação no tempo de tarefas a determinadas máquinas, sujeitas a algumas restrições, como, por exemplo, nenhuma máquina poder processar mais do que uma tarefa em simultâneo. Consideram-se algumas definições para os elementos do problema de Escalonamento (Madureira, 2003):

- Uma **máquina** é caracterizada pelas suas capacidades funcionais ou qualitativas, isto é, operações que é capaz de efetuar, e capacidades quantitativas, como, por exemplo, taxa de produção, tempo de processamento, tempos de preparação.
- Uma **tarefa** é composta por um conjunto de operações que podem ser sequenciais, ou concorrentes, necessárias para a produção de um produto ou lote de produtos. A cada tarefa está associada uma gama operatória definida por um grafo de precedências de operações, o qual especifica a ordem das operações bem como, para cada operação, quais as operações que a precedem e quais as que lhe sucedem.
- Uma **operação** corresponde a um processo de uma tarefa a ser processada numa máquina. A cada operação está associado um tempo de processamento numa máquina, além da possibilidade de definir tempos de preparação, tempos de transporte e tempos de espera nessa máquina.
- Um **plano de escalonamento** é um programa de execução de tarefas, com a identificação clara da sequência de processamento das tarefas nas máquinas, bem como os tempos de início e de conclusão das operações de cada tarefa. Um plano diz-se possível, admissível ou exequível se for possível ser totalmente cumprido obedecendo às restrições impostas ou existentes.

2.3 Classificação dos problemas de escalonamento

Os problemas de escalonamento podem ser classificados seguindo diferentes taxonomias. Madureira (2003) apresenta três categorias diferentes de classificação descritas na literatura, nomeadamente, considerando a complexidade de processamento, o ambiente de escalonamento, e a variabilidade de parâmetros.

A complexidade de processamento permite avaliar o número de passos de processamento, isto é, o número de visitas a máquinas, e o número de máquinas associadas ao processo de produção. Segundo a complexidade de processamento, os problemas de escalonamento podem ser categorizados em problemas com tarefas **uni-operação** e problemas com tarefas **multi-operação**. Nos problemas com tarefas **uni-operação**, as tarefas são constituídas por uma única operação que é processada numa única máquina, em sistemas de máquina única ou em sistemas de máquinas paralelas. A diferença entre os dois sistemas baseia-se no facto de nas máquinas paralelas, cada tarefa ser processada numa única máquina de entre um conjunto de máquinas possíveis. Nos problemas com tarefas **multi-operação**, cada tarefa é constituída por um conjunto de operações processadas em máquinas diferentes, e podem ser divididos em problemas **Flow-Shop**, **Job-Shop** e **Open-Shop**. Num problema **Flow-Shop** todas as tarefas têm a mesma ordem de processamento nas máquinas. Num problema **Job-Shop**, cada tarefa é processada numa sequência de máquinas fixa e pré-definida. Num problema **Open-Shop**, a ordem de processamento das operações nas diferentes máquinas é irrelevante.

O problema de escalonamento classificado segundo o ambiente de escalonamento pode ser considerado um problema **estático** ou **dinâmico** (French, 1982). **Problemas estáticos** são aqueles em que todas as tarefas a escalonar estão disponíveis no início do período de escalonamento e não sofrem modificações ao longo do tempo. Pelo contrário, se o número de tarefas variar ao longo do tempo, ou seja, se houver inserções ou cancelamento de tarefas, o problema é considerado **dinâmico**.

Quanto à variabilidade de parâmetros, os problemas de escalonamento podem ser classificados em **determinísticos** e **não-determinísticos**. Os problemas dizem-se **determinísticos** se todos os parâmetros das tarefas são conhecidos à priori. Desta forma, se existirem datas de lançamento diferentes para cada tarefa, estas são conhecidas. Os problemas **não-determinísticos** são aqueles que representam um cenário real de fabrico, sujeito a fatores aleatórios de mudança que provocam alterações no estado do sistema (Blazewicz et al., 2001). Assim, o plano de escalonamento precisa de ser reescalonado dinamicamente sempre que eventos inesperados ocorrem no sistema. Por omissão, os problemas estáticos são implicitamente determinísticos, uma vez que todos os parâmetros do problema são conhecidos no início do período de escalonamento. A generalidade dos sistemas reais de fabrico é constituída por problemas dinâmicos não-determinísticos, isto é, o seu estado pode ser alterado pela possibilidade de ocorrência contínua de eventos aleatórios (Madureira, 2003).

2.4 Técnicas de Otimização Inspiradas na Natureza

O processo de otimização envolve a análise de sistemas complexos, a construção de modelos que descrevam as relações entre as variáveis do sistema, e a sua resolução, que se traduz na procura das melhores soluções de forma eficiente. Os resultados fornecidos pelos modelos permitem compreender e prever o comportamento dos sistemas, e servem para apoiar os gestores no processo de tomada de decisões e execução das mesmas. Destaca-se o papel fundamental na gestão de recursos usados em operações e processos e na melhoria da produtividade, tendo um campo privilegiado de aplicação em diversas áreas científicas, como a Engenharia, a Gestão, a Economia, a Matemática, e muitas outras.

A Inteligência Artificial (termo introduzido por John McCarthy em 1956) pode ser definida como a área científica que procura explicar e imitar o comportamento inteligente através de processos computacionais. Refere-se a um domínio do conhecimento cada vez mais atual, que procura estudar e compreender o fenómeno da inteligência e, como ramo da Engenharia, tem por objetivo construir ferramentas/abordagens para apoiar e suportar as decisões humanas (Engelbrecht, 2007).

As técnicas de aproximação conceitualmente inovadoras, denominadas Técnicas de Otimização Inspiradas na Natureza (baseadas na Inteligência Artificial) ou Meta-Heurísticas, têm sido desenvolvidas e aplicadas nas mais diversas áreas, sendo também promissoras na resolução de diversos problemas tais como o problema de escalonamento. Ao longo das últimas décadas tem havido um interesse crescente na aplicação de algoritmos que adotam de algum modo os princípios de processos naturais, nomeadamente no que se refere à componente biológica e de imitação de comportamentos encontrados na natureza. Tais métodos têm recebido diferentes designações, desde Meta-Heurísticas, “Soft Computing”, Computação Evolucionária, “Swarm Intelligence”, entre outras (Dorigo, 2007), (Talbi, 2009). O aparecimento destas novas técnicas, e a sua possível adaptação a problemas tradicionalmente abordados por modelos clássicos, despertou um renovado interesse por este tipo de problemas.

Os métodos para a resolução de problemas de otimização de difícil resolução, cujo tempo de resolução aumenta exponencialmente à medida que a dimensão dos problemas aumenta, podem ser divididos em duas categorias abrangentes: a primeira inclui os métodos cujo objetivo consiste em encontrar soluções ótimas através de um processo de pesquisa exaustiva do espaço solução – os **métodos exatos**. Esta categoria inclui técnicas como a enumeração implícita, o “*Branch-and-Bound*” e a programação dinâmica. No entanto, estes métodos só devem ser considerados para resolução de problemas de pequena dimensão; a segunda categoria tem por finalidade encontrar soluções satisfatórias num período de tempo aceitável. Esta classe de técnicas designa-se genericamente por algoritmos ou **métodos de aproximação**.

Neste seminário, adota-se a definição mais genérica e usada por alguns autores, para designar os métodos de aproximação em que a otimalidade não é garantida, mas permitem a obtenção de soluções satisfatórias, numa forma eficiente - Meta-Heurísticas. Quando a solução ótima para o problema não é conhecida ou difícil de determinar pode considerar-se o uso da melhor solução conhecida até ao momento. Procurar a solução ótima para um problema pode não fazer sentido em determinadas situações, face a restrições económicas e/ou computacionais, ou mesmo ser impossível. É neste contexto que surgem os algoritmos ou métodos de aproximação, considerados ferramentas de utilização prática na resolução de problemas difíceis de otimização combinatória. São de referir os métodos ou heurísticas construtivas e as Meta-Heurísticas.

Tabela 1 - Analogia com a natureza

Técnica de Otimização	Aspetos de inspiração
Pesquisa Tabu (Tabu Search - TS)	Procura imitar o comportamento humano ao aplicar algumas regras de aprendizagem. Com o uso de memória, o passado recente ou mais afastado, vai influir determinantemente no processo de pesquisa, guiando-a em função das soluções já visitadas (Glover, 1989).
Arrefecimento Simulado (Simulated Annealing - SA)	Cuja inspiração advém da termodinâmica e da metalurgia, tendo por base o processo em que o metal em fusão é arrefecido lentamente, tendendo a solidificar numa estrutura de energia mínima (Kirkpatrick et al., 1983), (Cerny, 1985).
Algoritmo Genético (Genetic Algorithms - GA)	É inspirado na evolução natural das espécies de Darwin e na genética populacional. Os indivíduos melhor adaptados têm maior probabilidade de sobrevivência (Holland, 1975).
Otimização por Colónia de Formigas (Ant Colony Optimization - ACO)	Baseada no comportamento de uma colónia de formigas. Esta técnica simula o comportamento de um conjunto de agentes (formigas) que cooperam para resolver um problema de otimização por meio de comunicações muito simples (depósito de feromona). A inteligência da colónia demonstrada pelas formigas baseia-se não só na cooperação entre os indivíduos, mas também na coordenação de cada formiga individualmente (Dorigo et al., 1991).
Otimização por Nuvem de Partículas (Particle Swarm Optimization - PSO)	Inspirada na dinâmica dos movimentos e no comportamento social de bandos de aves ou cardumes de peixes em movimento coordenado e sincronizado como forma de descobrir alimento ou como mecanismo de autodefesa (Eberhart e Kennedy, 1995).
Colónias de Abelhas Artificiais (Artificial Bee Colony - ABC)	Inspirada nos comportamentos das abelhas. Os primeiros algoritmos surgiram em 2005 por Derviş Karaboğa (Karaboga, 2005) e Duc Truong Pham (Pham et al., 2005), de modo independente. Estes algoritmos são inspirados no comportamento numa colónia de abelhas à procura de comida, o que pode ser usado como modelo para comportamentos inteligentes e coletivos.
Otimização do Enxame de Pirlampos (Glowworm Search Optimization - GSO)	Técnica integrada na categoria de Swarm Intelligence que tem por objetivo otimizar funções multi-modais. O algoritmo foi proposto por Krishnanad e Ghose em 2005 (Krishnanad e Ghose, 2005) e usam entidades físicas (agentes) designados por pirlampos. Inspirado no comportamento de emissão de luz dos pirlampos para atrair uma presa na natureza.
(Cuckoo search algorithm - CSA)	Algoritmo inspirado na natureza, inspirado na estratégia reprodutiva de uma ninhada de aves cucos para aumentar a sua população (Yang e Deb, 2009). É inspirado no parasitismo da ninhada de algumas espécies de cucos colocando os ovos nos ninhos de outras espécies de aves.
Algoritmo de Pesquisa de Morcegos (Bat Algorithm - BA)	Inspirado no comportamento dos morcegos, considera a capacidade de ecolocalização dos morcegos rentabilizando a característica da frequência. A frequência tem influência na equação de velocidade que determina a direção na procura do espaço (Yang e Gandomi, 2012).
Algoritmo de otimização baseado nos lobos cinzentos (Grey Wolf Optimizer – GWO)	Imita a hierarquia de liderança e o mecanismo de caça dos lobos cinzentos na natureza (Mirjalili e Lewis, 2014).

Tem havido um interesse crescente na aplicação de algoritmos que adotam de algum modo os princípios de processos estritamente naturais (Tabela 1). São bem conhecidos os casos do Arrefecimento Simulado e da Pesquisa Tabu, permitindo a capacidade de aprendizagem e generalização. Por outro lado, a partir de paradigmas diferentes, ainda que claramente naturais, surgiram a partir de ideias iniciais de John Holland (1979) os primeiros conceitos sobre a Computação Evolucionária, introduzindo a capacidade evolutiva de adaptação e de hereditariedade de uma população. Dentro destes tipos de Computação Evolucionária e seguindo o mesmo princípio comum - a de uma população que se autopropetua ao longo de uma série de transformações, lutando pela própria sobrevivência - os Algoritmos Genéticos são os mais conhecidos. Mais recentemente, com inspiração no comportamento social dos insetos e outros animais surgiu o paradigma da Inteligência dos Enxames (*Swarm Intelligence*) desenvolvido a partir do estudo do comportamento coletivo auto-organizado de sistemas descentralizados, constituídos por um número elevado de agentes, com o objetivo de realizar uma determinada tarefa (Dorigo, 2007).

Esta classe de técnicas de otimização reflete a criatividade e inovação humana no sentido da imitação de fenómenos ou mecanismos verificados na natureza numa direta alusão aos fundamentos da Inteligência Artificial. As vantagens da inspiração e imitação de processos observados na natureza são inquestionáveis e podem ser analisados a diferentes níveis:

- Fonte de inspiração (processos físicos e biológicos, dinâmica do comportamento de bandos de aves, de enxames e cardumes e respetiva cooperação e sincronização).
- Simulação de comportamentos sociais (estratégias de defesa e de procura de alimento).
- Mecanismos de evolução e reprodução (seleção natural).

Para além do grande número de trabalhos teóricos, as Meta-Heurísticas de otimização têm sido aplicadas em várias áreas de estudo. O interesse crescente no recurso a técnicas de otimização enquadradas nesta categoria deve-se particularmente aos seguintes aspetos:

- Simplicidade - são inspiradas por conceitos muito simples e tipicamente relacionadas com fenómenos físicos, comportamentos de animais ou conceitos evolutivos. A simplicidade permite a simulação de diferentes conceitos naturais, e que novas meta-heurísticas sejam propostas, ou a sua hibridização seja realizada no sentido da melhoria do seu desempenho. A simplicidade permite ainda incrementar a curva de aprendizagem de outros peritos e a sua aplicação aos seus problemas.
- Flexibilidade - refere-se à aplicabilidade da MH a diferentes problemas sem alterações especiais na estrutura do algoritmo. A MH é facilmente aplicável a diferentes problemas, uma vez que assumem principalmente os problemas como caixas negras, apenas os inputs e output(s) de um sistema são importantes para o seu desenvolvimento. A representação do problema assume neste contexto uma importância relevante.
- Mecanismo livre de derivação - em contraste com as abordagens de otimização baseadas em gradiente, as MH otimizam os problemas de forma estocástica. O processo de otimização começa com soluções aleatórias, e não há necessidade de calcular a derivada dos espaços de pesquisa para encontrar a melhor solução.
- Evitem os ótimos locais - as MH têm a capacidade para evitar o ótimo local em comparação com as técnicas convencionais de otimização. Isto deve-se à sua natureza estocástica que lhes permite evitar a estagnação em soluções locais e procurar outros espaços de pesquisa, através da diversificação. O espaço de pesquisa de problemas reais é geralmente desconhecido e muito complexo com um número significativo de ótimos locais.

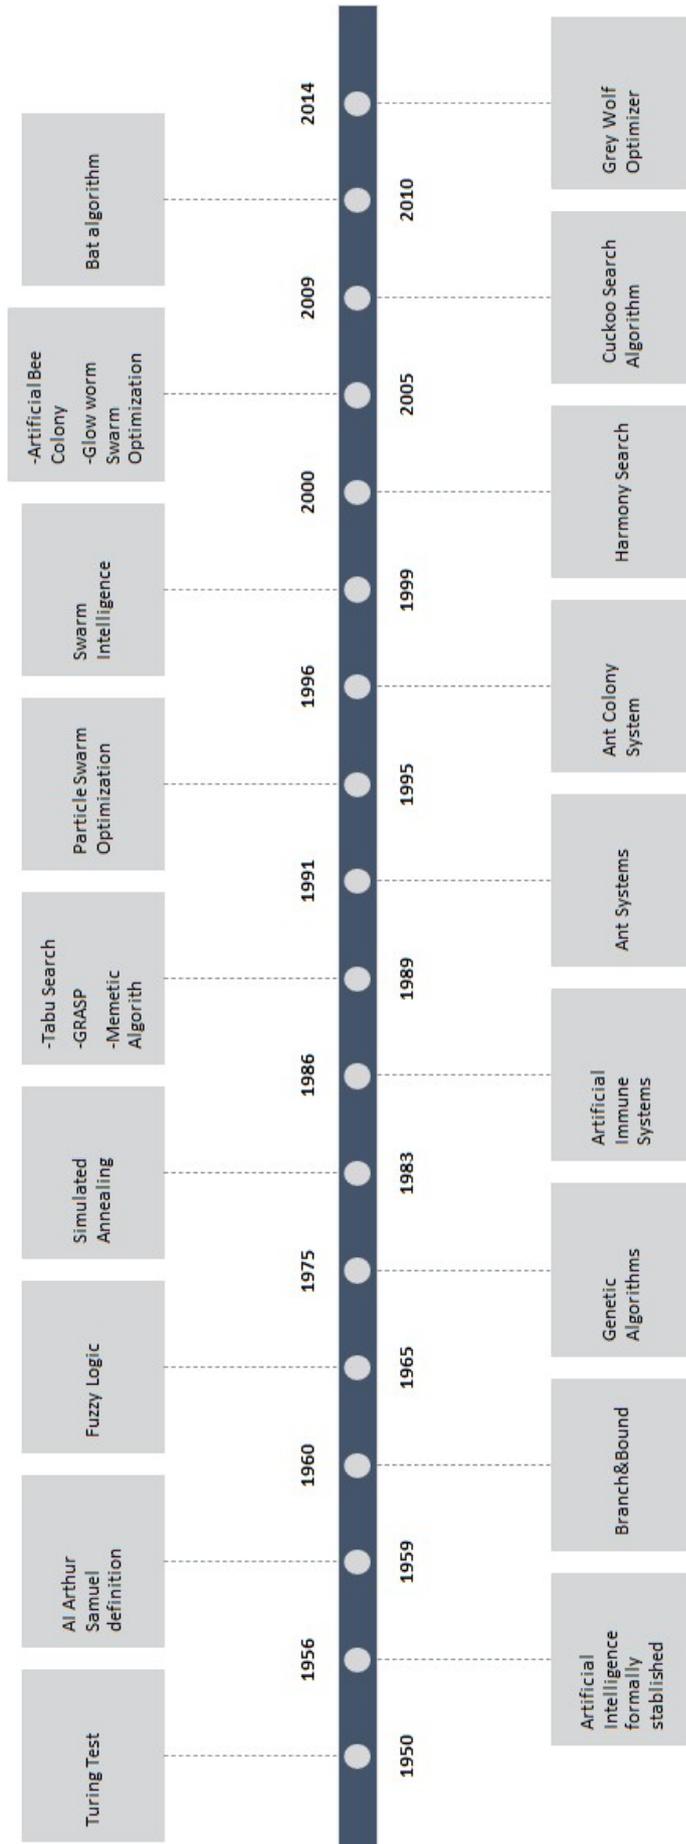


Figura 2 - Evolução das Técnicas de Otimização Inspiradas na IA

A aplicação das Meta-Heurísticas remonta à década de 60 (Figura 2). Desde então, diferentes variantes, baseadas na analogia com fenômenos da natureza, têm sido propostas e expandidas a outras áreas de aplicação. O aumento dos recursos computacionais assim como o uso de estruturas de dados sofisticadas tornaram as Meta-Heurísticas fortes competidoras com outras classes de algoritmos na resolução de problemas de grande dimensão. A flexibilidade e a facilidade de implementação tornaram-nas eficientes no tratamento e resolução de muitos problemas complexos reais.

