



# Redes Neurais Artificiais na Otimização do Processo de Digestão Anaeróbia - Aplicação a uma ETAR da AdCL

MÁRIO DE JESUS MOURA FERNANDES

Outubro de 2015

*Instituto Superior de Engenharia do Porto*

*Mestrado em Engenharia Civil*

# **Redes Neurais Artificiais na Otimização do Processo de Digestão Anaeróbia - Aplicação a uma ETAR da AdCL**

**Mário de Jesus Moura Fernandes – 1070270**

Relatório de Estágio submetido para satisfação parcial dos requisitos do grau de Mestre em  
**Engenharia Civil — Ramo de Infraestruturas**

**Empresa:** Noraqua, Consultores de Engenharia, Lda.

**Orientador:** Professor Jaime Gabriel Silva

**Supervisor:** Engenheiro Pedro Leite Ferreira



**Porto**

**Outubro de 2015**





## ÍNDICE GERAL

Índice Geral .....	iii
Resumo .....	v
Abstract .....	vii
Agradecimentos .....	ix
Índice de Texto .....	xi
Índice de Figuras.....	xiii
Índice de Tabelas .....	xv
Abreviaturas.....	xvii
1 Introdução.....	1
2 NORAQUA, Consultores de Engenharia, Lda.....	5
3 ETAR em Estudo.....	7
4 Digestão Anaeróbia.....	17
5 Redes Neurais Artificiais.....	46
6 Apresentação do caso em estudo .....	66
7 Considerações Finais .....	88
Referências Bibliográficas .....	92
Anexos .....	96
Índice de anexos.....	96



## RESUMO

Numa sociedade com elevado consumo energético, a dependência de combustíveis fósseis em evidente diminuição de disponibilidades é um tema cada vez mais preocupante, assim como a poluição atmosférica resultante da sua utilização. Existe, portanto, uma necessidade crescente de recorrer a energias renováveis e promover a otimização e utilização de recursos.

A digestão anaeróbia (DA) de lamas é um processo de estabilização de lamas utilizado nas Estações de Tratamento de Águas Residuais (ETAR) e tem, como produtos finais, a lama digerida e o biogás.

Maioritariamente constituído por gás metano, o biogás pode ser utilizado como fonte de energia, reduzindo, deste modo, a dependência energética da ETAR e a emissão de gases com efeito de estufa para a atmosfera. A otimização do processo de DA das lamas é essencial para o aumento da produção de biogás.

No presente relatório de estágio, as Redes Neurais Artificiais (RNA) foram aplicadas ao processo de DA de lamas de ETAR. As RNA são modelos simplificados inspirados no funcionamento das células neuronais humanas e que adquirem conhecimento através da experiência. Quando a RNA é criada e treinada, produz valores de *output* aproximadamente corretos para os *inputs* fornecidos. Uma vez que as DA são um processo bastante complexo, a sua otimização apresenta diversas dificuldades. Foi esse o motivo para recorrer a RNA na otimização da produção de biogás nos digestores das ETAR de Espinho e de Ílhavo da AdCL, utilizando o *software* NeuralTools™ da Palisade™, contribuindo, desta forma, para a compreensão do processo e do impacto de algumas variáveis na produção de biogás.

**PALAVRAS-CHAVE:** Estações de Tratamento de Águas Residuais, Digestão Anaeróbia, Biogás, Redes Neurais Artificiais.



## **ABSTRACT**

In a society with high energy consumption, the dependency on fossil energy which is continuously decreasing is a growing problem, as well as the air pollution resulting from their use. So, there is an increasing need for renewable energies and to promote the optimization and resources utilization.

Anaerobic digestion (AD) of sludge is a sludge stabilization process used in wastewater treatment plants (WWTP) and it has, as final products, digested sludge and biogas.

Mostly made of methane gas, the biogas can be used as an energy source, thereby reducing WWTP's energy dependence and emission of gases with greenhouse effect to the atmosphere. The AD sludge's optimization process is essential to increase biogas production.

In this internship report, Artificial Neural Networks (ANN) were applied to the sludge's AD of WWTP. ANN are simplified models inspired by the functioning of human neuronal cells and acquire knowledge through experience. When ANN is created and trained, it produces approximately correct output values for the provided inputs. As AD is a very complex process, it constitutes an obstacle to its optimization. This was the reason for resorting to ANN in the optimization of biogas production in the AdCL's WWTP Digester of Espinho and Ílhavo using the Palisade's™ NeuralTools™ software, thereby contributing to the comprehension of the process and the impact of some variables in biogas production.

**KEYWORDS:** Wastewater Treatment, Anaerobic Digestion, Biogas, Artificial Neural Networks.



## **AGRADECIMENTOS**

Terminado o meu percurso no Mestrado em Engenharia Civil – Ramo de Infraestruturas com a conclusão deste Relatório de Estágio, gostaria de agradecer a todos os que contribuíram para a sua realização:

Ao Eng<sup>o</sup> Luís Valente, pela confiança que depositou em mim, e também aos restantes elementos da Noraqua pela simpatia, hospitalidade e um excelente ambiente que me proporcionaram ao longo do semestre.

Ao orientador, Professor Jaime Gabriel Silva, pela partilha da ideia de um tema bastante interessante, pelo apoio prestado e motivação que forneceu ao longo do semestre.

Ao supervisor, Eng<sup>o</sup> Pedro Leite, pela sólida orientação e disponibilidade para esclarecer as dúvidas que lhe foram colocadas.

Um agradecimento especial ao Eng<sup>o</sup> Milton Fontes e à Eng<sup>a</sup> Alexandra Silva, pelo imenso tempo dispensado no fornecimento dos dados e na interpretação dos resultados obtidos.

Ao Professor Jorge Fernandes dos Santos do Departamento de Matemática do ISEP, pela ajuda fornecida na compreensão do processo de Redes Neurais Artificiais.

À minha família, amigos e colegas de curso pela força que me deram nos momentos mais complicados.

Um agradecimento exclusivo à namorada, por tudo, sobretudo paciência. Um verdadeiro pilar.



## ÍNDICE DE TEXTO

<b>1</b>	<b>Introdução.....</b>	<b>1</b>
1.1	Âmbito do Relatório de Estágio .....	1
1.2	Enquadramento geral do tema.....	2
1.3	Objetivos.....	4
<b>2</b>	<b>NORAQUA, Consultores de Engenharia, Lda.....</b>	<b>5</b>
<b>3</b>	<b>ETAR em Estudo.....</b>	<b>7</b>
3.1	ETAR de Espinho .....	7
3.2	ETAR de Ílhavo .....	13
<b>4</b>	<b>Digestão Anaeróbia.....</b>	<b>17</b>
4.1	Fases do Processo Anaeróbio .....	17
4.2	Vantagens e desvantagens da digestão anaeróbia .....	22
4.3	Fatores que interferem no processo de Digestão Anaeróbia.....	23
4.4	Fatores que prejudicam o processo de Digestão Anaeróbia .....	33
4.5	Principais modelos de digestão .....	37
4.6	Digestores anaeróbios .....	41
<b>5</b>	<b>Redes Neurais Artificiais.....</b>	<b>46</b>
5.1	Modelo Biológico .....	48
5.2	Características e descrição da RNA.....	50
5.3	Estrutura de uma RNA .....	50
5.4	Aprendizagem (treino).....	53

Redes Neurais Artificiais na Otimização do Processo de Digestão Anaeróbia - Aplicação a uma ETAR da AdCL

5.5	Percepção.....	55
5.6	Tipos de RNA.....	58
5.7	Fases da RNA para a resolução de problemas de previsão .....	62
5.8	Motivos da aplicação das RNA.....	64
<b>6</b>	<b>Apresentação do caso em estudo.....</b>	<b>66</b>
6.1	Recolha dos dados .....	67
6.2	Preparação e Tratamento dos dados.....	68
6.3	Resultado do processo de tratamento de dados.....	71
6.4	Abordagem ao <i>Software</i> de RNA .....	74
<b>7</b>	<b>Considerações Finais .....</b>	<b>88</b>
7.1	Conclusões .....	88
7.2	Desenvolvimentos futuros.....	90
	<b>Referências Bibliográficas.....</b>	<b>92</b>

## ÍNDICE DE FIGURAS

<b>Figura 1</b> - Vista aérea da ETAR de Espinho (Fonte: Bing Maps) .....	7
<b>Figura 2</b> - Diagrama Funcional da ETAR de Espinho.....	10
<b>Figura 3</b> - ETAR de Ílhavo da AdCL. (Fonte: AdCL, 2013; citado por Rocha, 2013) .....	14
<b>Figura 4</b> - Diagrama Funcional da ETAR de Ílhavo. (Fonte: AdCL, 2013; citado por Rocha, 2013) .....	16
<b>Figura 5</b> - Sequência de processos na digestão anaeróbia de macromoléculas complexas (os números referem-se a percentagens expressas como CQO) (Fonte: Van Haandel & Lettinga, 1994) .....	18
<b>Figura 6</b> - Taxa de crescimento das bactérias metanogénicas psicrófilas, mesófilas e termófilas (adaptado de Wiegand, 1990; citado por Mendes, 2014) .....	25
<b>Figura 7</b> - Relação entre o pH e a concentração de bicarbonato, a uma temperatura de 35°C (adaptado de U.S. EPA, 1979; citado por Mendes, 2014).....	27
<b>Figura 8</b> - Influência da temperatura e do tempo de retenção na eficiência de digestão anaeróbia de lamas primárias (adaptado de O'Rourke, 1968; citado por Mendes, 2014).....	30
<b>Figura 9</b> - Tipos de agitação dos digestores (a) recirculação bombeada externa, (b) agitação mecânica interna e (c) recirculação externa de biogás. (Fonte: Appels <i>et al.</i> , 2008) .....	31
<b>Figura 10</b> - Digestão anaeróbia em baixa carga (Fonte: Turovskiy & Mathai, 2006).....	38
<b>Figura 11</b> - Digestão anaeróbia em alta carga (Fonte: Turovskiy & Mathai, 2006) .....	40
<b>Figura 12</b> - Digestão anaeróbia em duas fases (Fonte: Turovskiy & Mathai, 2006) .....	41
<b>Figura 13</b> - Modelos de reatores anaeróbios de matéria em suspensão mais comuns (Fonte:CCE, 2000; citado por Mendes, 2014).....	43
<b>Figura 14</b> - Modelos de reatores anaeróbios de matéria fixa mais comuns (Fonte: CCE, 2000; citado por Mendes, 2014).....	44
<b>Figura 15</b> - Tipos de digestores anaeróbios descontínuos (Fonte: Vandevivere <i>et al.</i> , 2001; citado por Crespo, 2013) .....	45
<b>Figura 16</b> - Rede Neuronal Biológica (Fonte: Greenspine.ca, 2015) .....	47
<b>Figura 17</b> - Rede Neuronal Artificial (Fonte: Codeproject.com, 2012).....	47

<b>Figura 18</b> – Esquema representativo de um neurónio biológico (Fonte: Sobiologia.com.br, 2015) ....	48
<b>Figura 19</b> - Modelo de um nó de uma RNA (Fonte: Matos, 2008) .....	51
<b>Figura 20</b> - Exemplo de uma rede multicamada (Fonte: Lillesand <i>et al.</i> , 2002).....	52
<b>Figura 21</b> - Representação esquemática de um perceptrão (Fonte: Silva, 2013) .....	55
<b>Figura 22</b> - Esquema de uma rede PMC de 3 camadas. (Fonte: Silva, 2013) .....	56
<b>Figura 23</b> - Classificação estrutural e funcional de redes neurais artificiais (Fonte: Rauber, 2005; citado por Fernandes, 2014) .....	59
<b>Figura 24</b> - Exemplo de gráfico dos valores de pH da ETAR de Espinho .....	69
<b>Figura 25</b> - Distribuição de uma amostra .....	70

## ÍNDICE DE TABELAS

<b>Tabela 1</b> - Dados de Projeto (Fonte: AdCL, 2013; citado por Rocha, 2013).....	13
<b>Tabela 2</b> - Regimes de temperatura do processo de digestão anaeróbia (Fonte: Tchobanoglous & Burton, 1991) .....	24
<b>Tabela 3</b> - Valores de pH ótimos em diversos grupos de bactérias intervenientes no processo de digestão anaeróbia (Fonte: Di Berardino, 2006).....	26
<b>Tabela 4</b> - Composição típica de células bacterianas (adaptado de Tchobanoglous <i>et al.</i> , 2003) .....	28
<b>Tabela 5</b> - Condições operacionais das várias configurações de reatores anaeróbios (Mara & Horan, 2003) .....	45