As Meta-Heurísticas permitem suportar os sistemas de apoio à decisão na medida em que constituem ferramentas robustas que permitem a obtenção de soluções de boa qualidade, em horizontes temporais razoáveis, para importantes aplicações em diferentes áreas, nomeadamente na Engenharia e na Economia. Encontrar soluções exatas nestas aplicações continua ainda a ser um desafio real, apesar do impacto dos recentes avanços na área das Tecnologias de Informação e na interação entre a Informática, a Matemática, a Investigação Operacional e a Inteligência Artificial. Têm-se verificado significativos desenvolvimentos na teoria e aplicação das técnicas Meta-Heurísticas a problemas de otimização de difícil resolução (*NP-Hard*).

A rápida divulgação destes métodos deve-se à sua capacidade de adaptação a problemas de grande dimensão, como são a maior parte dos problemas reais. Uma abordagem introdutória pode ser encontrada em (Pirlot, 1996). Outras fontes onde poderão ser encontradas descrições sobre este assunto são (Dorigo, 2006), (Siarry e Michalewicz, 2008), (Gonzalez, 2008) e (Talbi, 2009). Mais recentemente surgiram as técnicas de otimização enquadradas na categoria de *Swarm Intelligence* (Bonabeau, Dorigo e Theraulaz, 1999) e definida geralmente como o comportamento emergente da inteligência coletiva de grupos de agentes.

A **complexidade** de um problema de otimização é um indicador da respetiva dificuldade de resolução. A **dimensão das instâncias do problema** é igualmente um fator importante a considerar. Mesmo para problemas NP-hard, instâncias de pequena dimensão são resolúveis pelos métodos exatos. Adicionalmente deve ser analisada a **estrutura das instâncias**. A literatura refere algoritmos polinomiais para a resolução de alguns problemas. Finalmente, o **tempo de pesquisa** disponível é considerado um fator importante na seleção do método de otimização a usar.

Não é coerente usar MH na resolução de problemas para os quais estão disponíveis métodos exatos eficientes. Por exemplo para a classe de problemas P, para os quais os métodos exatos apresentam tempos de execução aceitáveis em problemas de grande dimensão, as MH podem ser consideradas desnecessárias. As MH surgem como alternativa aos métodos exatos à medida que a dimensão e a complexidade dos problemas de otimização aumentam. Resumem-se as principais características dos problemas de otimização para as quais se justifica o recurso a MH (Talbi, 2009):

- Problemas da classe P com instâncias de grandes dimensões. Apesar do conhecimento de algoritmos polinomiais para a sua resolução, poderão tornar-se pouco eficientes para problemas de grande dimensão.
- Problemas da classe NP.
- Problemas de otimização com funções objetivo e/ou restrições pesadas computacionalmente, verificadas em problemas reais.
- Problemas de otimização em ambientes com incertezas ou sujeitos a dinamismo (modelos não determinísticos). As MH têm sido consideradas robustas na incorporação das perturbações, considerando a redução do tempo de pesquisa. Em cenários caracterizados por incerteza, ambiguidade e robustez não faz necessariamente sentido a obtenção da solução ótima.

2.5 Sumário

No mercado global atual e altamente competitivo, as empresas devem estar conscientes de oportunidades momentâneas de mercado, e serem capazes reagir de forma eficiente e corretamente aos pedidos dos clientes. A capacidade para lidar com um grande número de encomendas de pequenas quantidades aumenta a complexidade do processo de escalonamento. Encontrar boas soluções para os problemas de escalonamento torna-se muito importante para os sistemas reais de produção dado que a taxa e os custos de produção são muito dependentes dos planos de escalonamento usados para controlar o fluxo de trabalho através do sistema de fabrico.

Neste capítulo, foi inicialmente realizado o enquadramento da problemática da Optimização e o Problema de Escalonamento e realizada uma sistematização não exaustiva da classificação de problemas, tipos e procedimentos de resolução do problema de escalonamento, identificando o contexto de aplicação das Meta-Heurísticas e apresentada uma perspetiva histórica da sua evolução.

3. Sistemas Inteligentes e Adaptativos

O problema de escalonamento dinâmico corresponde a um problema distribuído, quer do ponto de vista físico quer do ponto de vista lógico. Do ponto de vista físico, os sistemas de produção dispõem de recursos geograficamente distribuídos (máquinas, robots, entre outros). Do ponto de vista lógico, estamos a lidar com um problema distribuído, dada a necessidade de processamento, em simultâneo, de diferentes tarefas em diferentes recursos.

O conceito de negociação ou cooperação revela-se necessário, na medida em que as entidades envolvidas se vêm compelidas a negociar ou a cooperar, uma vez que não possuem o controlo total sobre os recursos. É neste contexto que surgem diferentes vertentes de resolução deste tipo de problemas, nomeadamente as baseadas em Sistemas Multi-Agente (SMA). Serão de seguida descritos alguns trabalhos com contributos nesta linha de investigação, no sentido do desenvolvimento de sistemas inteligentes para a resolução de problemas distribuídos, cada vez mais complexos.

Neste capítulo, serão descritos os contributos nesta linha de investigação, no sentido do desenvolvimento de sistemas inteligentes para a resolução de problemas de escalonamento distribuídos e dinâmicos. Para cada um dos projetos de I&D foram descritos os objetivos, a arquitetura as principais contribuições e os resultados ou desenvolvimentos concretizados através de dissertações de mestrado e teses de doutoramento.

3.1 SEPDiNET - Sistema de Escalonamento para Problemas Dinâmicos Não-DETerminísticos

Nesta secção, é descrita inicialmente a arquitetura do sistema de escalonamento para a resolução do problema de escalonamento dinâmico baseado em Meta-Heurísticas, para o problema de máquina única, dada a sua especificidade e importância no âmbito do Sistema de Escalonamento para a resolução do problema *Job-Shop Alargado* em ambiente dinâmico não-determinístico.

O sistema SEPDiNET proposto e descrito em Madureira (2003) tem subjacente uma abordagem centralizada. O trabalho desenvolvido no âmbito do doutoramento, nomeadamente os aspetos definidos como trabalho futuro tiveram impacto em aplicações de relevo na área dos sistemas inteligentes de fabrico considerando o interesse crescente em abordagens descentralizadas para a resolução de problemas complexos do mundo real, como o problema de Escalonamento, e são cada vez mais as soluções propostas e as implementações bem-sucedidas. Muitas dessas abordagens recaem na área dos Sistemas Distribuídos, onde um número de entidades trabalha em conjunto para, cooperativamente, resolver problemas. De seguida, é descrito o Sistema de Escalonamento para a resolução de Problemas Dinâmicos Não-Determinísticos (SEPDiNET) orientado para a resolução de problemas de escalonamento do tipo *Job-Shop Alargado* em ambiente dinâmico não-determinístico, podendo ser aplicado a produtos simples ou compostos (Madureira, 2003).

Num sistema de fabrico do tipo *Job-Shop* podem ser identificados alguns fatores que contribuem para a dificuldade do processo de escalonamento, nomeadamente, a complexidade, as restrições e a incerteza. A complexidade é inerente à quantidade de tarefas e planos operatórios e quantidade de recursos para as processar. As restrições podem ser tecnológicas, determinando as precedências entre operações. Podem também ser temporais, por exemplo datas de entrega, tempos de preparação das máquinas e tempos de transporte. Podem ser físicas, por exemplo a capacidade dos recursos e a capacidade do nível de inventário (stock). Finalmente, as decisões têm que ser tomadas por vezes com informação incompleta e incerta sobre o estado futuro do sistema de fabrico.

Três questões importantes se colocam quando estamos perante problemas de escalonamento dinâmicos, às quais se procurou responder com o sistema SEPDiNET (Madureira, 2003):

Que decisão tomar perante uma perturbação: reescalonar ou não?

Como realizar o reescalonamento uma vez detetada a perturbação?

Como encontrar ou obter uma boa solução após a integração da alteração?

O sistema de escalonamento SEPDiNET, proposto e descrito no âmbito da tese de doutoramento, é orientado para a resolução de problemas reais de escalonamento do tipo *Job-Shop Alargado*, em ambientes dinâmicos de produção discreta de produtos simples ou compostos, constituídos por vários componentes que poderão envolver várias fases de montagem. A sua eficiência foi avaliada na resolução de problemas determinísticos com produtos simples e complexos, com estrutura linear e concorrente (com operações que podem ser executadas em simultâneo). Foi ainda considerada a possibilidade da existência de recursos ou máquinas alternativas. Uma vertente adicional tratada neste trabalho está relacionada com a resolução de problemas do tipo *Job-Shop Alargado*, mas sujeitos a um ambiente dinâmico caracterizado por variações nas condições e requisitos de processamento ao longo do tempo (Madureira, 2003). Foram tratados neste trabalho diferentes eventos aleatórios, tais como a chegada de novas tarefas e o seu cancelamento, e alterações nos tempos de processamento, nas datas de entrega e nas datas de lançamento e ainda a possibilidade da alteração das prioridades representadas pelas penalizações associadas às tarefas.

O sistema proposto é flexível, no sentido de poderem ser aplicados a diferentes classes de problemas de escalonamento, sujeitos a variadas restrições e com diferentes objetivos de desempenho. A facilidade de implementação, assim como a sua simplicidade são duas características atrativas para a sua adoção na realidade industrial.

O Método de Escalonamento baseado em Meta-Heurísticas apresenta uma filosofia inovadora, sendo diferente das encontradas na literatura até então. A originalidade está principalmente na modelação da classe de problemas, em problemas de máquina única e posterior integração das respetivas soluções no problema original. O plano resultante é constituído por um conjunto de sequências de operações, uma por cada máquina. Cada sub-problema de máquina única é resolvido por uma Meta-Heurística, que pode ser diferente de máquina para máquina. Por exemplo, a seleção da Meta-Heurística a usar pode estar relacionada com o número de tarefas a escalonar. Se esse número for reduzido pode ser aconselhável a utilização da Pesquisa Local, dada a simplicidade de implementação e requisitos computacionais, caso contrário é aconselhável o uso da Pesquisa Tabu por ter apresentado, no conjunto de testes computacionais realizados, o melhor desempenho.

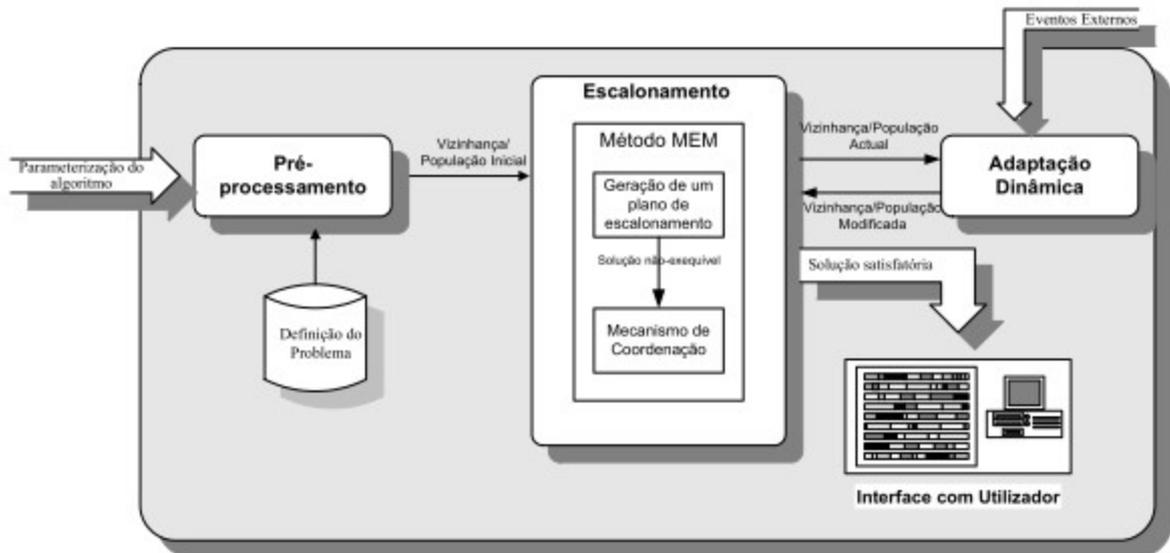


Figura 3 - Sistema de Escalonamento Dinâmico Baseado em Meta-Heurísticas (Madureira, 2003)

O sistema SEPDINET (Figura 3) tem implícita uma abordagem centralizada, sendo proposto um mecanismo reparador das soluções designado de Mecanismo de Coordenação, para a resolução de conflitos e conseqüente reparação da solução integrada. O processo de coordenação consiste em percorrer todas as seqüências e tentar “coordenar” a atividade das máquinas, tendo em conta as restrições de precedência definidas para cada uma das tarefas e os tempos de ocupação das máquinas onde estas irão ser processadas.

Neste projeto, tirou-se partido das potencialidades das Meta-Heurísticas, numa perspetiva de Escalonamento Orientado ao Recurso, que processa o escalonamento recurso a recurso, em vez de tarefa a tarefa, de forma satisfazer um dado critério de otimização, sem violar as restrições tecnológicas de precedência de cada tarefa.

3.2 MASDScheGATS - Sistema Multi-Agente para Escalonamento Distribuído da Produção com Algoritmos Genéticos e Pesquisa Tabu (POCTI/EME/61229/2004)

Neste sistema, cada agente representa uma unidade de processamento, máquinas ou tarefas. O problema de escalonamento é decomposto numa série de problemas de máquina única (Madureira, 2003), sendo que cada agente máquina resolve localmente os seus problemas de escalonamento, através da aplicação de Algoritmos Genéticos ou Pesquisa Tabu, procura e encontra soluções ótimas ou quase-ótimas. Após todos os agentes máquina terem resolvido os seus problemas locais, estes são integrados segundo um mecanismo de coordenação das soluções, de modo a serem respeitadas as precedências das tarefas, para ser criado um plano de escalonamento global.

No sistema MASDScheGATS (Madureira et al., 2009a) os Sistemas de Produção foram modelados através de Sistemas Multi-Agente, nos quais cada agente representa uma unidade de processamento (por exemplo, uma máquina). Pretendeu-se, neste projeto, tirar partido das potencialidades dos Sistemas Multi-Agente e das Meta-Heurísticas procurando apresentar uma solução inovadora com o objetivo de lidar com o problema complexo do Escalonamento Dinâmico de Sistemas Produtivos. Uma comunidade de agentes representa recursos e resolvem localmente os seus problemas de escalonamento, cooperando com outros agentes de recursos com os quais partilham tarefas tornadas explícitas através de relações de precedência entre operações. Os

Algoritmos Genéticos e a Pesquisa Tabu são adaptados de modo a lidar com problemas dinâmicos, através da reutilização e mudança de soluções e populações em função do dinamismo dos Sistemas de Produção. A afinação automática dos parâmetros usados nos métodos de Pesquisa Tabu e Algoritmos Genéticos poderão permitir uma melhor adaptação dos agentes representativos dos recursos à situação em causa.

Como objetivos específicos do sistema MASDScheGATS referem-se esforços no sentido de provar os seguintes aspetos (Madureira et al., 2009a):

- Os Sistemas de Produção podem ser modelados através de Sistemas Multi-Agente, nos quais cada agente representará uma unidade de processamento.
- Boas soluções globais para problemas de escalonamento podem emergir de uma comunidade de agentes (agente máquina) que representem recursos e que resolvam localmente os seus problemas de escalonamento, cooperando com outros agentes recursos com os quais partilhem tarefas tornadas explícitas através de relações de precedência entre operações.
- As Meta-Heurísticas - Algoritmos Genéticos e Pesquisa Tabu - podem ser adaptadas de modo a lidar com problemas dinâmicos, através da reutilização e mudança de soluções e populações em função do dinamismo dos Sistemas de Produção.
- A afinação dos parâmetros usados nos métodos de Pesquisa Tabu e Algoritmos Genéticos pode permitir uma melhor adaptação dos agentes representativos dos recursos à situação em causa.