## **ABREVIATURAS**

AdCL – Águas de Centro Litoral

AdP – Águas de Portugal

AGV – Ácidos Gordos Voláteis

CBO - Carência bioquímica de oxigénio

CMV – Carga Mássica Volúmica

CQO – Carência Química de Oxigénio

DA – Digestão Anaeróbia

EMQ – Erro Médio Quadrático

ETAR – Estação de Tratamento de Águas Residuais

GRNN – Generalized Regression Neural Network

MLFNN – MultiLayer Feed-forward Neural Network

MS – Matéria Sólida

MV – Matéria Volátil

PMC – Perceptrão Multicamadas

PNN – Probabilistic Neural Network

RNA – Redes Neurais Artificiais

TRH – Tempo de Retenção Hidráulica



# 1 INTRODUÇÃO

## 1.1 ÂMBITO DO RELATÓRIO DE ESTÁGIO

O presente relatório apresenta o trabalho realizado no âmbito da disciplina de DIPRE – Dissertação/Projeto/ Estágio, através de um Estágio Curricular realizado em ambiente empresarial, do Ramo de Infraestruturas incluído no Mestrado em Engenharia Civil (MEC), do Instituto Superior de Engenharia do Porto (ISEP).

O estágio decorreu na empresa Noraqua, Consultores de Engenharia, Lda. no Porto, durante o 2º semestre do 2º ano do mestrado com o tema: “Redes Neurais Artificiais na Otimização do Processo de Digestão Anaeróbia – Aplicação a uma ETAR da AdCL” e com desenvolvimento nas ETAR de Espinho e de Ílhavo da empresa Águas do Centro Litoral (AdCL).

A proposta do tema tem em vista dar continuidade a uma abordagem que tem vindo a ser realizada, em dois estágios semelhantes realizados nos dois anos letivos anteriores, de aplicação de redes neuronais artificiais na otimização do processo de digestão anaeróbia (DA) de Estações de Tratamento de Águas Residuais (ETAR) da AdCL, empresa do Grupo Águas de Portugal (AdP) que acolheu, nesses anos, estagiários do MEC.

Este ano, o estágio teve lugar na Noraqua, empresa que tem prestado serviços de engenharia ao Grupo AdP e nomeadamente à sua participada AdCL, pelo que o trabalho foi desenvolvido através do envolvimento entre essas duas empresas com vista a otimizar a Digestão Anaeróbia de mais uma das ETAR da AdCL.

Hélder Rocha (2013) e Joana Brandão (2014) foram os alunos que anteriormente abordaram este tema, desenvolvendo-o nas ETAR de Ílhavo e ETAR de Cacia, respetivamente. Os bons resultados alcançados nestes estágios foram motivo para as empresas Noraqua e AdCL entenderem, como adequado, seguir a mesma experiência de aplicação da metodologia anteriormente usada, desta vez

na ETAR de Espinho, localizada na freguesia de Paramos e, mais tarde, repetidamente na ETAR de Ílhavo, assunto este que irá ser abordado mais pormenorizadamente nos capítulos seguintes.

Para o desenvolvimento dos cálculos do presente trabalho, foram utilizados os *softwares* Microsoft Excel™, da Microsoft™, e NeuralTools™, da Palisade™, que se encontram disponíveis na empresa Noraqua.

Pretendeu-se, assim, compilar um conjunto de ferramentas e procedimentos que, aplicadas numa ordem lógica, facilitassem e estruturassem o tratamento, a preparação dos dados, o treino de RNA e a análise de resultados obtidos.

## 1.2 ENQUADRAMENTO GERAL DO TEMA

Em conformidade com Carreira (2014), devido ao aumento da população mundial desde meados do século XX a um ritmo alucinante, os recursos naturais começaram a ter uma importância que até então não era tão valorizada. O avanço da tecnologia, a melhoria das condições de vida, a diminuição da mortalidade, entre outros fatores, são a razão deste aumento exponencial da população, que por sua vez leva ao aumento do gasto dos recursos, bem como a sua dependência perante eles.

A água é um recurso natural bastante importante, desde sempre indispensável quer ao Homem quer a qualquer ecossistema da terra e, dado as suas características físico-químicas torna-se um composto único, insubstituível e essencial à vida. Apesar de cerca de dois terços do planeta estarem cobertos de água, existem locais no mundo em que a água é bastante escassa, quase inatingível. Perante o aumento da população e a má gestão deste tipo de recursos, nos últimos anos tem havido um aumento significativo de estações de tratamento de águas residuais (ETAR) de forma a reutilizar esse recurso, prevenir a poluição ambiental e evitar as consequências que os resíduos possam ter para a saúde pública, dado os microrganismos patogénicos e parasitas existentes.

Ainda em Carreira (2014), o principal objetivo destas estações de tratamento passa por corrigir as características do efluente que recebem, para que, após o tratamento, este obedeça às normas impostas e possa assim ser depositado no meio recetor sem existirem consequências prejudiciais para o ecossistema. Além disto, os combustíveis fósseis também sofrem com este aumento da

## INTRODUÇÃO

população e com todos os fatores a ele associados. É importante encontrar alternativas de forma a reduzir a dependência dos combustíveis fósseis. Tal facto aliado ao aumento do aquecimento global faz com que as energias renováveis estejam em expansão devido à urgência de implementar soluções alternativas. De acordo com (Tchobanoglous *et al.*, 2003) e citando Carreira (2014), o dimensionamento e a operação das ETAR modernas estão cada vez mais centrados na maximização da eficiência do uso da energia elétrica e na redução dos custos de tratamento. Sendo o biogás um produto resultante de uma das fases de tratamento de águas residuais, a digestão anaeróbia, e uma fonte de energia renovável com um potencial significativo, o seu reaproveitamento é cada vez mais evidente dado tratar-se de um biocombustível de baixo custo (Silveira, 2009). O biogás apresenta vantagens perante outras energias renováveis, pois é produzido através da matéria biodegradável da biomassa, que é considerada um resíduo, contribuindo assim para a diminuição da emissão de gases de efeito de estufa. Possui várias aplicações, tais como combustão direta e produção de calor, utilização como combustível, geração de eletricidade e possibilidade de integrar na rede de gás natural. A combustão do metano, o principal gás constituinte do biogás derivado da digestão anaeróbia, pode substituir as principais fontes de energia.

A digestão anaeróbia é descrita como um processo instável dado todos os fatores que o influenciam e a sua otimização que se reflete na produção de biogás. No entanto, nos últimos anos os estudos feitos em torno deste tipo de digestão têm contribuído para o conhecimento mais profundo das fases mais sensíveis do processo, por forma a conseguir uma melhor estabilidade dos digestores anaeróbios. Quando comparada com processos de via aeróbia, a digestão anaeróbia apresenta algumas vantagens: menor necessidade de nutrientes, menor produção de biomassa, capacidade da biomassa preservar a sua atividade mesmo estando sem ser alimentada por longos períodos de tempo e produção de uma fonte de energia, o biogás. Contudo, se o digestor não for bem monitorizado, nem for controlado, torna-se difícil usufruir dos benefícios que a digestão anaeróbia dispõe.

De forma a combater esta dificuldade, a aplicação de RNA ao processo pode ajudar a compreender melhor o seu funcionamento e assim otimizar a produção de biogás. As RNA são capazes de imitar as funções do cérebro, conseguindo entender relações complexas existentes entre dados que lhe são fornecidos. Estes funcionam como exemplo para que quando novos dados lhe sejam fornecidos, a rede preveja conforme os dados anteriormente estudados (Palisade, 2013). Esta ferramenta, apesar de ainda não ter grande divulgação, é utilizada em variadíssimas áreas, tais como na engenharia e ambiente, ao nível das previsões da precipitação diária, modelação de sistemas de abastecimento de

água, ou no setor financeiro, análise e pesquisa de mercado, avaliação de créditos, entre outras. Apesar de todos os avanços feitos ao longo dos anos acerca da digestão anaeróbia, ainda existem muitas dúvidas por responder sobre o seu funcionamento e quais as variáveis que mais influenciam a produção de biogás (Carreira, 2014).

### 1.3 OBJETIVOS

O principal objetivo na realização deste trabalho consiste na aplicação de RNA ao processo de DA das ETAR de Espinho e de Ílhavo, de forma a desenvolver um modelo que permita otimizar a produção de biogás, tirando partido da potencialidade de predição das referidas redes. Para tal, o caminho a seguir no desenvolvimento deste estudo compreende etapas cujos objetivos intermédios podem ser sintetizados nos seguintes aspetos principais:

- Análise da adequação da aplicação de redes neuronais artificiais à modelação do processo de digestão anaeróbia, com a finalidade de fornecer uma base para a compreensão e utilização de RNA, analisando as vantagens e possibilidades que a sua aplicação poderá trazer em termos da previsão e otimização da produção de biogás.
- Estudo e perceção das variáveis com maior impacto no funcionamento da DA, estabelecendo uma hierarquização entre elas. Devido à escassez de dados ou à carência de ferramentas adequadas ao seu tratamento, não existe certezas quanto à relação entre o volume de biogás produzido e as variáveis intervenientes num processo de DA. Um exemplo fornecido por Rocha (2013) indica que o volume de biogás produzido cresce com o aumento da carga aplicada e com a temperatura dentro do digestor, no regime mesófilo, a situar-se entre os 30°C e os 35°C. No entanto, devido à quantidade de variáveis intervenientes e à complexidade do processo, a análise estatística tradicional não oferece as respostas necessárias.

## **2 NORAQUA, CONSULTORES DE ENGENHARIA, LDA.**

A Noraqua, Consultores de Engenharia, Lda., empresa onde foi levado a cabo o presente estágio, foi fundada no ano de 1981 através do conhecimento técnico e experiência profissional dos seus sócios fundadores na área da hidráulica, recursos hídricos e ambiente.

Ao longo dos seus mais de 30 anos de existência, sempre demonstrou interesse e aptidão para o desenvolvimento de estudo na área da Engenharia Civil, nomeadamente na sua vertente ligada à Hidráulica. Já elaborou mais de 1500 trabalhos, com reconhecida qualidade.

A Noraqua inclui na sua carteira de clientes, empresas públicas e privadas, das mais variadas áreas. No que concerne a empresas públicas, destacam-se as câmaras municipais e, ultimamente, as empresas do grupo Águas de Portugal, responsáveis por boa parte dos sistemas em funcionamento em construção no território português. Relativamente a empresas públicas, destacam-se gabinetes de arquitetura, empresas exploradoras de comércio a retalho, empreiteiros, etc.

Esta ligação tem-se vindo a maturar ao longo dos anos e reflete-se tanto na elaboração de projetos para a execução de grandes linhas de adução e de drenagem, como também na realização de planos orientadores e definidores do desenvolvimento do saneamento básico em diversas regiões, tanto em Portugal, onde se sedia, como internacionalmente, mais concretamente em Angola. Neste sentido, e acompanhando a tendência dos mercados, é intenção da Noraqua expandir o seu conhecimento e habilitações para outras regiões e países, nomeadamente países de língua oficial Portuguesa, como são Moçambique, Brasil ou Cabo Verde.

As suas instalações situam-se na cidade do Porto, Portugal, onde trabalham cerca de 15 colaboradores internos (engenheiros, desenhadores e administrativos), a que se juntam colaboradores externos, das mais diversas especialidades, aptos para abranger todas as valências necessárias em cada trabalho que seja solicitado.

Esta empresa defende soluções altamente especializadas e os produtos e serviços desta empresa estão organizados e inseridos nas seguintes áreas de intervenção:

- Sistemas de abastecimento de água;
- Sistemas de drenagem de águas residuais domésticas;
- Sistemas de drenagem de águas pluviais;
- Tratamento de águas residuais domésticas e industriais;
- Análise de redes existentes;
- Infraestruturas urbanísticas;
- Infraestruturas hidráulicas de edifícios;
- Projeto de Segurança contra Incêndios;
- Vias de comunicação;
- Fiscalização de obras;
- Gestão de empreendimento.

A otimização do processo de digestão anaeróbia insere-se claramente na temática da otimização energética no ciclo urbano da água. Face à complexidade da temática, a Noraqua considera o Plano de Trabalhos definido conjuntamente com o ISEP, os meios associados e a experiência do Eng<sup>o</sup> Jaime Gabriel Silva, o meio ideal para desenvolver as competências necessárias à prossecução de uma área de trabalho inovadora, no sector de mercado em que se insere.

### 3 ETAR EM ESTUDO

O presente capítulo tem como objetivo descrever as duas ETAR que foram escolhidas como objeto de estudo.

#### 3.1 ETAR DE ESPINHO

Recorrendo informações fornecidas pela AdCL, irá ser descrita, sucintamente neste capítulo, a ETAR de Espinho, sendo referido as suas características, constituição e método de funcionamento.