3.2.1 Arquitetura do sistema MASDScheGATS

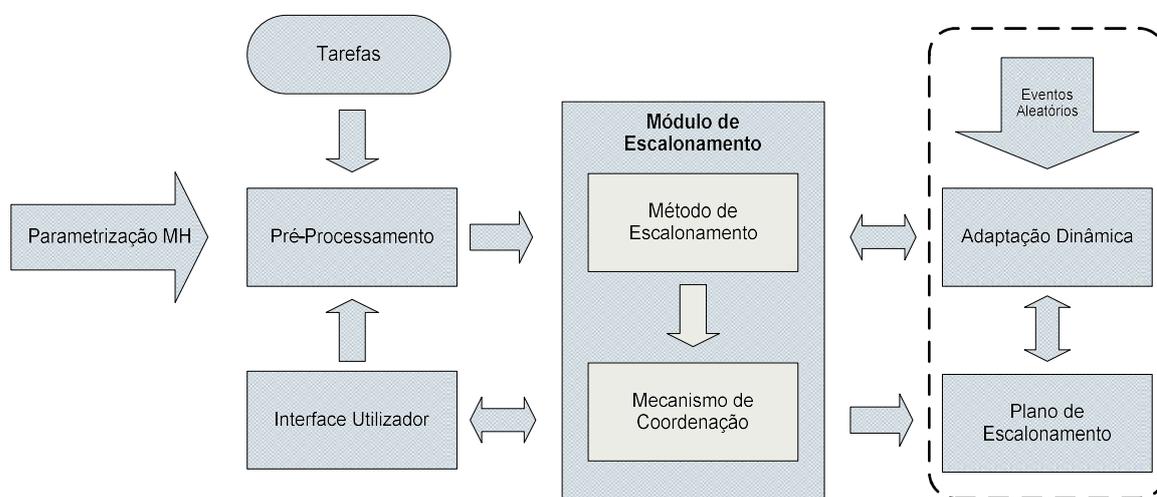


Figura 4 - Arquitetura do sistema MASDScheGATS (adaptado de Madureira et al. (2009a))

O sistema Multi-Agente MASDScheGATS está organizado seguindo o modelo em equipa e a sua arquitetura encontra-se ilustrada nas Figura 4 e 5, baseando-se em três diferentes tipos de agentes (Madureira et al., 2009b):

- **AgenteUI**: além de ser responsável pela interface de comunicação com o utilizador, o **AgenteUI** é também responsável pela criação dinâmica dos **AgentJob** necessários de acordo com o número de tarefas do problema de escalonamento, por atribuir cada tarefa ao

agente respetivo, e também por verificar e coordenar as soluções recebidas pelos **AgentResource**.

- **AgentJob**: processam a informação necessária da tarefa, ou seja, são responsáveis pela geração dos tempos mais cedo e mais tarde de processamento e pela comunicação de cada operação ao agente recurso (**AgentResource**) respetivo.
- **AgentResource**: são responsáveis por escalonar as operações recebidas dos agentes Tarefa (**AgentJob**). Estes agentes aplicam Meta-heurísticas (Algoritmos Genéticos e Pesquisa Tabu) para encontrar as melhores soluções possíveis num tempo de processamento aceitável e comunicam ao **AgentUI**, para este verificar as soluções, e aplicar o mecanismo de coordenação de modo a ser gerado um plano de escalonamento final exequível.

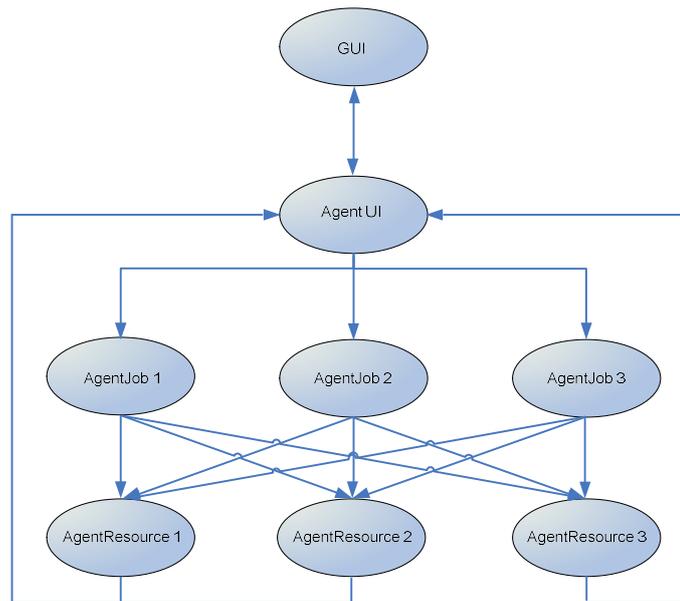


Figura 5 - Modelo do SMA MASDScheGATS (Madureira et al., 2009b)

Neste projeto, tirou-se partido das potencialidades das Meta-Heurísticas, numa perspetiva de Escalonamento Orientado ao Recurso com cooperação, numa abordagem distribuída ou descentralizada rentabilizando as potencialidades dos Sistemas Multi-Agente, no sentido da Resolução distribuída de problemas.

3.2.2 Resultados

No âmbito deste projeto de I&D foram desenvolvidos trabalhos de mestrado que permitiram ainda responder a questões e oportunidades de desenvolvimento, dos quais se destaca a dissertação de mestrado concluída e patente publicada:

1. Patente do sistema MASDScheGATS nos EUA (US patent nº 8606386).
2. NUNO MIGUEL FERNANDES GOMES, “Desenvolvimento de Sistema Multi-Agente para o problema de escalonamento distribuído”, no Mestrado em Investigação Operacional e Engenharia de Sistemas do Instituto Superior Técnico - Universidade Técnica de Lisboa, 2005/2008.

3.3 AutoDynAgents - Autonomic Agents with Self-Managing Capabilities for Dynamic Scheduling Support in a Cooperative Manufacturing System (PTDC/EME-GIN/66848/2006)

Com o projeto **AutoDynAgents** pretendeu-se a especificação de um sistema baseado em SMA e em Técnicas Otimização Inspiradas na Natureza com capacidades de aprendizagem e autogestão para a resolução de problemas de escalonamento complexos, com recurso a negociação cooperativa, tendo como principal objetivo reduzir a complexidade do processo de gestão deste tipo de sistemas e a intervenção humana. O sistema de escalonamento deverá ser equipado com capacidade de diagnóstico e resolução de problemas, incorporando o conceito da Computação Autónoma.

Tradicionalmente, a resolução de problemas de escalonamento requer a intervenção de utilizadores bem qualificados (os peritos). Esta é uma tarefa difícil, e reflete um domínio com importantes desafios, dado que os sistemas atuais estão a tornar-se cada vez mais complexos, distribuídos, interligados e sujeitos a rápidas mudanças. A Computação Autónoma (*Autonomic Computing*) surgiu assim como uma visão/desafio para o futuro, no qual os sistemas seriam capazes de se auto gerirem de acordo com objetivos de alto nível definidos pelo utilizador. Pretende-se com o projeto AutoDynAgents dar uma contribuição significativa na especificação de sistemas de escalonamento, para problemas dinâmicos em sistemas de fabrico, com autogestão. O sistema AutoDynAgents possui as seguintes capacidades de autogestão (Madureira et al., 2014):

- **Auto-Configuração** - permite aos agentes adaptar-se a alterações/perturbações pela alteração da sua própria configuração, permitindo acrescentar ou remover recursos/tarefas sem interrupção do processamento. Os agentes máquina estão preparados para lidar com o dinamismo, adaptando as soluções a perturbações externas.
- **Auto-Otimização** - dá aos agentes a capacidade de monitorizar o seu estado e desempenho, e proativamente afinar os seus parâmetros de modo a responder às perturbações externas. Cada agente adota e providencia a auto-parametrização do algoritmo de resolução de acordo com o problema a ser tratado (os parâmetros podem mudar/adaptar-se em tempo de execução). Cada agente deve ser capaz de definir qual o algoritmo usado e os respetivos parâmetros de acordo a situação atual ou até mudar para outro algoritmo, considerando as características do problema atual (dimensão, complexidade, etc.) e aprendizagem prévia.
- **Auto-Reparação** - os agentes possuem a capacidade de diagnosticar desvios das condições normais e tomar proativamente a ação necessária para a normalizar evitando interrupções de processamento. O Sistema a desenvolver não se dedicará apenas a uma classe de problemas de escalonamento, embora seja particularmente orientado para a resolução de problemas reais.

3.3.1 Arquitetura do sistema AutoDynAgents

A arquitetura do sistema de escalonamento dinâmico colaborativo – sistema AutoDynAgents – consiste num SMA em que uma comunidade de agentes modela um sistema de fabrico real sujeito a perturbações e imponderáveis (Figura 6). Os agentes devem ser capazes de aprender e gerir o seu comportamento interno e as suas relações com outros agentes autónomos, através de negociação de acordo com as políticas de negócio definidas pelos gestores operacionais.

Considerando as características distribuídas, autónomas e de coordenação, a tecnologia dos SMA é adequada para modelar sistemas de fabrico reais, onde agentes inteligentes autónomos cooperam para resolver problemas de escalonamento. Tendo em consideração as relações

operacionais e subordinadas dos agentes no sistema proposto, é possível considerar a arquitetura híbrida baseada em modelo de mercado, com agentes híbridos.

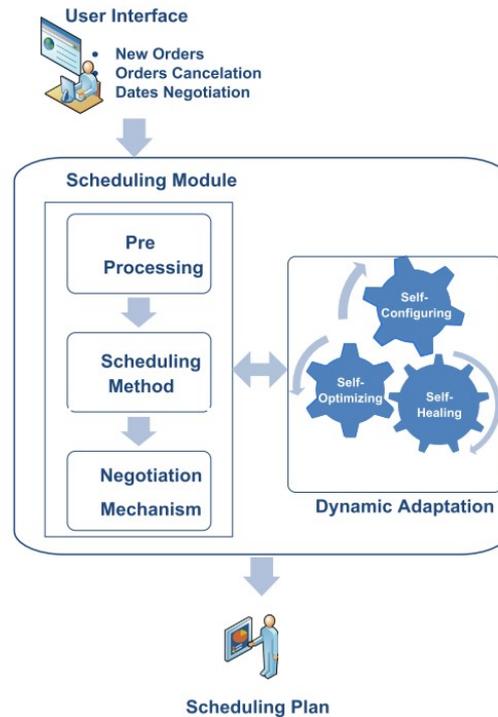


Figura 6 - Arquitetura do sistema AutoDynAgents (Madureira et al., 2014)

3.3.2 Modelo do sistema AutoDynAgents

O modelo do sistema representa os principais componentes de um processo de escalonamento dinâmico. O modelo implementado consiste num sistema Multi-Agente para simular recursos e tarefas num processo de tomada de decisão de escalonamento que envolve coordenação. No modelo proposto, há agentes que representam tarefas (*TaskAgents*) e agentes que representam máquinas/recursos (*ResourceAgents*) num ambiente de fabrico. Os *ResourceAgents* devem ser capazes de encontrar uma solução ótima ou próxima através de algoritmos **Swarm Intelligence** (ABC, ACS e PSO) para SMSP e negociar com outros agentes (Figura 7). O SMSP visa sequenciar um conjunto tarefas numa única máquina.

Além disso, o modelo proposto considera um agente coordenador (Coordenador da UI) responsável por coordenar e integrar a capacidade de recuperação de falhas. Com este agente, o sistema torna-se estável, mesmo que possam ocorrer alguns impasses ou falhas.

O modelo do sistema baseia-se em quatro tipos diferentes de agentes: o Agente coordenador da interface de utilizador (UI Coordinator), os agentes tarefa (*TaskAgent*), os agentes recurso (*ResourceAgents*) e os agentes auto-* (*Self-ConfigurationAgent*, *Self-OptimizationAgent* e o *Self-Healing Agent*).

Da análise da Figura 7, é possível verificar a interligação dos vários agentes presentes na arquitetura, com destaque para a comunicação entre os agentes do Sistema Multi-Agente. Assim, o *Self-ConfigurationAgent* deteta as alterações ao problema provenientes do ambiente externo (Interface Gráfica ou eventos aleatórios) e comunica-os ao agente de *Self-OptimizationAgent*, responsável pela definição dos parâmetros de uma Meta-heurística para a resolução do problema. Este por sua vez comunica com o agente *UICoordinator*,

responsável pela criação dos vários TaskAgents, pela coordenação das soluções locais dos ResourceAgents, e também pela comunicação da solução final ao Self-OptimizationAgent, bem como à Interface Gráfica, para a respetiva visualização.

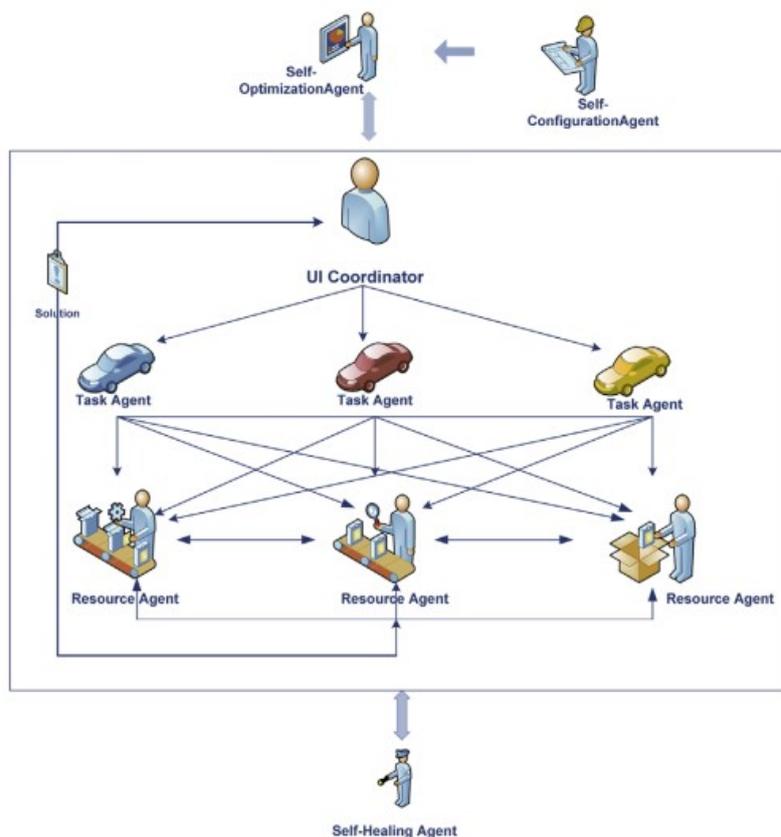


Figura 7 - Modelo do sistema AutoDynAgents (Madureira et al., 2014)

Cada TaskAgent efectua o pré-processamento da respetiva tarefa, distribui as soluções pelos vários ResourceAgents, cada um responsável por obter uma solução local para o problema de máquina única respetivo e comunicação ao agente UICoordinator. Finalmente, o agente Self-Healing Agent encontra-se ligado a todos os agentes do sistema Multi-Agente para deteção e correção de possíveis falhas.

Neste sistema, pretendeu-se tirar partido da integração das potencialidades em Sistemas Multi-Agente, Técnicas de Otimização Inspiradas na Natureza - particularmente *Swarm Intelligence*, da Aprendizagem em SMA e da Computação Autónoma.

3.3.3 Resultados

No âmbito deste projeto de I&D foram desenvolvidos trabalhos de mestrado que permitiram ainda responder a questões e oportunidades de desenvolvimento, dos quais se destaca as dissertações de mestrado concluídas:

1. BRUNO MIGUEL FERNANDES MAGALHÃES, “Auto-regulação na Gestão de Conflitos em Retalho”, no Mestrado em Engenharia Informática - Tecnologias do Conhecimento e Decisão do ISEP, no ano Letivo 2009/2010.
2. IVO ANDRÉ SOARES PEREIRA, “Aspectos de Otimização em Aprendizagem”, no Mestrado em Engenharia Informática - Tecnologias do Conhecimento e Decisão do ISEP, no ano Letivo 2008/2009.

3.4 ADSyS - Sistema de Apoio à Decisão Adaptativo e Interativo para Escalonamento com Metacognição e Modelação da Experiência do Utilizador (PTDC/EME-GIN/109956/2009)

Considerou-se que a principal contribuição deste projeto, no sentido da Tomada de Decisão Inteligente e na Resolução Híbrida de Problemas, está no esforço de integração de diferentes áreas de investigação e paradigmas, tratar problemas de otimização combinatória encontrados nos problemas de escalonamento em ambiente real de produção, tirando partido das suas vantagens e integração:

- **A resolução do Problema de Escalonamento em ambiente real de produção** é uma tarefa de difícil resolução. Os ambientes de fabrico apresentam um nível elevado de incerteza, os processos apresentam requisitos específicos e detalhados, e os objetivos de gestão são diversos, dinâmicos e por vezes conflituosos. Neste tipo de ambientes é importante a capacidade de eficaz e eficientemente, adaptar os planos a perturbações externas mantendo níveis de desempenho do negócio.
- **Métodos de Otimização Inspirados na Natureza**, referindo-se a uma classe de ferramentas poderosas na resolução de problemas complexos de otimização, produzindo de forma eficiente soluções de boa qualidade. Estas técnicas podem ser adaptadas para lidar com problemas dinâmicos, adaptando as soluções de acordo com o dinamismo.
- **Aprendizagem Observacional e Aprendizagem Ativa**, onde é possível identificar oportunidades e melhorias na aprendizagem em diferentes fases num sistema de escalonamento da produção: Eficiência na Pesquisa que adquire conhecimento para guiar o “escalonador” no espaço de pesquisa; Especificação do domínio que aprende as pré-condições e consequências das ações de planeamento; e a Qualidade que adquire conhecimento dos planos de boa qualidade.
- **Coordenação/Adaptação/Aprendizagem em Sistemas Multi-Agente (SMA)** é responsável pela eficácia, desempenho e qualidade de sistemas automáticos complexos que observam o comportamento do perito e tentam gerar e melhorar o seu conhecimento baseado na observação. Os Sistemas de Apoio à Decisão (SAD) devem adaptar-se às perturbações pela alteração da sua própria configuração, permitindo acrescentar ou remover recursos/tarefas sem interrupção do processamento.
- **Interfaces com Utilizador Inteligentes e Adaptativos (IUI)**, considerando o esforço que este deve dispendir para fornecer as entradas ao sistema e para interpretar os resultados, e quanto esforço será necessário para aprender como fazê-lo. O IUI deve deixar o utilizador incorporar alterações nos resultados e o sistema ser capaz de recolher de forma eficiente a informação e dinamicamente ajustar o seu “*layout*” e elementos às necessidades e sugestões do utilizador.

Este projeto baseou-se no pressuposto de que o desenvolvimento da nova geração de sistemas de apoio à decisão fosse conduzido pela convergência dos sistemas biológicos e dos sistemas de computação digitais no sentido dos sistemas autónomos. Considerou-se que a próxima geração de Sistemas de Apoio à Decisão está relacionada com Sistemas Multi-Agente Cooperativos e inteligentes a assumir um papel fundamental na procura ativa e na aquisição de informação relevante para os seus utilizadores em sistemas complexos e abertos como a Web. Os mecanismos inerentes a este tipo de Sistemas de Apoio à Decisão, sobretudo ao nível das suas capacidades cognitivas, de aprendizagem, e autonomia de perceção, serão baseados nos conceitos explorados e nos paradigmas identificados na Figura 8: Sistemas Multi-Agente, Técnicas de otimização,

Computação Autónoma, Técnicas de Aprendizagem Automática, a especificação de Interfaces Inteligentes e Adaptativos e a Modelação do Perfil do Utilizador.

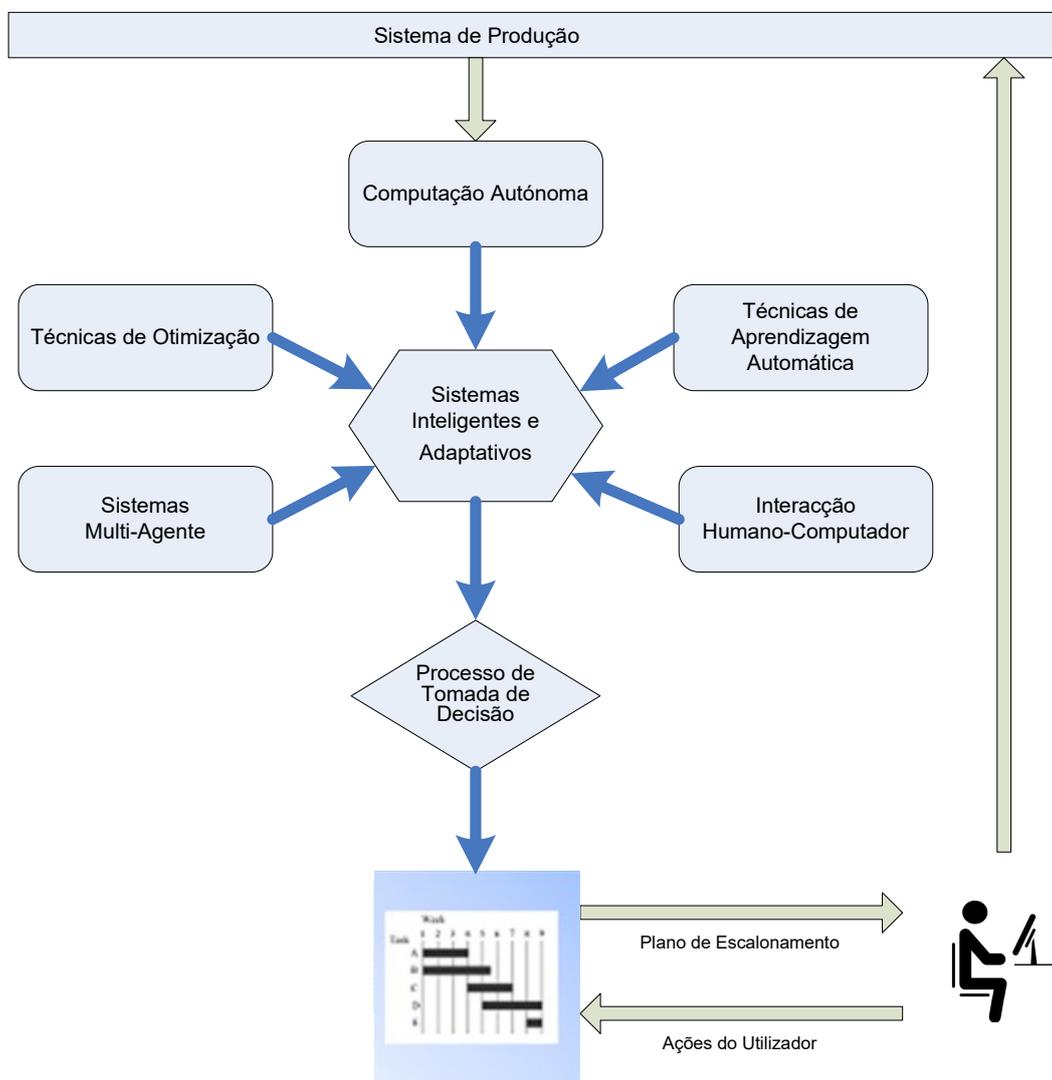


Figura 8 - Paradigmas usados no desenvolvimento do sistema inteligente e adaptativo

Da observação da natureza é possível concluir que qualquer espécie capaz de aprender por observação pode desenvolver uma cultura social. Observar a realização de uma tarefa por outro permite incrementar ou facilitar o processo de aprendizagem (aprendizagem por demonstração). Para um aprendiz humano este processo envolve a visão. O projeto ADSyS procura imitar esta aptidão das espécies, para aprender por observação e desenvolver comportamentos sociais, e incorporar metacognição e aprendizagem por observação num sistema de apoio ao escalonamento com o intuito de melhorar o desempenho global da função de escalonamento.

O projecto ADSyS (Adaptive Decision Support System for Interactive Scheduling with MetaCognition and User Modelling Experience) investiga o desenvolvimento de Sistemas Inteligentes para Escalonamento Assistido por Aprendizagem, com recurso a aprendizagem por acumulação e interpretação da experiência ou por observação das decisões do perito. Pretendeu-se que o sistema fosse dotado da capacidade de escalabilidade no sentido de adaptar/definir a sua inteligência e o utilizador possa ainda seleccionar o nível de inteligência desejado de acordo com os objetivos de negócio.

Neste projeto, pretendeu-se dar uma contribuição no sentido de ultrapassar algumas das limitações dos Sistemas de Apoio à Decisão (SAD) existentes para Problemas de Escalonamento reais através da melhoria do processo de geração e execução de planos de fabrico pela aprendizagem baseada na experiência. O sistema de escalonamento desenvolvido é dotado de:

- Interação inteligente e proativa entre o utilizador e o Sistema de Apoio à Decisão, o qual deve suportar os utilizadores no acesso, gestão, partilha e troca de informação. A interface adequa-se ao tipo e perfil de utilizador.
- Capacidade de aprendizagem ativa para aprender com o utilizador e inferir as suas intenções permitindo a inclusão de conhecimento do domínio, e a aprendizagem por observação.
- Incorporação de conhecimento nos métodos de otimização através da observação do utilizador e capacidade de adaptação que lhes permitam reagir a perturbações do ambiente exterior de forma proativa.

Neste sistema, e seguindo uma abordagem incremental, tirou-se partido da experiência e do conhecimento adquirido da equipa de investigação, em projetos de I&D anteriores, nomeadamente o MASDScheGATS e o AutoDynAgents em Técnicas de Otimização Inspiradas na Natureza, Sistemas Multi-Agente e *Autonomic Computing*. Foram rentabilizadas novas sinergias com as áreas de aprendizagem automática, Hiper-Heurísticas e Coordenação em Sistemas Multi-Agente, modelação do perfil do utilizador e particularmente a área de Interação Humano-Máquina: interação inteligente, adaptativa e colaborativa entre o utilizador e os sistemas inteligentes.

No âmbito deste projeto procedeu-se ao desenvolvimento de uma plataforma baseada em sistemas Multi-Agente e em Técnicas Inspiradas na Natureza com capacidade de autogestão e aprendizagem por observação e experiência para a resolução de problemas de escalonamento complexos e em ambiente real de produção, com recurso a negociação e cooperação. O sistema é dotado da capacidade de inteligência escalável, isto é, é capaz de autonomamente decidir que Meta-Heurística usar num dado problema de escalonamento e respetiva parametrização, como decidir perante a chegada de uma tarefa urgente que mecanismo de integração usar para a sua eficiente incorporação no plano atual, como ainda em termos de modelo de interação, sugerir/recomendar e disponibilizar informação/suporte ao utilizador de acordo com o perfil/tipo de utilizador.

O sistema incorpora uma interface centrada no utilizador. O modelo de interação proposto suporta a definição de problemas de escalonamento, a parametrização de técnicas de otimização e a visualização dos resultados. A arquitetura proposta para o componente de modelação dos utilizadores consiste em 4 elementos que colaboram para criar um ambiente inteligente. Estes elementos cooperam com o objetivo de classificar os utilizadores de acordo com a sua experiência, usando essa classificação para oferecer as ajudas e recomendações necessárias para a realização de tarefas de otimização no âmbito de um problema de escalonamento.

3.4.1 Arquitetura do sistema ADSyS

O sistema ADSyS é um sistema de escalonamento em que uma comunidade de agentes modela um sistema de fabrico real sujeito a perturbações. Os agentes têm de ser capazes de aprender e gerir o seu comportamento interno e a relação com outros agentes, ao colaborar de acordo com o objetivo estipulado.

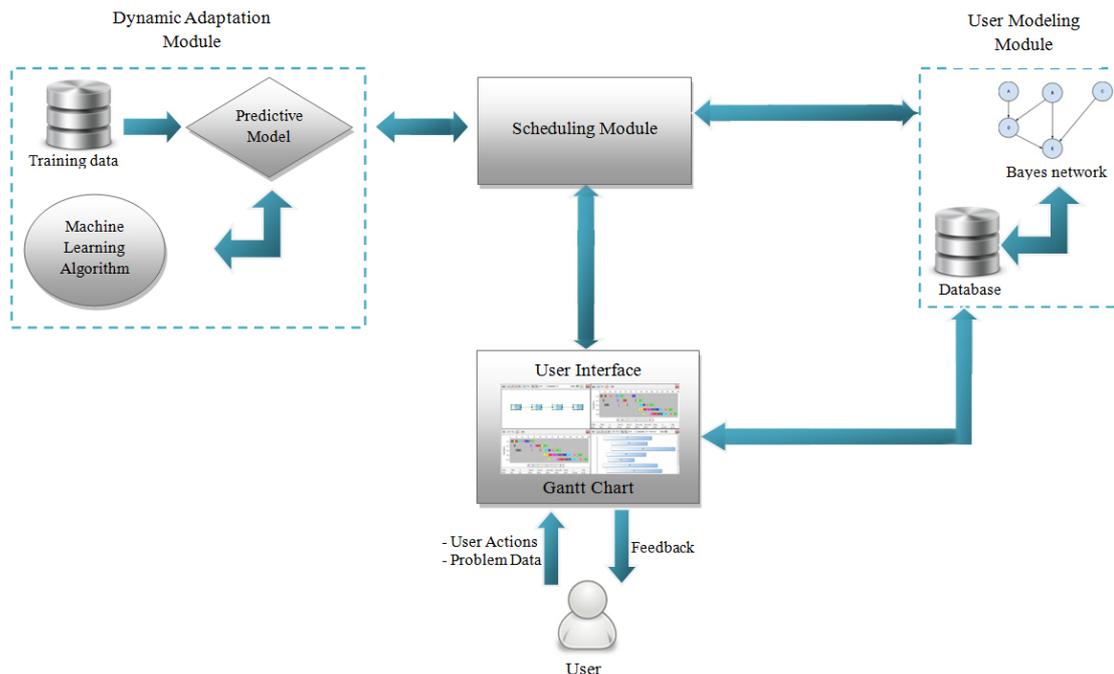


Figura 9 - Visão global do sistema ADSyS (Madureira et al., 2014)

O protótipo desenvolvido consiste em quatro módulos principais (Figura 9 e Figura 10): o Módulo da interface integrada, o módulo de escalonamento, o módulo de modelação do perfil do utilizador e o módulo de adaptação dinâmica:

- **Módulo de Escalonamento:** módulo responsável pelo processamento e otimização referentes a um determinado problema de escalonamento.
- **Módulo de *User Modelling*:** módulo responsável pela modelação do perfil de utilizadores, foi introduzido no protótipo ADSyS, com o objetivo de facilitar a curva de aprendizagem de novos utilizadores, permitindo melhorar a produtividade dos utilizadores experientes. Consiste em vários componentes que cooperam de forma a caracterizar o comportamento do utilizador e analisá-lo, utilizando a informação recolhida para proporcionar uma experiência no sistema personalizado, disponibilizando ajudas e sugestões conforme o tipo de utilizador.
- **Módulo de Adaptação Dinâmica:** módulo responsável pela incorporação dos eventos externos no plano corrente.
- **Módulo da interface integrada:** responsável pelo intercâmbio de informação entre o utilizador e o sistema de escalonamento e o Módulo de *User Modelling*.

Os módulos que fazem parte da interface (Editor de Tarefas, Editor de Problemas, Editor de Máquinas, Visualização de Resultados) são responsáveis pelo intercâmbio de informação entre o utilizador e o sistema de escalonamento:

- **Editor de Tarefas:** módulo a partir do qual o utilizador é capaz de criar uma gama operatória (tarefa) ou editar uma já existente. Uma operação é a unidade fundamental de uma tarefa, uma vez que uma tarefa é definida como um conjunto de operações.
- **Editor de Problemas:** módulo no qual o utilizador define um novo problema de escalonamento ou então edita um problema já existente. Uma tarefa é a unidade fundamental para a definição de um problema de escalonamento.

- **Editor de máquinas:** módulo no qual o utilizador define o parque de máquinas. A cada máquina é associada uma operação ou um conjunto de operações.
- **Visualização de Resultados:** módulo responsável pela visualização dos resultados produzidos pelo módulo de escalonamento. Além da visualização de resultados, este módulo permite que o utilizador introduza alterações ao plano de escalonamento de forma interativa. Estas alterações permitem ao utilizador validar cenários, uma vez que essas alterações são fornecidas ao módulo de escalonamento como informação de feedback.

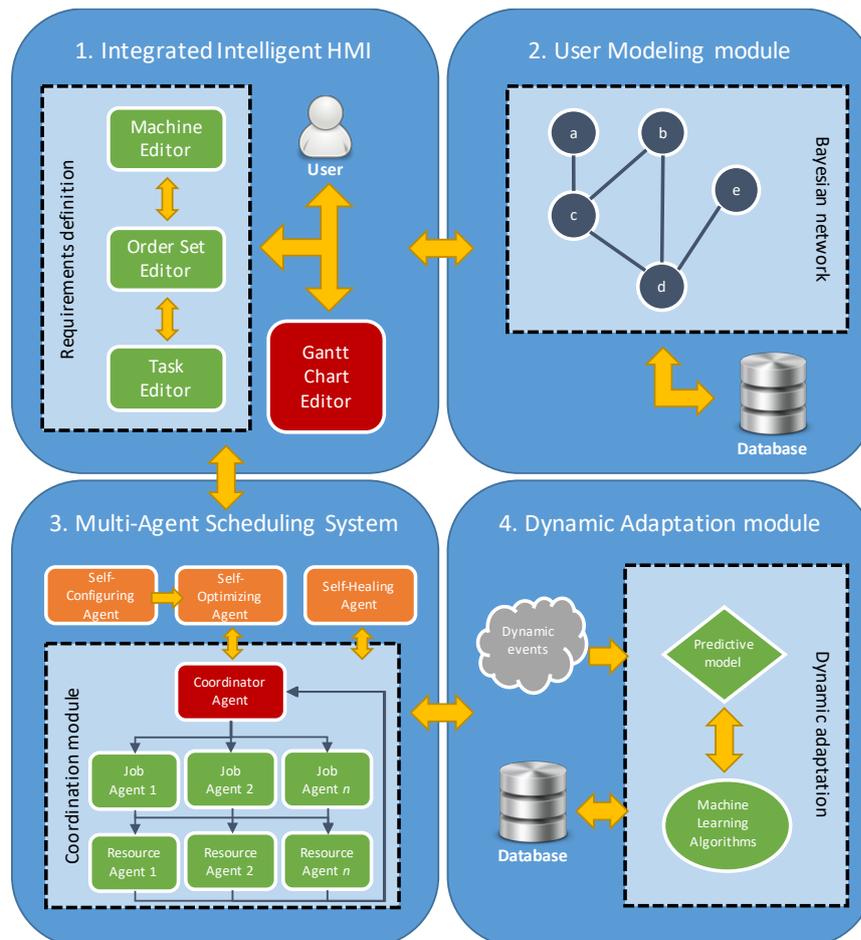


Figura 10 - Arquitetura do sistema ADSyS (Madureira et al., 2017)

A arquitetura proposta (Figura 10), é composta por agentes que representam tarefas/operações (*Task Agents*) e agentes que representam máquinas/recursos (*Resource Agents*) num ambiente industrial. O modelo proposto considera também um agente coordenador (*UI Coordinator agent*) responsável por coordenar soluções individuais obtidas por cada agente recurso, de forma a obter um escalonamento global para o problema original. A arquitetura Multi-Agente é similar à do sistema AutodynAgents (Madureira et al., 2010), sendo os agentes enriquecidos com comportamentos adicionais, nomeadamente a aprendizagem por observação e experiência.