##### 3.1.1 Principais características



- Legenda:
- 1 - Edifício de Tratamento Preliminar
  - 2 - Biofiltro (turfa)
  - 3 - Decantação Primária
  - 4 - Tanques de Arejamento
  - 5 - Decantação Secundária
  - 6 - Digestão Anaeróbia
  - 7 - Gasómetros
  - 8 - Caldeira, Permutadores de Calor e Cogeneradores
  - 9 - Espessadores de Lamas
  - 10 - Desodorização (biofiltros)
  - 11 - Exutor submarino
  - 12 - Edifício de Exploração

Figura 1 - Vista aérea da ETAR de Espinho (Fonte: Bing Maps)

A ETAR de Espinho, esquematizada na **Figura 1**, está localizada na freguesia de Paramos, concelho de Espinho. Foi projetada para satisfazer as necessidades de tratamento dos efluentes provenientes dos concelhos de Espinho, parte Ovar e Santa Maria da Feira.

Em funcionamento desde 1998, esta ETAR foi propriedade da Câmara Municipal de Espinho até 2001, altura em que foi adquirida pela AdCL, mantendo-se a sua exploração a cargo da Lusagua, SA.

Esta infraestrutura foi dimensionada para servir uma população de 100.000 habitantes equivalentes (ano 2006), tendo uma capacidade de tratamento diário de 18.300 m<sup>3</sup>.

Ao nível da fase líquida, esta ETAR realiza tratamento secundário aos efluentes domésticos e industriais, composto pelas seguintes etapas: tratamento preliminar, decantação primária, tratamento biológico e decantação secundária. Do tratamento da fase sólida, resulta a produção de biogás, aproveitável para o aquecimento das lamas e resulta a produção de lamas digeridas e desidratadas, valorizáveis na Agricultura.

### **3.1.2 Principais elementos constituintes da ETAR de Espinho**

As 3 fases que compreendem o tratamento do efluente são constituídas pelos seguintes componentes.

#### **3.1.2.1 Fase Líquida**

- Elevação Inicial:
  - Elevação com Parafusos de Arquimedes (2+1).
  - Receção de lamas de fossas sépticas – tanque de armazenamento de 21 m<sup>3</sup>.
- Tratamento preliminar:
  - Gradagem com 2 grades manuais com espaçamento entre barras de 40 mm (2 linhas) e 2 tamisadores com espaçamento entre barras de 6 mm (2 linhas).
  - Desarenamento e desengorduramento – 2 linhas.

- Medição de caudal através de medidor eletromagnético.
- Tratamento Primário:
  - Pré-precipitação química – Tanque de mistura rápida de 45 m<sup>3</sup> com adição de coagulante.
  - Tanque de mistura lenta de 286 m<sup>3</sup> com adição de polímero.
  - Decantação primária – 3 decantadores circulares de Ø 22 m.
- Tratamento Secundário:
  - Tanque de arejamento – 3 tanques Lamas Ativadas com 2 124 m<sup>3</sup> cada com 3 arejadores de superfície por tanque. Os tanques podem ser operados em mistura completa ou pistão.
  - Decantação secundária – 4 decantadores circulares de Ø 24 m e Ø 34 m. Uma parte da água tratada será reutilizada para água de serviço.
  - Elevação para exutor submarino – 4 bombas submersíveis (3+1).

### 3.1.2.2 Fase Sólida

- Espessamento de lamas:
  - Espessamento gravítico de lamas primárias – 2 espessadores gravíticos de Ø 10 m.
  - Espessamento mecânico de lamas secundárias – 3 tambores espessamento.
  - Armazenamento de lamas espessadas mistas – 1 tanque de 45 m<sup>3</sup>.
- Digestão anaeróbia:
  - 2 Digestores de Ø 18,5 m e 2 773 m<sup>3</sup>.
  - Aquecimento de lamas – 1 caldeira com potência unitária de 440 000 kcal/h alimentada a biogás ou gás propano e 2 permutadores de calor.
  - Armazenamento de biogás – 2 gasómetros de Ø 13 m e 1 040 m<sup>3</sup>.
  - Armazenamento das lamas digeridas – 1 tanque de 250 m<sup>3</sup>.

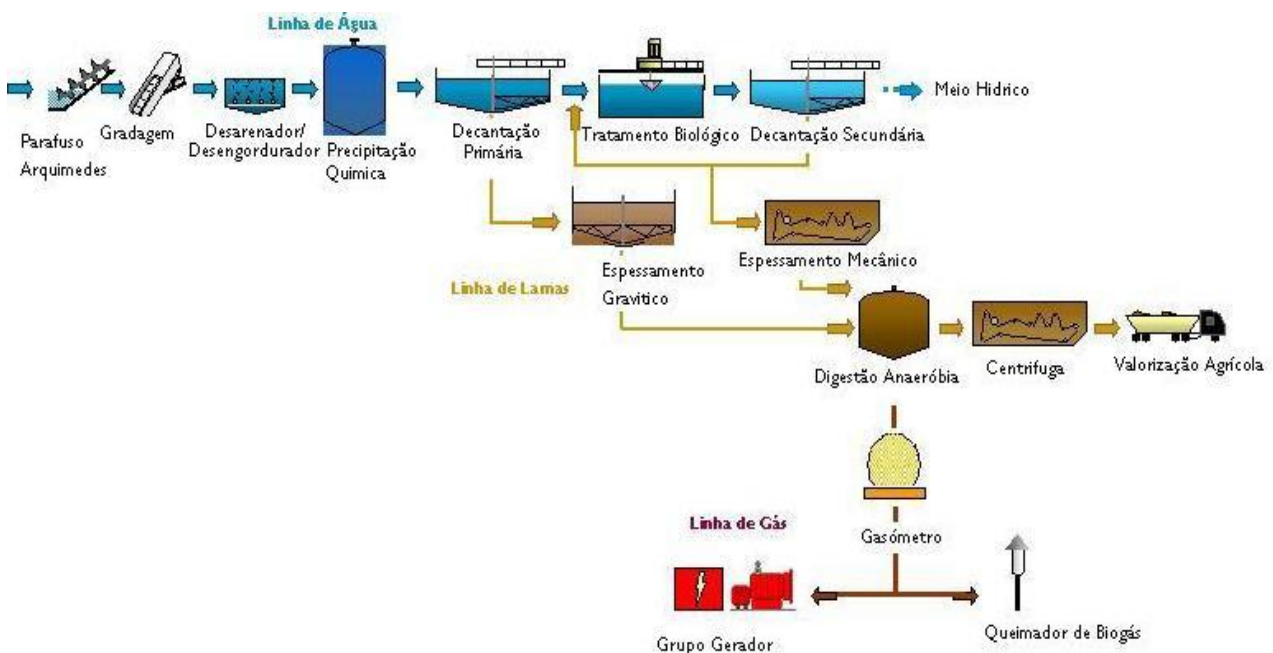
- Desidratação das lamas digeridas – 3 centrífugas (2+1).
- Armazenamento das lamas desidratadas – 1 silo de 120 m<sup>3</sup>.