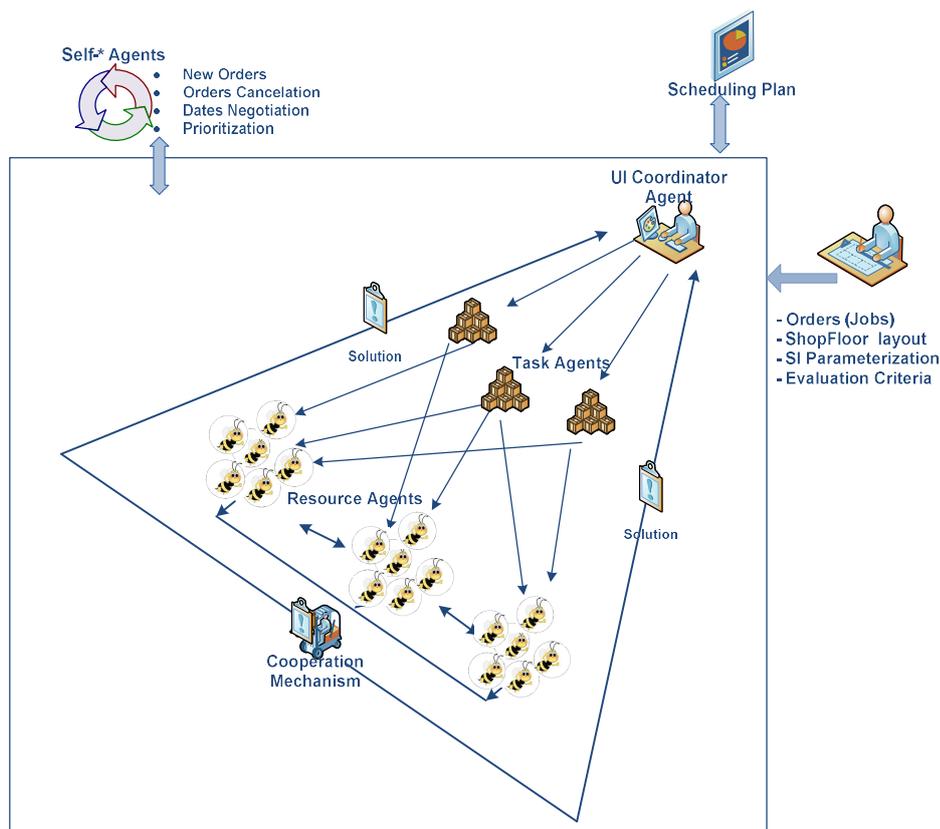


Figura 11 - Modelo do Sistema Multi-agente (Madureira et al., 2017)

A Figura 11 ilustra o modelo capaz de se auto-gerir, que possui três tipos distintos de agentes, designados de *self-* agents*: *Self-Configuration Agent*, *Self-Optimization Agent* e *Self-Healing agent*. A arquitetura Multi-agente proposta é considerada híbrida dado que combina duas ou mais abordagens num único agente, que inclui agentes colaborativos, agentes de aprendizagem colaborativos e de interface:

- **UI Coordinator Agent** - o UI Agent é responsável por uma comunicação permanente e fluída com o utilizador. Além de ser responsável pela interface, este agente gera os agentes tarefa (*Task Agents*) necessários dinamicamente, de acordo com o número de tarefas que compõem o problema de escalonamento. No final, recolhe as soluções de cada agente máquina (*Resource Agent*) e valida essas soluções num mecanismo de reparação e num mecanismo de coordenação (cooperação ou negociação).
- **Task Agents** - Os agentes tarefa (que são classificados como agentes colaborativos) processam a informação necessária acerca de cada tarefa; i.e., são responsáveis por um pré-processamento dos dados do problema de escalonamento. Isto representa a geração dos primeiros e últimos tempos de processamento e a alocação de operações aos respetivos agentes máquina.
- **Resource Agents** - Os agentes máquina (também agentes colaborativos) são responsáveis pelo escalonamento de operações que requerem processamentos na máquina que estes controlam. Implementam métodos de *Swarm Intelligence* (*Particle Swarm Optimization* e *Ant Colony Optimization*) com o objetivo de encontrar a melhor combinação do escalonamento das operações e, depois, coordenam através da cooperação/negociação para melhorar os planos.

- **Self-Configuration Agent** - Este agente é responsável pela monitorização do sistema de forma a detetar modificações que afetem o escalonamento, permitindo ao sistema a adaptação dinâmica. Este agente trabalha em conjunto com o *Self-Optimizing Agent*.
- **Self-Optimizing Agent** - Este agente (um agente de interface) é responsável pela afinação dos parâmetros das Meta-heurísticas, de acordo com o problema. O agente recebe o problema inicial (número de tarefas/máquinas, as suas rotas, operações e atributos, etc.) ou uma alteração detetada pelo agente *Self-Configuration*, e escolhe automaticamente a MH a utilizar, definindo a sua auto-parametrização. Se ocorrer algum evento dinâmico, os parâmetros podem ser alterados em tempo de execução. Esta afinação dos parâmetros é feita através de aprendizagem e experiência, dado que recorre a um módulo de CBR (raciocínio baseado em casos). De cada vez que um novo problema (caso) surge, o CBR usa experiência anterior para especificar a MH e os parâmetros a usar. Caso seja um novo caso o resolvido, este é guardado para uso futuro.
- **Self-Healing Agent** - Fornece ao sistema a capacidade de detetar desvios das condições normais e, de forma proactiva, toma medidas para normalizar, evitando interrupções do serviço. Dado que os agentes podem falhar por diversos motivos, este agente fornece um ou mais agentes de *backup* para garantir armazenamento para a reativação dos que ficaram perdidos ou encravados e possuem resultados significativos, permitindo que o sistema reinicie de um ponto prévio, e não desde o início. Com este agente, o sistema torna-se estável, capaz de lidar com qualquer problema que possa ocorrer.

Pretendeu-se demonstrar que o desenvolvimento da nova geração de sistemas de apoio à decisão pode tirar partido dos seguintes aspetos:

- Observar a realização de uma tarefa por outro permite incrementar ou facilitar o processo de aprendizagem (aprendizagem por demonstração). Para um aprendiz humano este processo envolve a visão. O sistema procura imitar esta aptidão das espécies, para aprenderem por observação e desenvolver comportamentos sociais, e incorporar metacognição e aprendizagem por observação num sistema de apoio ao escalonamento com o intuito de melhorar o desempenho global da função de escalonamento. A analogia com a visão humana é incorporada no sistema através de uma interface inteligente e interativa. Assim, combinar a inteligência humana com a inteligência computacional poderá ser uma forma eficaz de resolver o problema de escalonamento.
- A aprendizagem por observação foi concretizada pelo módulo de modelação do perfil do utilizador, que permite a classificação dos utilizadores de acordo com a sua experiência, usando essa classificação para oferecer as ajudas e recomendações necessárias para a realização do processo de otimização das tarefas de escalonamento. A interação providenciada segue uma abordagem de iniciativa mista. O objetivo da classificação dos utilizadores é adaptar o sistema (com foco na interface) ao utilizador considerando os três níveis ou perfis, desde o iniciado ao avançado. A prioridade do sistema é monitorizar e ajudar os utilizadores que estão a começar e oferecer mais possibilidades aos utilizadores já avançados. Existem dois tipos principais de ajudas: sugestões e prevenção de erros. A primeira é visível quando o utilizador está a criar ou a modificar um plano. Se estiver a criar, o sistema é capaz de perceber (usando a BD e a rede) a parametrização apropriada para o novo plano e automaticamente preenche os formulários. O segundo tipo está mais presente quando se está a modificar um plano. O sistema interpreta a ação (independente e a combinação delas) e apresenta ao utilizador uma sugestão, de acordo com o contexto. Apesar de usar mensagens não obstrutivas para interagir com o utilizador, a ajuda não está

restrita a esta forma de comunicação. Quando um plano sofre alterações há modificações automáticas feitas pelo sistema, usando a rede para inferir as mudanças apropriadas (por exemplo se um movimento proibido for planeado no diagrama, o sistema corrige automaticamente, explicando ao utilizador o motivo).

- A metacognição foi concretizada na proposta de uma hiper-heurística que tem por função decidir proativamente que mecanismo de integração usar para a integração das operações de uma tarefa urgente (dinâmica), no módulo de adaptação dinâmica.
- A aprendizagem por experiência é concretizada na capacidade de auto-parametrização das Meta-Heurísticas. Esta capacidade permite ao sistema decidir de forma proativa e autónoma que técnica de otimização deverá ser usada para a otimização de um dado problema de escalonamento e respetiva parametrização. O módulo de auto-parametrização incorpora técnicas de aprendizagem, de modo a dotar o sistema da capacidade de aprender com a experiência adquirida na resolução de casos anteriores similares.
- A coordenação dos agentes é responsável pela eficácia, desempenho e qualidade de sistemas automáticos complexos que observam o comportamento do perito e tentam gerar e melhorar o seu conhecimento baseado na observação. Com base nas técnicas Colónia de Abelhas Artificiais e Otimização de Colónia de Formigas foi validada a cooperação e a negociação entre os agentes recurso no sentido do incremento da eficácia do plano obtido.
- O sistema está dotado da capacidade de adaptação dinâmica, isto é, de se adaptar às perturbações externas pela alteração da sua configuração, permitindo acrescentar ou remover tarefas sem interrupção do processamento. Tal capacidade está suportada num módulo de aprendizagem baseado em técnicas de aprendizagem supervisionada. Permitindo ao sistema integrar as alterações de forma autónoma.

3.4.2 Resultados

No âmbito deste projeto de I&D foram desenvolvidos trabalhos de mestrado e de doutoramento que permitiram ainda responder a questões e oportunidades de desenvolvimento.

Teses de Doutoramento:

1. BRUNO MIGUEL ALMEIDA CUNHA, “Escalonamento Inteligente com Recurso a Aprendizagem por Reforço”, Doutoramento em Informática Escola de Ciências e Tecnologia da Universidade de Trás-os-Montes e Alto Douro, 2021.
2. ANDRÉ BORGES GUIMARÃES SERRA E SANTOS, “Auto-Parametrização de Meta-Heurísticas para Problemas de Escalonamento em Ambiente Industrial”, Doutoramento em Engenharia Industrial e Sistemas, Departamento de Produção e Sistemas, Universidade do Minho, 2020.
3. IVO PEREIRA, “Aprendizagem por Observação para Escalonamento Interativo”, Doutoramento em Engenharia Eletrotécnica e de Computadores da Escola de Ciências e Tecnologia da Universidade de Trás-os-Montes e Alto Douro, 2015. Este trabalho de doutoramento foi coorientado pelo Doutor Paulo Barroso de Moura Oliveira.

Dissertações de Mestrado:

1. ÂNGELA CAROLINA ANDRADE CARNEIRO MENDONÇA TAVARES, “Metodologias para a avaliação de usabilidade” no Mestrado em Engenharia Informática - Sistemas e Tecnologias Multimédia do ISEP, 2019/2020.

2. SAMUEL DOMINGUES SANTOS COSTA CARVALHO, “Heurística auxiliada por Aprendizagem Automática aplicada a problemas de Escalonamento”, no Mestrado em Engenharia Informática - Sistemas de Informação e Conhecimento do ISEP, 2016/2017.
3. MARISA DANIELA DE CAMPOS FERREIRA DA SILVA, “Análise de Performance de Técnicas de Otimização”, no Mestrado em Engenharia Informática - Sistemas de Informação e Conhecimento do ISEP, 2016/2017.
4. NELSON JOSÉ FERREIRA DA SILVA, “Análise de Desempenho de Técnicas de Otimização Swarm Intelligence”, no Mestrado em Engenharia Informática do ISEP, 2015/2016.
5. BRUNO MIGUEL ALMEIDA CUNHA, “Scalable Intelligence for Scheduling Systems”, no Mestrado em Engenharia Informática do ISEP, 2014/2015.
6. LUIS TEIXEIRA, “Simulador de sistema de fabrico em ambiente real”, no Mestrado em Engenharia Electrotécnica e de Computadores do ISEP, concluída no ano letivo 2011/2012.
7. PAULO TAVEIRA, “Edição Gráfica de Layout Fabril no Apoio ao Planeamento e Controlo da Produção”, no Mestrado em Engenharia Informática - Sistemas e Tecnologias Multimédia do ISEP, concluída no ano Letivo 2011/2012.
8. JESUS EDUARDO PIAIRO, “Interfaces com o utilizador Inteligentes e Adaptativos”, no Mestrado em Multimédia da Faculdade de Engenharia da Universidade do Porto, concluída no ano Letivo 2011/2012.

3.5 Sumário

Neste capítulo, foram descritos os contributos nesta linha de investigação, no sentido do desenvolvimento de sistemas inteligentes para a resolução de problemas de escalonamento distribuídos e dinâmicos, cada vez mais complexos. Para cada um dos projetos de I&D foram descritos os objetivos, a arquitetura e os resultados ou desenvolvimentos futuros concretizados através de dissertações de mestrado e teses de doutoramento. No projeto MASDScheGATS, os Sistemas de Produção são modelados através de um SMA, onde cada agente representa uma unidade de processamento, máquinas ou tarefas. O problema de escalonamento é decomposto numa série de problemas de máquina única (Madureira, 2003), em que cada agente máquina resolve localmente os seus problemas de escalonamento, através da aplicação de Algoritmos Genéticos ou Pesquisa Tabu, na pesquisa de soluções ótimas ou quase-ótimas. Após todos os agentes máquina terem resolvido os seus problemas locais, as suas soluções são integradas com um mecanismo de coordenação de modo a serem respeitadas as precedências das tarefas, para ser criado um plano de escalonamento global. A principal contribuição do projeto AutoDynAgents, no sentido da Tomada de Decisão Inteligente e na Resolução Híbrida de Problemas, está no esforço de integração de diferentes áreas de investigação e paradigmas desde a *Swarm Intelligence*, a Aprendizagem em SMA e a Computação Autónoma, na resolução de problemas de otimização combinatoria encontrados nos problemas de escalonamento em ambiente real de produção, tirando partido das suas vantagens e integração. A arquitetura do sistema de escalonamento dinâmico colaborativo consiste num SMA em que uma comunidade de agentes modela um sistema de fabrico real sujeito a perturbações e imponderáveis. Os agentes são capazes de aprender e gerir o seu comportamento interno e as suas relações com outros agentes autónomos, através de negociação de acordo com as políticas de negócio definidas. O sistema possui a capacidade de aprendizagem e autogestão (diagnóstico e resolução de problemas, incorporando o conceito da Computação Autónoma) para a resolução de problemas de escalonamento complexos, tendo como

principal objetivo reduzir a complexidade do processo de gestão deste tipo de sistemas e a intervenção humana.

Considera-se, ter sido dada uma contribuição para ultrapassar algumas das limitações dos Sistemas de Apoio à Decisão para o problema de escalonamento em ambiente real de produção, através da melhoria do processo de geração e execução de planos de fabrico com a aprendizagem baseada na experiência, considerando que: a interação inteligente e proactiva entre o utilizador e o SAD que permite suportar os utilizadores no acesso, na gestão, na partilha e na troca de informação; a capacidade de aprendizagem que permite ao sistema aprender com o utilizador e inferir as suas intenções; as técnicas de aprendizagem automática surgem como candidatas dado que permitem a inclusão de conhecimento do domínio e são adequadas para aprendizagem por observação; a incorporação de conhecimento nos métodos de otimização através da observação do utilizador e a capacidade de adaptação que lhes permitam reagir a perturbações do ambiente exterior. Dos resultados obtidos foi possível concluir, por um lado quanto à adequação do modelo de interação às necessidades dos utilizadores, assim como do interesse da modelação do perfil do utilizador, facultando ajudas e dando recomendações de acordo com o nível do utilizador. Por outro lado, foi possível analisar e recolher evidências da influência dos diferentes mecanismos propostos (auto-parametrização e adaptação dinâmica) no desempenho do sistema.

4. Sistemas inteligentes no Suporte à Tomada de Decisão: Que Futuro?

A constante evolução das tecnologias digitais está a transformar profundamente a economia e a sociedade, abrindo perspectivas de um mundo mais interconectado e inteligente: um mundo onde emergem novas formas de relacionamento entre as organizações e respetivos modelos de negócio, no interior das organizações, entre produtores e consumidores, e entre o homem e a máquina. O conceito de transformação digital passou a estar presente na economia e na sociedade a nível global. Neste contexto, acrescem ainda os desafios associados ao impacto da pandemia Covid-19, na economia e na sociedade a nível global. Neste capítulo, pretende-se identificar paradigmas e desafios emergentes associados ao processo de desenvolvimento de Sistemas Inteligentes em ambientes de fabrico. Será enquadrada a problemática do processo de Transformação Digital e da Indústria 4.0, identificando os principais impulsionadores da mudança: os Sistemas Cíber-Físicos, a Inteligência Artificial (IA), a *Internet das Coisas - Internet of Things* (IoT), a *Blockchain*, a Computação em Nuvem, a Realidade Virtual/Aumentada, a Cibersegurança, entre outros.

4.1 Transformação Digital

A Transformação Digital (TD) é já uma realidade bem presente no quotidiano das organizações, constituindo a base para a criação de novos modelos de negócio. A Internet transformou o modo como as organizações se relacionam com os seus clientes e utilizadores, levando ao aparecimento de novas formas de interação e de comunicação com o público-alvo. No mercado global e aberto à inovação, a transformação digital pretende a redução nos custos, a entrada mais rápida no mercado, a vantagem competitiva e a satisfação final do cliente.

A TD é normalmente entendida como a mudança associada à aplicação das tecnologias digitais a todos os aspetos da sociedade e setores de atividade. Implica uma aposta criativa e inovadora na digitalização¹ de recursos e processos. O economista alemão Schwab (2016), referia no seu livro *“The Fourth Industrial Revolution”*, estarmos perante uma revolução tecnológica que modificaria a forma como vivemos, trabalhamos e nos relacionamos - *“As mudanças são tão profundas que, na perspectiva da história da humanidade, nunca houve um momento tão potencialmente promissor ou perigoso. Numa escala de alcance e complexidade, a transformação será diferente de qualquer outra que o ser humano já experimentou antes”*.

Estamos perante uma nova era de desenvolvimento tecnológico, caracterizado pela transformação digital, comumente designada de 4ª Revolução Industrial. É certo que ainda não existe um consenso quanto à forma e dimensão do impacto, não só económico, mas também

¹ Termo também referido por virtualização ou desmaterialização.

na sociedade, mas o facto de ser referida como uma “revolução”, é indicativo do seu potencial e abrangência. As atuais transformações tecnológicas, suportadas nas tecnologias digitais móveis, na digitalização de processos e produtos e especialmente na utilização de técnicas da IA irão também produzir profundas transformações na forma como trabalhamos, produzimos, ensinamos e vivemos. Os mais otimistas defendem que o resultado final será positivo, não só para economia, mas também para a comunidade em geral que terá acesso aos benefícios de um crescimento sustentável. Os mais pessimistas argumentam que esta 4ª revolução industrial será diferente das anteriores, dado que teremos máquinas com capacidade físicas e intelectuais similares às dos humanos. Grandes desafios surgem no sentido da redução dos atuais profissionais e da necessidade da sua adaptação às novas tecnologias (Oliveira, 2019). Expressões como “Upskill” e “Reskill” surgem, no contexto atual, requerendo esforços e necessidades de formação em novas áreas do conhecimento para que as organizações consigam adaptar, os seus recursos humanos às novas necessidades e desafios.

Tem sido referida como Economia Digital, 4ª Revolução Industrial, Indústria 4.0 ou ainda a Era dos Sistemas Ciber-Físicos. Diferentes designações para uma mesma realidade: uma nova dimensão de interconectividade, de pessoas e máquinas; uma rede global, capaz de produzir uma quantidade massiva de dados, tornando visíveis padrões até agora impossíveis de processar pela mente humana; constituída por máquinas e sistemas capazes de aprender, comunicar entre si e tomar decisões (CIP, 2018).

4.2 Indústria 4.0

Neste contexto, espera-se uma transformação metodológica e tecnológica do modelo dos sistemas de produção. Na economia global e nas operações empresariais globais, testemunhámos que a Indústria 4.0 tem sido necessária para o incremento a nível global da industrialização, informatização e digitalização da produção, no sentido de uma maior eficiência e competitividade. Considerando a relevância deste tema, tem havido uma procura crescente e esforço de investigação em relação a este tópico, com o objetivo de fornecer informações sobre as questões, desafios e soluções relacionadas com a conceção, implementação e gestão de soluções para o suporte da atividade produtiva.

O paradigma da Indústria 4.0 baseia-se na interligação das máquinas, dos sistemas de produção e equipamentos, que permitirá às empresas ter a capacidade de criar redes inteligentes ao longo de toda a cadeia de valor, e assim, coordenar os processos de produção de forma independente e autónoma. Se até agora o progresso tecnológico assentou, em grande parte, na criação de novo hardware, este novo ciclo será orientado principalmente para criação de valor através de dados e do desenvolvimento de software. As tecnologias da 4ª Revolução Industrial transferem as funcionalidades da inovação em componentes mecânicas ou elétricas para o mundo digital.

O impacto da Indústria 4.0 vai para além da simples digitalização, passando por uma forma muito mais complexa de inovação baseada na combinação de múltiplas tecnologias, que forçará as empresas a repensar a forma como gerem os seus negócios e processos, como se posicionam na cadeia de valor, como planeiam o desenvolvimento de novos produtos e os introduzem no mercado, ajustando as ações de marketing e de distribuição. Torna-se necessário perceber que alterações se irão verificar em ambos os lados da cadeia de valor, tanto a nível das exigências dos clientes como dos parceiros de negócio. De acordo com Klaus Schwab (2016) são quatro as principais alterações esperadas na Indústria em geral: alterações nas expectativas dos clientes; produtos mais inteligentes e processos mais produtivos; novas formas de colaboração e parcerias; a transformação e conversão do modelo operacional em modelo digital.

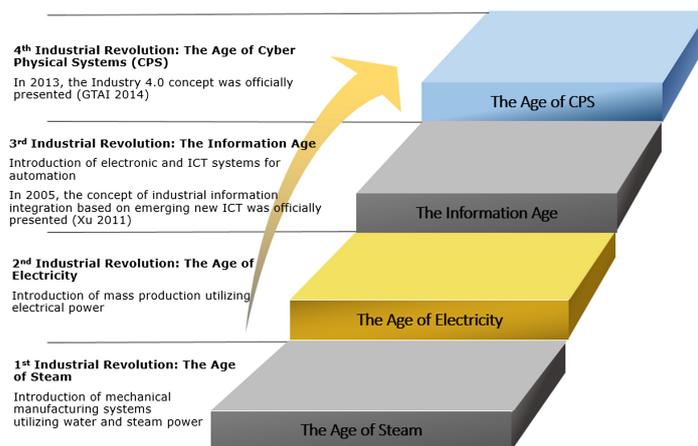


Figura 12 - A evolução até à Indústria 4.0 (Xu et al., 2018)

A Indústria 4.0 está associada a uma nova revolução (Figura 12) conhecida como a 4ª Revolução Industrial - a Era dos Sistemas Ciber-Físicos - que integra técnicas de fabrico de vanguarda com sistemas inteligentes que se interligam com as organizações e as pessoas. Mas este conceito não consiste somente em sistemas inteligentes interligados, o seu alcance é mais amplo e considera desde o sequenciamento genético até à nanotecnologia, das energias renováveis à computação quântica. A sua génese está na integração das novas tecnologias e a sua interação por meio dos domínios físicos, digitais e biológicos. É também identificado como um conceito de fabrico apoiado pela integração de uma série de tecnologias com o objetivo de criar ecossistemas de fábricas inteligentes, autónomas e descentralizadas e serviços de produtos integrados (Almada-Lobo, 2016). O impacto da Indústria 4.0 é esperado a vários níveis: na melhoria do intercâmbio de informações, permitindo a comunicação entre seres humanos, máquinas e produtos, e o acesso em tempo real à informação sobre produtos e produção; nas operações, por possuírem processos de trabalho totalmente autónomos e a integração perfeita das cadeias de valor; nos processos de inovação, através do envolvimento dos produtores e dos consumidores e da redução do tempo para a entrada no mercado.

O termo Indústria 5.0 surgiu, entretanto, como uma reação à visão da Indústria 4.0 impulsionada pelo impacto da pandemia. O foco em temas como a sustentabilidade e a resiliência, e o apelo para que as pessoas voltem a ser mais centrais, tornou-se um tema a que os decisores, políticos e organizações devem estar cada vez mais atentos (Zutshi, 2019). Este novo conceito fornece uma visão da indústria que visa além da eficiência e produtividade como os únicos objetivos, e reforça o papel e o contributo da indústria para a sociedade. Coloca o bem-estar do trabalhador no centro do processo produtivo e utiliza as novas tecnologias para proporcionar prosperidade para além do emprego e do crescimento, respeitando ao mesmo tempo os limites de produção do planeta. Complementa a atual abordagem "Indústria 4.0", colocando especificamente a investigação e a inovação ao serviço da transição para uma indústria sustentável, centrada no homem e resiliente (EC, 2021).

4.2.1 Pilares da Indústria 4.0

A indústria 4.0 está fortemente focada na melhoria contínua em termos de eficiência, segurança, produtividade das operações e especialmente no retorno do investimento. Segundo (Almada-Lobo, 2016) a transformação associada à Indústria 4.0 assenta em três pilares fundamentais:

- a digitalização da produção (sistemas de informação para a gestão e planeamento da produção).
- a automatização (sistemas de dados, linhas de produção e utilização de máquinas).

- o intercâmbio automático de dados (ligação de locais de produção permitindo a gestão global da cadeia de abastecimento).

As oportunidades da Indústria 4.0 podem ser classificadas em seis tipologias principais (Büchi et al., 2020): a flexibilidade de produção, que ocorre durante o fabrico de pequenos lotes; a velocidade dos protótipos em série; maior capacidade de produção; redução dos custos de instalação e menos erros e tempos de inatividade das máquinas; maior qualidade do produto e menor taxa de defeitos; e o maior grau de satisfação dos clientes.

4.2.2 Tecnologias de suporte à Indústria 4.0

São várias as tecnologias e tendências facilitadoras disponíveis: a Inteligência Artificial – *Big Data* e *Data Analytics*, a *Internet of Things* (IoT)/*Internet of Services* (IoS), a *Blockchain*, a Realidade Aumentada, a Robótica, a Computação Quântica, entre outras (Tabela 2).

Tabela 2 - Tecnologias de suporte à Indústria 4.0 (Büchi et al., 2020)

Tecnologias de suporte	Definição
Soluções avançadas de fabrico	Refere-se à criação de sistemas interligados e modulares que garantem planos industriais automatizados. Estas tecnologias incluem sistemas automáticos de movimentação de materiais e robótica ("cobots" - robôs colaborativos ou veículos autonomamente guiados automatizados ou veículos aéreos não tripulados).
Realidade aumentada	Envolve uma série de dispositivos que enriquece (ou diminui) a perceção sensorial humana através do acesso a ambientes virtuais; isto é acompanhado por elementos sensoriais, tais como som, cheiro ou toque. Estes elementos podem ser adicionados a dispositivos móveis (smartphones, tablets ou computadores) ou outros sensores para aumentar a visão (óculos de realidade aumentada), som (auriculares) ou toque (luvas) para fornecer informações multimédia.
Internet of Things	Corresponde a um conjunto de dispositivos e sensores inteligentes que facilitam a comunicação entre pessoas, produtos e máquinas.
BigData Analytics	Refere-se às tecnologias que recolhem, armazenam, analisam e divulgam grandes quantidades de dados derivados dos produtos, processos, máquinas e pessoas interligadas numa empresa, bem como o ambiente que a rodeia.
Cloud Computing	Facilita o armazenamento e processamento de grandes quantidades de dados com elevado desempenho em termos de velocidade, flexibilidade e eficiência. A computação em nuvem também resulta num maior número de serviços desenvolvidos com base em dados para um sistema produtivo – incluindo funções de monitorização e controlo – para garantir a qualidade e melhorar as operações e a produção.
Cibersegurança	Inclui medidas de segurança destinadas a proteger o fluxo de informação sobre os sistemas corporativos interligados.
Fabrico aditivo	Permite, para produtos complexos, a criação de camadas de materiais, incluindo diferentes tipos de materiais como plásticos, cerâmica, metais e resinas, eliminando assim a necessidade de montagem do material (impressão 3D).
Simulação	Envolve reproduzir o mundo físico em modelos virtuais e permitir que os operadores testem e otimizem as configurações para obter materiais, processos produtivos (elementos discretos) e produtos (elementos acabados ou distintos).
Integração horizontal e vertical	A integração oferecida pela Indústria 4.0 caracteriza-se por duas dimensões: interna versus externa. A integração horizontal diz respeito à integração e intercâmbio de informações entre as diferentes áreas da empresa. A integração vertical diz respeito às relações da empresa com os seus fornecedores e clientes.
Outras tecnologias	Incluem várias tecnologias usadas para áreas específicas, como o agroalimentar e a economia biológica, entre outras. Inclui as ferramentas para determinar onde, quando e como os recursos energéticos são usados com o objetivo de eliminar ou reduzir os resíduos/desperdícios.

A Deloitte (Gravenhorst, 2020) realizou um estudo para analisar quais as tecnologias que os gestores empresariais antecipam ter maior impacto nas suas organizações rumo à visão Indústria 4.0. Da análise da Figura 13, é possível constatar que as tecnologias identificadas com

maior impacto: *Internet of Things* que liga os mundos digital e físico através da recolha, medição e análise de dados para prever e automatizar processos de negócio. É identificada como a tecnologia que se espera ter o impacto mais profundo nas organizações; tecnologias da inteligência artificial, que executam e/ou aumentam tarefas que tradicionalmente requerem inteligência humana; Computação em Nuvem (*Cloud Computing*) e *Big data/analytics*. Estas tecnologias de base trabalham em conjunto para interligar as organizações, gerar dados e impulsionar operações mais inteligentes. Alguns autores referem a existência de uma forte correlação e dependência entre várias tecnologias da Indústria 4.0.

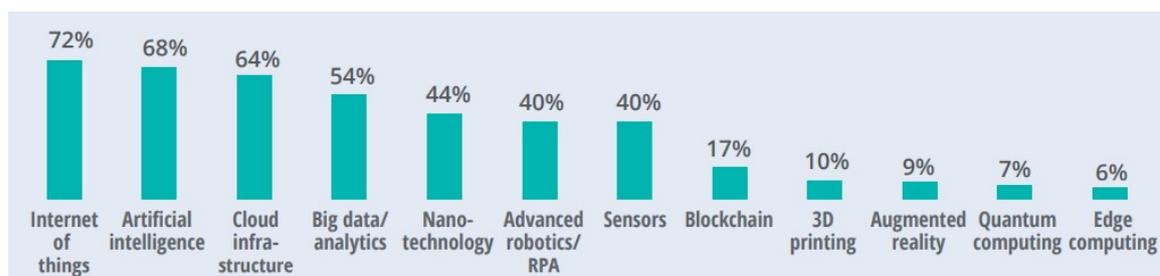


Figura 13 - As tecnologias com impacto na indústria 4.0 (Gravenhorst, 2020)

4.3 Sistemas Ciber-físicos

Os sistemas Ciber-Físicos (“*Cyber-Physical systems*” - CPS) correspondem a uma nova geração de sistemas inteligentes que integram a computação e os processos físicos interagindo com os seres humanos de diferentes formas (Al-Ali et al., 2018). Redes integradas de computadores, sensores e tecnologias similares monitorizam e controlam os processos físicos, reportando dados relevantes aos planeadores e decisores, e vice-versa. Os sistemas CPS utilizam componentes eletrónicos, em muitas circunstâncias invisíveis, mas acessíveis através da utilização de produtos ou equipamentos inovadores. Os sistemas embutidos desempenham um papel relevante: incorporam inteligência nos objetos, dispositivos e outros equipamentos. Com o desenvolvimento da banda larga de alta velocidade e a Internet das Coisas, os CPS, incorporaram um número muito significativo de dispositivos ligados ao mundo físico capazes de trocar dados entre si, aceder a serviços da web e interagir com as pessoas (Dujin et al., 2014). As componentes individuais dos diferentes dispositivos interagem mutuamente, aumentando significativamente a sua complexidade. Em geral, caracterizam-se por duas componentes funcionais principais: a conectividade avançada que garante a aquisição de dados em tempo real a partir do mundo físico e o feedback de informação do espaço cibernético; e a gestão inteligente de dados, análise e capacidade computacional que suporta o espaço cibernético (Letichevsky, 2017).

Os sistemas Ciber-Físicos (CPS) são de natureza computacional e colaborativa, e têm a capacidade de possuir uma conectividade intensa com o mundo físico circundante. Estes dispositivos físicos são construídos com sensores incorporados, software, conectividade de rede, bem como capacidades computacionais, e podem ser aplicados numa gama de áreas industriais e comerciais, desde dispositivos e veículos até eletrodomésticos e *wearables* (Barros et al., 2017).

Estas capacidades são fornecidas através da Internet das Coisas (IoT) e da Internet do Serviço (IoS), permitindo o acesso remoto, serviços inteligentes e *BigData Analytics* online e em tempo real. Por outro lado, a IoT é composta por recolhas autónomas, intercâmbios e ações sobre dados relativos a uma rede de dispositivos físicos inteligentes.

No que diz respeito à conceção, e desenvolvimento de um CPS, os desafios fundamentais referem-se ao estabelecimento de uma interoperabilidade eficaz, à normalização das práticas operacionais e de fabrico, à modelação e reconfiguração em tempo real, bem como à adequada implementação de um elevado nível de ciber-segurança. A IoT enfrenta diferentes desafios, que estão principalmente relacionados com a grande quantidade de dados disponíveis e processados utilizando esta tecnologia, como a gestão eficiente de dados, a mineração de dados, os níveis de privacidade, a ciber-segurança, e o problema com o ciclo de inovação e evolução enfrentado pelas tecnologias relacionadas com a IoT.

4.4 IoT e tecnologias relacionadas

O termo Internet das Coisas “*Internet of Things (IoT)*” refere-se a objetos físicos e virtuais ligados à internet. Tem sido impulsionada pelo aparecimento e uso generalizado de sensores cada vez mais pequenos e baratos, assim como o desenvolvimento nos dispositivos móveis, comunicações *wireless* e tecnologias *cloud*. A nova abordagem por *Internet of Services (IoS)*, é a evolução natural da *Internet of Things*. A conectividade e a interação das coisas criando serviços de valor perceptível para o cliente é um dos fatores mais relevantes, abrindo um mundo de oportunidades e desafios. Os principais desafios relacionados com a tecnologia referem-se a: segurança; privacidade; interoperabilidade e standards; regulamentar, legal e direitos; e economias emergentes e em desenvolvimento (Rose et al., 2015).

4.5 Blockchain

A tecnologia Blockchain permite o registo distribuído que visa a descentralização como medida de segurança (Schueffel et al., 2019). São bases de registos e dados distribuídos e partilhados que têm a função de criar um índice global para todas as transações que ocorrem num determinado mercado, público, partilhado e universal, que cria consenso e confiança na comunicação direta entre duas partes, sem a intermediação de terceiros. Tem o potencial de revolucionar a forma como partilhamos informações e realizamos transações *online*.