### 3.1.2.3 Fase Gasosa

- Cogeração – 2 grupos de cogeração de 400 kW;
- Desodorização – 2 biofiltros com 184 m<sup>3</sup> cada.

### 3.1.3 Fases do tratamento do efluente

O processo de tratamento do efluente recebido pela ETAR desenvolve-se por duas linhas distintas, a linha de água e a linha de lamas (fase líquida e fase sólida, respetivamente), conforme demonstra a seguinte **Figura 2**.



**Figura 2** - Diagrama Funcional da ETAR de Espinho

### **3.1.3.1 Linha de água**

Em conformidade em Di Berardino (2006) e Rocha (2013), nesta fase é feita a correção das características físicas, químicas e microbiológicas e posterior descarga no meio recetor das águas residuais tratadas, tendo em consideração as características do meio recetor.

No tratamento preliminar, são realizadas operações preparatórias que visam remover os sólidos grosseiros, areias e gorduras contidos no esgoto, sendo posteriormente realizado um tratamento primário de sedimentação efetuado em decantadores. A sedimentação permite uma remoção de sólidos suspensos totais (SST) superior a 90% (Di Berardino, 2006). Esta operação permite atingir um nível de depuração do esgoto de 30-35% em termos de  $CBO_5$ , reduzindo significativamente a carga poluente do esgoto. Após o tratamento primário, a matéria poluente remanescente é constituída essencialmente por coloides.

No tratamento biológico secundário, a matéria orgânica do efluente resultante do tratamento primário é degradada por intermédio de microrganismos aeróbios que são introduzidos em reatores biológicos sujeitos a arejamento. No efluente do decantador secundário, o esgoto contém uma quantidade elevada de biomassa que se desenvolve à custa da degradação de parte significativa do material orgânico e dos nutrientes presentes no esgoto. Estes microrganismos vão sedimentar no fundo do decantador sendo removidos por decantação. Após o tratamento secundário, as águas residuais tratadas apresentam um nível reduzido de poluição por matéria orgânica, podendo na maioria dos casos, serem descarregadas no ambiente recetor, que neste caso é o Oceano Atlântico.

O processo completo de tratamento permite atingir, na sua globalidade, uma eficiência de tratamento superior a 90% em termos de  $CBO_5$ , produzindo lamas primárias e lamas secundárias. Os tratamentos primário e secundário possibilitam, deste modo, uma redução significativa do volume de lamas comparativamente ao volume de efluente inicial. No entanto estas lamas concentram ainda a carga orgânica poluente retirada ao esgoto, apresentando um estado elevado de putrefação, viscosidade e mau cheiro (Di Berardino, 2006).

### 3.1.3.2 Linha de Lamas

Ainda de acordo com Di Berardino (2006) e Rocha (2013), na linha de lamas realiza-se o tratamento das lamas geradas no tratamento das águas residuais e, após o tratamento, o encaminhamento das lamas para destino final adequado (agricultura, aterro, etc.).

As lamas primárias, que correspondem a cerca de 2,5 - 3,5 % do volume de esgoto e resultam do processo de sedimentação dos SST, são recolhidas do decantador primário e encaminhadas para os espessadores. As lamas secundárias são removidas do decantador secundário e são reencaminhadas para o reator biológico (recirculação de lamas) ou encaminhadas para o flotador. As lamas espessadas no espessador e no flotador são recolhidas e misturadas numa câmara de lamas mistas antes de serem enviadas para o digestor anaeróbio. Os tanques de espessamento como os espessadores e o flotador permitem aumentar a concentração das lamas, possibilitando uma redução do seu volume e do caudal a enviar para a digestão.

No digestor anaeróbio processa-se a digestão anaeróbia das lamas da qual resulta a produção de biogás rico em metano.

As lamas digeridas passam por mais um processo de aumento da sua concentração através do espessamento por centrifugação antes de serem armazenadas num silo para posterior encaminhamento para destino final (aterro ou agricultura).

O biogás produzido é armazenado num gasómetro que abastece as caldeiras para o aquecimento das lamas e o moto-gerador no qual se processa a cogeração de eletricidade.

As águas residuais municipais e as lamas de esgoto apresentam-se como um substrato com características adequadas para aplicação na área biotecnológica, uma vez que apresentam uma composição muito particular que contém os compostos necessários para o crescimento microbiano.

## 3.2 ETAR DE ÍLHAVO

Recorrendo informações fornecidas pela AdCL e consultas efetuadas a Rocha (2013), irá ser descrita, sucintamente neste capítulo, a ETAR de Ílhavo, sendo referido as suas características, constituição e método de funcionamento.

### 3.2.1 Principais características

A ETAR de Ílhavo, esquematizada na **Figura 3**, localiza-se na freguesia da Gafanha da Encarnação, concelho de Ílhavo, encontrando-se em funcionamento desde Agosto de 2002.

Atualmente recebe e trata os efluentes provenientes de Aveiro (parte), Ílhavo, Mira, Vagos e Cantanhede.

Os seus dados de projeto encontram-se na seguinte **Tabela 1**.

**Tabela 1** - Dados de Projeto (Fonte: AdCL, 2013; citado por Rocha, 2013)

Dados de Base	Ano 2018	Ano 2038
Pop. Equivalente (hab)	159 700	182 000
Caudal médio (m <sup>3</sup> /dia)	39 278	46 635
Caudal de ponta (l/h)	860	1 020



Legenda:

- 1 - Edifício de Pré Tratamento
- 2 - Decantação Primária
- 3 - Tratamento Biológico
- 4 - Decantação Secundária
- 5 - Estação Elevatória IS8
- 6 - Espessamento de lamas
- 7 - Digestão Primária
- 8 - Digestão Secundária
- 9 - Edifício de Digestão, Desidratação e PT
- 10 - Silo de lamas
- 11 - Gasómetro
- 12 - Edifício de Exploração e Oficinas
- 13 - Portaria

Figura 3 - ETAR de Ílhavo da AdCL. (Fonte: AdCL, 2013; citado por Rocha, 2013)

### 3.2.2 Principais elementos constituintes da ETAR de Ílhavo

As fases que compreendem o tratamento do efluente são constituídas pelos seguintes componentes.

- Receção de efluentes provenientes do Intercetor Sul, do Emissário Barra/Costa Nova e do Emissário Aveiro/Ílhavo.
- Pré-tratamento:
  - 2 Tamisadores (5 mm) + 1 grelha manual (20 mm).
  - 2 Desarenadores /desengorduradores (2x308 m<sup>3</sup>).
- Medição de caudal através de medidor eletromagnético.


## ETAR EM ESTUDO

- Decantação Primária: - 2 decantadores circulares (= 31,5 m e V= 2750 m<sup>3</sup>).
- Tratamento Biológico:
  - 2 Tanques de arejamento (2x3882 m<sup>3</sup>).
  - Lamas ativadas de média carga e baixa idade.
  - 4 Turbinas de arejamento superficial em cada tanque.
- Decantação secundária: - 2 decantadores circulares de sucção ( $\phi = 38$  m e V=4150 m<sup>3</sup>).
- Espessamento de lamas:
  - 2 Espessadores para as lamas primárias (2x276 m<sup>3</sup>).
  - 1 Flotador para as lamas secundárias (250 m<sup>3</sup>).
  - Edifício de pressurização e tanque de mistura lamas (15 m<sup>3</sup>).
- Digestão anaeróbia:
  - 2 Digestores primários (2x3000 m<sup>3</sup>).
  - 1 Digestor secundário (1370 m<sup>3</sup>).
- Aquecimento das lamas:
  - 2 Caldeiras com potência unitária de 350.000 Kcal/h, alimentadas a biogás e gás natural.
  - 2 Permutadores de calor.
- Desidratação de lamas: - 2 centrífugas.
- Armazenamento de lamas: - Silo com 100 m<sup>3</sup> de capacidade.
- Desodorização por via química, no edifício de pré-tratamento, na sala de desidratação das lamas e nos espessadores.
- Potência instalada: 1000 KVA.

- Destino final do efluente tratado: Oceano Atlântico, após descarga através do exutor submarino de S. Jacinto.
- Captação própria de água.
- Ligação à rede municipal de abastecimento de água e ligação à rede de distribuição de gás natural.
- Moto-gerador: 725 KW.

### 3.2.3 Fases do tratamento do efluente

O processo de tratamento do efluente recebido pela ETAR desenvolve-se por duas linhas distintas, a linha de água e a linha de lamas (fase líquida e fase sólida, respetivamente), conforme demonstra a seguinte **Figura 4**.



**Figura 4** - Diagrama Funcional da ETAR de Ílhavo. (Fonte: AdCL, 2013; citado por Rocha, 2013)

Sendo os processos de ambas as fases (líquida e sólida) bastante idênticos entre as duas ETAR, a caracterização destes pode ser consultada no capítulo anterior, referente à ETAR de Espinho.

## 4 DIGESTÃO ANAERÓBIA

### 4.1 FASES DO PROCESSO ANAERÓBIO

A digestão anaeróbia é um processo mediado por uma comunidade complexa de microrganismos que promovem a decomposição e degradação da matéria orgânica nos respectivos compostos químicos mais simples, na ausência de oxigênio, permitindo, deste modo, a estabilização bioquímica de resíduos orgânicos (Silveira, 2009).

O bom funcionamento do processo está dependente da ação cooperativa e sequencial de diversas bactérias de diferentes grupos tróficos (McHugh *et al.*, 2003; citado por Silveira, 2009).

As bactérias anaeróbias de diferentes grupos tróficos apresentam muitas vezes relações de sintrofia (benefício mútuo), cooperando entre si de modo a aproveitar de modo eficiente quantidades muito reduzidas de energia que normalmente se verificam no processo de conversão da matéria orgânica em metano (Schink, 1997; citado por Silveira, 2009).

Os produtos finais da digestão anaeróbia são o biogás, constituído essencialmente por metano ( $\text{CH}_4$ ) e dióxido de carbono ( $\text{CO}_2$ ), e o produto digerido, constituído por biomassa microbiana (Kelleher *et al.*, 2002; citado por Silveira, 2009).

Os compostos orgânicos dos resíduos podem ser classificados em diversos grupos biológicos representados pelas proteínas, glúcidos e lípidos. Os glúcidos são, de longe, os maiores constituintes dos resíduos biodegradáveis e incluem celulosas, amido e açúcares. As proteínas representam um vasto complexo de materiais orgânicos compostos por grupos de aminoácidos. Os lípidos são compostos constituídos por ácidos gordos.