Foram desenvolvidas algumas iniciativas legais e regulamentares no âmbito da estratégia da Comissão Europeia para suportar a aplicação da tecnologia Blockchain na Europa que inclua os valores e ideais europeus (ECBS, 2021), particularmente:

- Sustentabilidade ambiental: deve ser sustentável e eficiente em termos energéticos.
- Proteção de dados: deve ser compatível com as regras de proteção de dados e privacidade da Europa.
- Identidade Digital: deve respeitar e melhorar o quadro de identidade digital em evolução da Europa. Isto inclui ser compatível com os regulamentos de assinatura eletrónica, e apoiar um quadro de identidade sensato, pragmático descentralizado e auto-soberano.
- Ciber-segurança: deve ser capaz de fornecer altos níveis de ciber-segurança.
- Interoperabilidade: As *blockchains* devem ser interoperáveis entre si e com sistemas antigos no mundo exterior.

4.6 Inteligência Artificial

Com o aparecimento dos computadores surgiu uma questão importante, quer do ponto vista filosófico quer do ponto vista prático: poderá um computador comportar-se um dia de forma inteligente, exibindo um comportamento semelhante ao de um ser humano? Esta questão

mereceu já a atenção de muitos cientistas, engenheiros e filósofos. A ideia de que a tecnologia poderia, um dia, vir a replicar o pensamento lógico humano foi preconizada por Alan Turing em 1950, em que formulou a questão “Poderão as máquinas pensar?” (Turing, 1950). O termo Inteligência Artificial foi proposto pela comunidade científica, numa conferência em Dartmouth, nos EUA em 1956. Desde então diversas definições e desenvolvimentos têm sido propostos na literatura.

A inteligência artificial (IA) é considerada como um subcampo das ciências da computação focada na resolução de tarefas em que os seres humanos são bons (por exemplo, linguagem natural, reconhecimento de imagem). A IA, através da qual os computadores são programados para imitar comportamentos inteligentes de aprendizagem para encontrar soluções para os problemas, está presente na maioria dos aspetos das nossas vidas e setores de atividade.

Os sistemas inteligentes são sistemas de software (e eventualmente também de hardware) concebidos por seres humanos que, tendo recebido um objetivo complexo, atuam na dimensão física ou digital percebendo o seu ambiente mediante a aquisição de dados, interpretando os dados estruturados ou não estruturados recolhidos, raciocinando sobre o conhecimento ou processando as informações resultantes desses dados e decidindo as melhores ações a adotar para atingir o objetivo estabelecido. Os sistemas de IA podem utilizar regras simbólicas ou aprender um modelo numérico, bem como adaptar o seu comportamento mediante a análise do modo como o ambiente foi afetado pelas suas ações anteriores.

Enquanto disciplina científica, a IA inclui diversas abordagens e técnicas (EC-Ethics, 2019) tais como: a Aprendizagem Automática (“*Machine Learning*”- ML) de que a aprendizagem profunda (“*Deep Learning*”) e a aprendizagem por reforço (“*Reinforcement Learning*”) são exemplos específicos); o raciocínio automático que inclui o planeamento, a programação, a representação do conhecimento e o raciocínio, a pesquisa e a otimização; e a robótica que inclui o controlo, a perceção, os sensores e atuadores, bem como a integração outras técnicas em CPS.

Desde a sua proposta, na década de 50, a IA evoluiu de um campo académico para um poderoso motor de mudança social, tecnológica e económica. A IA é agora a base para uma vasta gama de tecnologias, incluindo a pesquisa web, as aplicações de *smartphones*, o diagnóstico médico, o reconhecimento de voz e, mais recentemente, os veículos autónomos.

O termo Inteligência Aumentada ou Amplificada (“*Augmented Intelligence*”), surge como uma visão da IA relativa à diferença entre sistemas que desenvolvem, melhoram e escalam a experiência humana, e aqueles que tentam replicar a inteligência humana. A capacidade dos sistemas de IA de transformar grandes quantidades de informação complexa e ambígua em conhecimento tem o potencial de revelar segredos de longa data e ajudar a resolver alguns dos problemas mais duradouros do mundo. Os sistemas de IA podem potencialmente ser usados para ajudar a descobrir conhecimento para o tratamento e diagnóstico de doenças, prever a meteorologia e gerir a economia global. A Inteligência Aumentada é uma conceptualização alternativa do termo Inteligência Artificial que se foca no papel de assistência da IA na melhoria das capacidades humanas e não na sua substituição (Carlsson et al., 2018).

Várias definições e desenvolvimentos têm sido propostos na literatura, mas é consensual que o principal objetivo da IA está em dotar os sistemas e componentes de características inspiradas na inteligência humana (EC-AI, 2018). Neste contexto têm surgido desenvolvimentos, contribuições, consideradas por alguns como subáreas da IA: *Machine Learning/Deep Learning* (Alpaydin, 2004; Mitchell, 1997; Bishop, 2006; Goodfellow et al.,

2016), *Industrial AI* (Gupta and Farahat, 2020), *Generalized AI* (Wang et al., 2007), *Safety AI* (Yampolskiy, 2018), (Gheraibiaet al., 2021) (Banavar, 2016), entre outras.

A IA é uma ferramenta inegavelmente poderosa. E como todas as ferramentas poderosas, deve ser tido grande cuidado no seu desenvolvimento e implementação. Vários esforços têm sido desenvolvidos no sentido da regulamentação de aspetos relacionados com a cibersegurança e a ética da IA. Os desenvolvimentos no campo da IA indiciam a necessidade de se considerar a Segurança como um princípio de design e não opcional. Recentemente o IEEE lançou a norma **IEEE 7000™-2021- IEEE Standard Model Process for Addressing Ethical Concerns During System Design** que fornece uma metodologia para analisar valores, éticos e sociais a ter em consideração no processo de desenvolvimento de sistemas inteligentes, minimizando o risco e fortalecendo as relações com os seus utilizadores finais e clientes (IEEE-SASB, 2021). A Comissão Europeia tem também realizado esforços nesta área, do qual se destaca a publicação do documento “Ethics Guidelines for Trustworthy AI” (EC-Ethics, 2019) que propõe orientações éticas para uma IA de confiança. A nível nacional, com o lançamento do documento “A Estratégia Nacional para a Inteligência Artificial - AI Portugal 2030”, pretende-se explorar as diferentes potencialidades da IA na economia e na sociedade, bem como a sua aplicação em áreas como as redes de energia sustentável, cidades, florestas e oceanos, mobilidade, condução autónoma ou saúde (AI-PT, 2019).

4.6.1 Machine Learning

Os humanos, e os animais em geral, reagem ao seu ambiente e realizam diferentes ações em resposta aos estímulos que recebem. Considera-se, geralmente, um sinal de inteligência se um determinado sujeito responde às alterações que ocorrem ao longo do tempo e se tornam mais eficazes. A aprendizagem é um fator fundamental da inteligência humana assim como da Inteligência Artificial. A Aprendizagem Automática estuda algoritmos de aprendizagem, os quais especificam como as alterações no comportamento do aprendiz depende dos estímulos recebidos e do *feedback* do ambiente. Dependendo deste *feedback*, é possível identificar três categorias de Aprendizagem Automática, que se distinguem pelo tipo de informação tratada, tal como referido na literatura (Alpaydin, 2004; Mitchell, 1997; Bishop, 2006): **Aprendizagem Supervisionada** (emprega dados rotulados); **Aprendizagem Não-Supervisionada** (utiliza dados não rotulados); e **Aprendizagem por Reforço** (com o objetivo de maximizar uma recompensa).

A Aprendizagem Profunda é uma forma de aprendizagem automática que permite aos computadores aprender com a experiência e compreender o mundo em termos de uma hierarquia de conceitos (Goodfellow et al., 2016). A DL refere-se a uma subárea da Aprendizagem Automática, com um subconjunto particular de modelos que apresentam um bom desempenho em certas tarefas, tais como o reconhecimento de imagem e o processamento de linguagem natural.

4.6.2 Industrial AI

Em 2015, o *AlphaGo* — suportado por Aprendizagem Automática — tornou-se o primeiro jogo de computador a vencer um jogador profissional de *Go* (considerado um dos jogos de estratégia mais complexos da atualidade). O *AlphaGo* é considerado um marco no processo de evolução da IA, sugerindo que a IA poderia superar o desempenho humano. O entusiasmo (ou o receio) gerado no sentido de que estas tecnologias poderiam substituir a maioria dos empregos humanos, acabou por se dissipar. Surgem muitos desafios no recurso à IA a aplicações no mundo real, onde estas não são tão claramente definidas como as peças, pretas ou brancas, no tabuleiro do jogo *Go*. O ambiente industrial, é mais complexo, o comportamento humano e as operações das máquinas são envolvidas em processos físicos,

químicos ou biológicos em equipamentos mecânicos, elétricos e eletrônicos. Surgem desafios específicos nas aplicações industriais, tanto a partir da perspectiva dos algoritmos como dos dados (Gupta e Farahat, 2020).

O termo IA Industrial (“*Industrial AI*”) surgiu do interesse em enquadrar a aplicação da Inteligência Artificial, particularmente as técnicas de Aprendizagem Automática e tecnologias relacionadas na resolução de problemas do mundo real em domínios industriais. Estes problemas podem ser amplamente categorizados nas áreas horizontais de manutenção e reparação, operações e cadeia de abastecimento, qualidade, segurança, design e otimização - com aplicações numa variedade de áreas verticais. Nos últimos anos, temos assistido a um interesse crescente na aplicação de técnicas de *Deep Learning* a problemas industriais, que vão desde a utilização de modelos de sequência como Memória de Longo e Curto Prazo (*Long Short-Term Memory - LSTM*) para prever falhas no equipamento, até ao recurso de *Deep Reinforcement Learning* (Deep RL) para escalonamento e despacho (Gupta e Farahat, 2020).

A IA Industrial (IAI) é uma disciplina sistemática que se centra no desenvolvimento, validação e desenvolvimento de abordagens baseadas em ML para aplicações industriais com desempenho sustentável. A implementação bem-sucedida da tecnologia pode melhorar significativamente a agilidade, a resiliência e a fiabilidade dos sistemas de fabrico e solidificar o percurso no sentido da Indústria 4.0. A IAI incorpora procedimentos padronizados de processamento de dados que oferece soluções consistentes e fiáveis para aplicações industriais. Explora a convergência da deteção em tempo real, da aprendizagem automática, das infraestruturas cibernéticas avançadas e das ferramentas de suporte à tomada de decisão para melhorar a agilidade, a resiliência e a fiabilidade dos sistemas de fabrico e dos ativos industriais. A implementação da IAI permite a partilha segura de dados entre fabricantes, monitorização remota e operações, gestão de ativos geograficamente distribuídos, entre outros (Gupta e Farahat, 2020).

A sistematização e a normalização são as principais razões pelas quais a IAI é mais fiável e consistente do que a IA tradicional. A sistematização da tecnologia é criada através do estabelecimento de uma abordagem unificada com protocolos normalizados para regular o desenvolvimento de modelos, considerando coletivamente a relação entre dados, modelo e tarefa. Esta abordagem fornece respostas claras a questões fundamentais como (Lee, 2020a): *Dada uma tarefa específica, qual é o plano ideal para gerar e recolher dados de um sistema industrial? Tendo em conta um conjunto de dados de treino, qual é o melhor algoritmo para construir um modelo? Tendo em conta um modelo treinado, que dados adicionais trarão a melhoria mais significativa para o modelo?*

Para além dos protocolos padrão para o desenvolvimento de modelos, a IAI engloba também a normalização da aquisição de dados, a construção de modelos, mecanismos tolerantes a falhas e procedimentos operacionais baseados na previsão, entre outros. Sem sistematização e normalização na IAI, os algoritmos desenvolvidos no domínio geral da IA podem ter um fraco desempenho quando aplicados diretamente aos sistemas industriais.

Combinada com as abordagens de deteção, comunicação e *Big Data analytics* de última geração, uma metodologia sistemática de IAI permitirá a integração de sistemas físicos com modelos computacionais. O conceito de IAI pressupõe o uso coletivo de tecnologias como a Internet das Coisas, os Sistemas Ciber-Físicos e *Big Data Analytics*, no âmbito da iniciativa Indústria 4.0, onde dispositivos informáticos incorporados, objetos inteligentes e o ambiente físico interagem entre si para atingir os objetivos pretendidos. Uma vasta gama de indústrias, poderá aproveitar o poder da IAI na obtenção de informações sobre a relação invisível das condições de operação e utilizá-la para otimizar o seu tempo, a produtividade e a eficiência das suas operações. Em termos de manutenção preditiva, a IAI pode detetar alterações

incipientes no sistema e prever os tempos de vida útil e ainda otimizar tarefas de manutenção para evitar perturbações nas operações (Lee, 2020b).

Ao traduzir dados sensoriais em tempo real para a saúde do equipamento através da utilização de algoritmos de IA, a análise preditiva pode ser alavancada para fornecer informações, por exemplo, sobre o desempenho do equipamento futuro e estimar o tempo restante antes da falha. Este conhecimento permitirá aos fabricantes decidir o intervalo de tempo ideal para planear as atividades de manutenção para que o tempo de paragem inesperado seja evitado e a produtividade não seja afetada - manutenção preditiva.

4.6.3 Safe AI

Investigadores e profissionais de IA e Segurança são confrontados com diferentes níveis de segurança, diferentes padrões e valores éticos, e diferentes graus de responsabilidade, que os obrigam a examinar uma multiplicidade de compromissos e soluções alternativas. Estas escolhas só podem ser analisadas de forma holística se as perspetivas tecnológicas e éticas estiverem integradas no problema da engenharia, ao mesmo tempo que se consideram os desafios teóricos como os desafios práticos da segurança da IA (Yampolsky, 2018), (Banavar, 2016). Neste contexto, surgiu uma nova e abrangente visão da IA - AI Safe ou AI Safety - deve abranger uma vasta gama de paradigmas de IA, incluindo sistemas específicos da aplicação, bem como aqueles que são mais gerais, considerando riscos potencialmente inesperados (Yampolsky, 2018), (Gheraibia et al., 2019).

O cenário no qual os sistemas baseados na IA tomarão decisões importantes e críticas de forma autónoma, exige por um lado transparência (a capacidade de explicar as decisões) e a auditabilidade (a capacidade de traçar o fluxo de decisões e ações do ser humano para o algoritmo) a fim de promover princípios de segurança e ética, incluindo a proteção da privacidade e a equidade, mas também prevenir o uso indevido de técnicas avançadas de IA. A adequação do quadro jurídico para determinar a responsabilidade em conflitos com o envolvimento da tomada de decisões da IA torna-se uma área de intervenção importante e para a qual a comunidade científica, mas também a política se deve orientar (AI-PT, 2019) para fazer face aos desafios sociais trazidos pela IA.

O termo **IA de Confiança** (*“Trustworthy AI”*) diz respeito não só à fiabilidade do próprio sistema de IA, mas também à fiabilidade de todos os processos e intervenientes que fazem parte do ciclo de vida do sistema. Uma IA de confiança tem três componentes (EC-Ethics, 2019): deve ser **Legal**, garantindo o respeito de toda a legislação e regulamentação aplicáveis; deve ser **Ética**, demonstrando respeito e garantindo a observância de princípios e valores éticos; e deve ser **Sólida**, tanto do ponto de vista técnico como do ponto de vista social, uma vez que, mesmo com boas intenções, os sistemas de IA podem causar danos não intencionais.

4.6.4 Generalized AI

A **IA generalizada** (*“Generalized AI”*), ou **Inteligência Artificial Generalizada (IAG)**, refere-se a uma forma teórica de IA que replica funções humanas, tais como raciocínio, planeamento e resolução de problemas. Normalmente, um sistema informático pode aprender a executar bem uma tarefa, mas não pode aplicar a mesma aprendizagem a outras funções da mesma forma que os humanos (Wang et al., 2007).

A IAG, por vezes referida como IA forte, é descrita na literatura como uma forma teórica de IA usada para descrever um modelo mental do desenvolvimento da IA, isto é, corresponde a uma visão da IA que visa criar máquinas inteligentes, com conhecimentos abrangentes e

capacidades de computação cognitiva, em que o seu desempenho não se distingue do de um ser humano.

Atualmente, tendo por base a literatura, o termo **Inteligência Artificial Generalizada** é considerado um conceito teórico. Enquanto alguns cientistas, como Marvin Minsky², foram citados como demasiado otimistas no que seria possível conseguir em algumas décadas no campo da IA; outros referem que os sistemas de IAG fortes não podem ser desenvolvidos. Neste contexto, o teste de Turing³ é ainda considerado a base do processo de avaliação da inteligência de um sistema.

4.7 Sumário

A evolução das tecnologias digitais está a transformar profundamente a economia e a sociedade, abrindo perspetivas de um mundo onde emergem novas formas de relacionamento entre as organizações e respetivos modelos de negócio, no interior das organizações, entre produtores e consumidores, e entre o homem e a máquina. O conceito de Transformação Digital passou a estar presente na economia e na sociedade a nível global. A inteligência artificial deixou de ser ficção científica, fazendo parte do nosso quotidiano. Da utilização de assistentes pessoais virtuais na organização das nossas agendas, passando pelos telemóveis que nos sugerem músicas e restaurantes de que poderemos gostar ou percursos alternativos para fugir ao trânsito, a IA é uma realidade. O cenário atual da Indústria 4.0 - onde se processa a evolução de uma indústria tradicional para uma indústria inteligente - baseia-se na integração de diferentes tecnologias digitais, novos materiais e novos processos.

Neste capítulo, foi realizada uma sistematização, não exaustiva, dos principais paradigmas emergentes, associados ao processo de desenvolvimento de Sistemas Inteligentes em ambientes de fabrico. Foi enquadrada a problemática do processo de Transformação Digital da Indústria 4.0, identificando os principais impulsionadores da mudança. Foram ainda, identificados os desafios para o futuro dos Sistemas Inteligentes, Adaptativos e Resilientes e identificados tópicos/áreas de investigação com impacto no processo de Tomada de Decisão a nível global.

² Marvin Minsky (1927-2016) - cientista cognitivo norte-americano, cuja principal área de atuação foi centrada nos estudos cognitivos no campo da inteligência artificial.

³ Também conhecido por Jogo da Imitação (Turing, 1950), avalia o desempenho de uma máquina em relação ao ser humano através de uma sequência de perguntas. A tarefa do interrogador é distinguir entre o ser humano e o computador com base em questões, que pode colocar a ambos através, por exemplo, de um terminal. Se o interrogador não distinguir se a resposta é dada pela máquina ou pelo ser humano então a máquina é dita ser inteligente.

5. Considerações Finais

Os desafios associados à Transformação Digital e Indústria 4.0 são fatores responsáveis pelo fomento da investigação e desenvolvimento de novas abordagens para a resolução dos problemas de planeamento e escalonamento em sistemas de produção. A necessidade do reforço em termos de competitividade contribui também, para o esforço de investigação na área de desenvolvimento de sistemas de escalonamento, motivados pelo acesso crescente e facilitado a sistemas inteligentes, adaptativos e resilientes.

Neste seminário, pretendeu-se descrever a linha de investigação seguida pela candidata na área de Sistemas Inteligentes e Adaptativos no Suporte à Tomada de Decisão. Para cada um dos projetos de I&D foram descritos os objetivos, a arquitetura e os resultados ou desenvolvimentos concretizados através de dissertações de mestrado e teses de doutoramento. Dos resultados obtidos foi possível concluir, por um lado: quanto à flexibilidade, robustez e eficiência das MH no processo de otimização e geração dos planos de escalonamento; quanto à adequação do modelo de interação às necessidades dos utilizadores, assim como do interesse da modelação do perfil do utilizador, facultando ajudas e dando recomendações de acordo com o nível do utilizador. Por outro lado, foi possível também analisar e recolher evidências da influência dos diferentes mecanismos propostos (auto-parametrização e adaptação dinâmica), no desempenho das MH. Assim, considera-se ter sido dada uma contribuição, para ultrapassar algumas das limitações dos Sistemas de Apoio à Decisão para o problema de escalonamento em ambiente real de produção, através da melhoria do processo de geração e execução de planos de fabrico pela aprendizagem baseada na experiência, considerando: a interação inteligente e proactiva entre o utilizador e o SAD permite suportar os utilizadores no acesso, na gestão, na partilha e na troca de informação; a capacidade de aprendizagem permite ao sistema aprender com o utilizador e inferir as suas intenções. As técnicas de aprendizagem automática surgem como candidatas naturais à implementação dos diferentes módulos dotados de aprendizagem e autonomia dado que permitem: a inclusão de conhecimento do domínio e são adequadas para aprendizagem por observação; a incorporação de conhecimento nos métodos de otimização através da observação do utilizador e a capacidade de adaptação que lhes permitam reagir a perturbações do ambiente exterior.

À medida que o rápido desenvolvimento das tecnologias digitais e o uso de informação nos processos produtivos induzem mudanças estruturais na economia (produção, distribuição e serviços), são também geradas novas tendências através da transformação digital e da adoção de novas tecnologias.

A Economia Digital está longe de se cingir a um novo paradigma económico. Integra todos os aspetos da sociedade, desde a forma como as pessoas comunicam, às competências necessárias para arranjar um bom emprego, passando pelos avanços tecnológicos e científicos e aos processos de tomada de decisões.

Considerações Finais

Neste seminário, foi enquadrada a problemática do processo de Transformação Digital e da Indústria 4.0, e identificados os principais impulsionadores da mudança. Foram ainda, identificados os desafios para o futuro dos Sistemas Inteligentes e Adaptativos e resilientes e identificados tópicos/áreas de investigação com potencial impacto no processo de tomada de decisão a nível global.

Referências Bibliográficas

AI-PT (2019), Estratégia Nacional para a Inteligência Artificial - “AI Portugal 2030”, retirado em 01-06-2021 de <https://www.incode2030.gov.pt/en/ai-portugal-2030>.

Al-Ali, A. R., Gupta, Ragini and Nabulsi, Ahmad Al (2018), Cyber physical systems role in manufacturing technologies, AIP Conference Proceedings 1957, <https://doi.org/10.1063/1.5034337>, April 2018.

Almada-Lobo, F. (2016), The Industry 4.0 Revolution and the Future of Manufacturing Execution Systems (MES), Journal of Innovation Management, 3(4), pp 16-21.

Alpaydin, E. (2004), Introduction to Machine Learning (Adaptive Computation and Machine Learning), The MIT Press, Cambridge, USA.

Baker, K.R., (1974), Introduction to sequencing and scheduling, Wiley, New York.

Banavar, Guruduth (2016), Learning to trust artificial intelligence systems Accountability, compliance and ethics in the age of smart machines, IBM Global Services.

Barros, A.C., Simões, A.C., Toscano, C., Marques, A., Rodrigues, J.C. and Azevedo A. (2017), Implementing Cyber-Physical Systems in Manufacturing, CIE47 Proceedings, 11-13 October 2017, Lisbon, Portugal.

Bishop, Christopher (2006), Pattern Recognition and Machine Learning, Springer.

Bonabeau E, Dorigo M, Theraulaz G., Swarm intelligence: from natural to artificial systems: OUP USA, 1999.

Büchi, Giacomo, Cugno, Monica, Castagnoli, Rebecca (2020), Smart factory performance and Industry 4.0, Technological Forecasting and Social Change, Vol. 150, 119790, <https://doi.org/10.1016/j.techfore.2019.119790>.

Carlsson, Kjell, Sridharan, Srividya, Gownder J. P., e Vale, Jeremy (2018), Augmented Intelligence Unlocks The Intelligence In AI, The Best Way To Leverage Artificial Intelligence Is To Combine Its Superhuman Abilities With The Super-AI Abilities Of Humans, Report, Forrester, retirado em 05-06-2021 de <https://www.forrester.com/blogs/augmented-intelligence-is-the-key-to-driving-rapid-business-value-with-ai/>.

Cerny, V., A thermodynamical approach to the travelling salesman problem: an efficient simulation algorithm, Journal of Optimization Theory and Applications, 45:41-51, 1985.

CIP (2018), “A economia do futuro é hoje”, Economia Digital, Indústria - Revista de Empresários e Negócios, N.º 115, março 2018.

Conway, R. W., Maxwell, W. L., e Miller, L. W., (1967), Theory of scheduling, Addison-Wesley Publishing Company.

Dorigo, M., Maniezzo, V. and Coloni, A., Positive Feedback as a Search Strategy. Technical Report No. 91-016, Politecnico di Milano, Italy, 1991.

Dorigo, Marco, Swarm Intelligence, Springer New York, 2007.

Eberhart, R. C. e Kennedy, J., A new optimizer using particle swarm theory, Proceedings of the Sixth International Symposium on Micromachine and Human Science, Nagoya, Japan. pp. 39-43, 1995.

EC (2021), Industry 5.0 - Towards a sustainable, human-centric and resilient European industry, EC Report, Research and Innovation, January 2021, retirado em 15-06-2021 de: https://ec.europa.eu/info/research-and-innovation/research-area/industrial-research-and-innovation/industry-50_pt.

EC-AI (2018), Artificial Intelligence for Europe, Communication from the Commission to the European Parliament, The European Council, The Council, The European Economic and Social Committee and the Committee of the Regions, retirado em 10-06-2021 de [https://ec.europa.eu/transparency/documents-register/detail?ref=COM\(2018\)237&lang=en](https://ec.europa.eu/transparency/documents-register/detail?ref=COM(2018)237&lang=en).

ECBS (2021), Blockchain Strategy - Shaping Europe's digital future, retirado em 12-06-2021 de <https://digital-strategy.ec.europa.eu/en/policies/blockchain-strategy>.

EC-Ethics (2019), Ethics Guidelines for Trustworthy AI, High-Level Expert Group on Artificial Intelligence, European Commission, retirado em 10-06-2021 de <https://ec.europa.eu/futurium/en/ai-alliance-consultation.1.html>.

Engelbrecht, Andries P., Computational Intelligence: An Introduction, 2ª edição, Wiley, 2007.

French, S., (1982), Sequencing and Scheduling: An introduction to the Mathematics of the Job Shop, Ellis Horwood, Chichester.

Gheraibia, Youcef, Kabir, Sohag Aslansefat, Koorosh, Sorokos, Ioannis and Papadopoulos, Yiannis (2019), Safety + AI: A Novel Approach to Update Safety Models Using Artificial Intelligence, IEEE Access, vol.7, pp.35855-135869, IEEE, DOI:10.1109/ACCESS.2019.2941566.

Glover, F. (1989), Tabu Search: Part I. ORSA Journal of Computing, 1:190206.

Gonzalez, Teofilo F. (2008), Handbook of Approximation Algorithms and Metaheuristics, Chapman & Hall/CRC.

Goodfellow, Ian, and Aaron, Yoshua Bengio (2016), Courville Deep Learning, MIT Press.

Gravenhorst, Jeff (2020), Technology: Leaders continue to retreat from disruption, The Fourth Industrial Revolution survey 2020 - At the intersection of readiness and responsibility, Deloitte insights.

Gupta, Chetan, Farahat, Ahmed (2020), Deep Learning for Industrial AI: Challenges, New Methods and Best Practices, KDD '20: Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, ACM, pp.3571–3572, <https://doi.org/10.1145/3394486.3406482>.

Holland, J. H. (1975), Adaptation in Natural and Artificial Systems, University of Michigan Press, Ann Arbor.

Horn, Paul (2001), Autonomic Computing: IBM's Perspective on the State of Information Technology, IBM.

IEEE-SASB (2021), IEEE 7000™-2021, Standard, Addressing Ethical Concerns During Systems Design, IEEE SA Standard Board, junho 2021.

Karaboga, D. (2005), An idea based on honey bee swarm for numerical optimization, Technical Report TR06, Erciyes University, Engineering Faculty, Computer Engineering Department.

Krishnanand, K. N., & Ghose, D. (2005), Detection of multiple source locations using a glowworm metaphor with applications to collective robotics, In Proceedings of IEEE swarm

- intelligence symposium, pp. 84–91, Piscataway: IEEE Press.
- Krishnanand, K.N. and Ghose, D. (2009), Glowworm swarm optimisation: a new method for optimizing multimodal functions. *Int. J. Computational Intelligence Studies*, vol.1, no.1, pp.93-119.
- Kulkarni, Anand J., Siarry, Patrick (2021), *Handbook of AI-based Metaheuristics*, 1st Edition, CRC Press, Taylor & Francis Group.
- Lee, Jay (2020a), *Introduction to Industrial Artificial Intelligence*, Automation & Robots, 2020.
- Lee, Jay (2020b), *Industrial AI - Applications with Sustainable Performance*, Springer Singapore, DOI:10.1007/978-981-15-2144-7.
- Letichevsky, A. A., Letychevskiy, O. O., Skobelev, V. G. & Volkov, V. A. (2017), *Cyber-Physical Systems, Cybernetics and Systems Analysis*, vol.53, Springer, pp.821–834.
- Madureira, Ana M. (2003), *Aplicação de Meta-Heurísticas ao Problema de Escalonamento em Ambiente Dinâmico de Produção Discreta*, Tese de Doutorado, Universidade do Minho.
- Madureira, Ana M., (1995), *Aplicações de Meta-Heurísticas em problemas de sequenciamento*, Dissertação de Mestrado, FEUP.
- Madureira, Ana, Pereira, I., Pereira, P., Abraham, A. (2014), Negotiation mechanism for self-organized scheduling system with collective intelligence, *Neurocomputing*, Volume 132, pp. 97–110, Elsevier, DOI: <https://doi.org/10.1016/j.neucom.2013.10.032>.
- Madureira, Ana, Pereira, Ivo, Cunha, Bruno (2017), “Specification of an Architecture for Self-organizing Scheduling Systems”, In: Madureira A., Abraham A., Gamboa D., Novais P. (eds) *Intelligent Systems Design and Applications. ISDA 2016. Advances in Intelligent Systems and Computing*, vol 557. Springer, Cham, ISBN 978-3-319-53479-4, pp.771-780, DOI: https://doi.org/10.1007/978-3-319-53480-0_76.
- Madureira, Ana, Santos, Joaquim, Pereira, Ivo (2009a), MASDSheGATS – Scheduling System for Dynamic Manufacturing Environments, *MultiAgent Systems*, S. Ahmed, M. N. Karsity (eds) In-Tech, ISBN: 978 3 902613-51-6.
- Madureira, Ana, Santos, Joaquim, Pereira, Ivo (2009b), *Hybrid Intelligent System For Distributed Dynamic Scheduling*, published in the series *Natural Intelligence for Scheduling, Planning and Packing Problems*, Series: *Studies in Computational Intelligence*, Vol. 250, Chiong, R.; Dhakal, S. (Eds.) Springer-Verlag ISBN: 978-3-642-04038-2.
- Mirjalili, S., Mirjalili, S.M. and Lewis, A. (2014), Grey Wolf Optimizer, *Advances in Engineering Software*, 69, 46-61, <http://dx.doi.org/10.1016/j.advengsoft.2013.12.007>.
- Mitchell, Tom (1997), *Machine Learning*, McGraw Hill.
- Monostori, L. (2014), Cyber-physical production systems: Roots, expectations and R&D challenges, *Procedia CIRP*, 17, 9–13.
- Moscato, P., (1989), *On Evolution, search, Optimization, Genetic Algorithms and Martial Arts – Towards Memetic Algorithms*, Caltech Concurrent Computation Program, C3P Report 826.
- Oliveira, Arlindo (2019), *Inteligência Artificial, Ensaio FFMS*, Fundação Francisco Manuel dos Santos, ISBN: 9789898943316.
- Pham, D. T., Ghanbarzadeh, A., Koc, E., Otri, S., Rahim, S. & Zaidi, M. (2005), *Technical Report MEC 0501-The Bees Algorithm*, Manufacturing Engineering Centre, Cardiff University.
- Pinedo, Michael, *Scheduling: Theory, Algorithms, and Systems*, 5ª edição, Springer Science+Business Media, LLC, 2016.

- Pirlot, M., (1996), General Local Search Methods, European Journal of Operational Research, vol. 92, pp.493-511.
- Rose, Karen, Eldridge, Scott, e Chapi, Lyman (2015), The Internet of Things (IoT): An Overview, Understanding the Issues and Challenges of a More Connected World, The Internet Society (ISOC), retirado em 05-06-2021 de <https://www.internetsociety.org/wp-content/uploads/2017/08/ISOC-IoT-Overview-20151221-en.pdf>.
- Schueffel, Patrick, Groeneweg, Nikolaj, Baldegger, Rico (2019), The Crypto Encyclopedia Coins, Tokens and Digital Assets from A to Z, School of Management Fribourg (HEG-FR), GROUT Publisher.
- Schwab, K. (2016), Historical contexto - The Fourth Industrial Revolution, WEF, 2016.
- Shah, Pritesh, Sekhar, Ravi, Kulkarni, Anand J., Siarry, Patrick (2021), Metaheuristic Algorithms in Industry 4.0, 1ªedição, CRC Press, Taylor & Francis Group, DOI: <https://doi.org/10.1201/9781003143505>.
- Siarry, Patrick e Michalewicz, Zbigniew, Advances in Metaheuristics for Hard Optimization, Springer, 2008.
- Talbi, El-Ghazali, Metaheuristics: From Design to Implementation, ISBN, Wiley, 2009.
- Turing, A.M. (1950), Computing Machinery and Intelligence Mind, 59, pp.433-460.
- Wang, Pei, Goertzel, Ben (2007), Introduction: Aspects of Artificial General Intelligence, Advances in Artificial General Intelligence: Concepts, Architectures and Algorithms, Proceedings of the AGI Workshop 2006. pp. 1–16. ISBN 978-1-58603-758-1.
- WEF (2020), The Future of Jobs Report 2020, World Economic Forum, October 2020.
- Xu, Li Da, Xu, Eric L. & Li, Ling (2018), Industry 4.0: state of the art and future trends, International Journal of Production Research, 56:8, 2941-2962, DOI: 10.1080/00207543.2018.1444806.
- Yampolskiy, Roman V. (2018), Artificial Intelligence Safety and Security, 1st Edition Chapman and Hall/CRC, New York, DOI:<https://doi.org/10.1201/9781351251389>.
- Yang, X. S. and Gandomi, A. H. (2012), Bat algorithm: a novel approach for global engineering optimization, Engineering Computations, 29(5):464-483.
- Yang, X. S. (2010), A New Metaheuristic Bat-Inspired Algorithm, In: González J.R., Pelta D.A., Cruz C., Terrazas G., Krasnogor N. (eds), Nature Inspired Cooperative Strategies for Optimization (NICSO 2010), Studies in Computational Intelligence, vol 284, pp.65-74 Springer, Berlin, Heidelberg, https://doi.org/10.1007/978-3-642-12538-6_6.
- Yang, X.S. and Deb, S. (2009), Cuckoo search via Lévy flights, Proceedings of World Congress on Nature & Biologically Inspired Computing (NaBIC 2009, India, IEEE Publications, USA, pp.210–214.
- Zutshi, Aroop (2019), 5IR: The Emergence of an Experience-Driven Manufacturing Economy. Future is Digital, Smart, Flexible and Intuitive, retirado em 15-06-2021 de <https://www.frost.com/frost-perspectives/industry-5-0-bringing-empowered-humans-back-to-the-shop-floor/>.