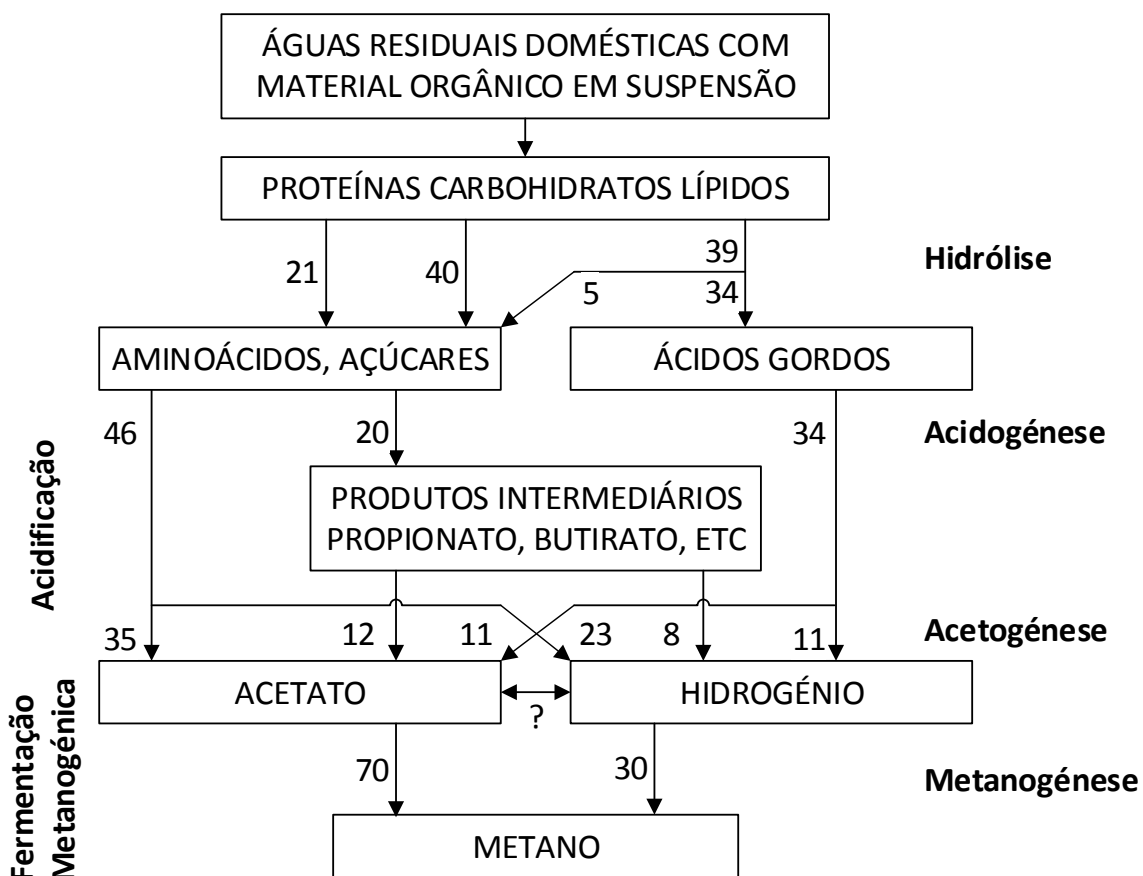
O processo de estabilização anaeróbio, esquematizado na **Figura 5**, e a consequente produção de metano podem-se dividir nas seguintes quatro etapas interdependentes (Khalid *et al.*, 2011):

**Hidrólise:** nesta primeira etapa ocorre a redução de polímeros orgânicos complexos em moléculas solúveis mais simples através de enzimas extracelulares;

**Acidogénese:** os compostos reduzidos são convertidos, pelas bactérias fermentativas, numa mistura de ácidos gordos voláteis (AGV) de cadeias curtas, dióxido de carbono, hidrogénio e ácido acético;

**Acetogénese:** nesta fase os ácidos gordos são convertidos em acetato, dióxido de carbono e hidrogénio, os quais são os substratos diretos para a produção de metano (Li, *et al.*, 2011);

**Metanogénese:** nesta última etapa diversas bactérias metanogénicas consomem acetato, dióxido de carbono e hidrogénio para a produção de metano.



**Figura 5** - Sequência de processos na digestão anaeróbia de macromoléculas complexas (os números referem-se a percentagens expressas como CQO) (Fonte: Van Haandel & Lettinga, 1994)

### 4.1.1 Hidrólise (Bactérias Hidrolíticas)

A fase inicial de decomposição envolve a ação de bactérias fermentativas hidrolíticas num processo denominado por hidrólise. Este primeiro passo da degradação anaeróbia consiste na degradação de compostos orgânicos complexos, tais como hidratos de carbono, proteínas e lípidos, que são transformados em compostos solúveis mais simples. Nesta etapa as proteínas são convertidas em aminoácidos, os polissacarídeos em monossacarídeos, os lípidos em ácidos gordos e os ácidos nucleicos em purinas e pirimidinas.

A hidrólise pode-se tornar uma etapa limitante do processo, influenciando a eficiente conversão dos substratos orgânicos, principalmente se ocorrerem situações de sobrecarga destes substratos nos digestores.

O bom funcionamento do processo de hidrólise está dependente do contato eficiente entre a biomassa e o substrato e também de vários fatores como a composição e concentração do substrato, produção e estabilidade das enzimas, disponibilidade de substrato, pH, temperatura do líquido em digestão e concentração de AGV (Rocha, 2013).

### 4.1.2 Acidogénese (Bactérias Acidogénicas)

Na fase da acidogénese, também denominada por fermentação ácida, os compostos solúveis gerados na hidrólise são absorvidos e degradados pelas células dos microrganismos acidogénicos e depois excretados sob a forma de compostos orgânicos simples. Estes compostos são, por exemplo, ácidos gordos voláteis, álcoois, ácido láctico e compostos minerais como dióxido de carbono, hidrogénio, amónia e gás sulfídrico (Van Haandel & Lettinga, 1994).

Esta fase é realizada essencialmente por bactérias, na sua maioria anaeróbias estritas. Contudo, existem algumas bactérias facultativas, que conseguem metabolizar matéria orgânica por via oxidativa. Este facto tem grande importância na digestão anaeróbia, devido ao oxigénio dissolvido ser tóxico para os microrganismos estritamente anaeróbios, como é o caso das bactérias metanogénicas (Van Haandel & Lettinga, 1994).

A via metabólica de produção de produtos intermédios (AGV, álcoois e lactato) vai assumindo preponderância à medida que se verifica um aumento da pressão parcial de H<sub>2</sub> derivado, por

exemplo, de uma redução do valor do pH (<6). Se o valor de pH for igual ou inferior a 4, pode existir uma inibição do processo fermentativo, assim como se existir um aumento de concentrações de substrato (Crespo, 2013).

### 4.1.3 Acetogénese (Bactérias Acetogénicas)

Na acetogénese, os ácidos gordos e o etanol formados na fase anterior são degradados pelas bactérias acetogénicas, que irão produzir acetato, dióxido de carbono e hidrogénio, que vão servir de substrato para as bactérias metanogénicas na sua produção de metano.

Dependendo do estado de oxidação da matéria orgânica, a formação de ácido acético é acompanhada pela formação de dióxido de carbono e hidrogénio. Da matéria orgânica originalmente presente na lama afluyente à digestão, 70% é convertida em ácido acético e o resto principalmente em hidrogénio (Mendes, 2014).

Existem dois tipos de bactérias intervenientes na acetogénese: as bactérias acetogénicas produtoras obrigatórias de hidrogénio (bactérias sintróficas) e as bactérias acetogénicas consumidoras de hidrogénio. As primeiras promovem a oxidação anaeróbia dos AGV a acetato. As reações envolvidas não são termodinamicamente favoráveis e só ocorrem quando a pressão parcial de H<sub>2</sub> é mantida a níveis reduzidos. As segundas, existentes em menor número, produzem acetato a partir de CO<sub>2</sub> e H<sub>2</sub>, contribuindo assim para uma baixa pressão de hidrogénio no sistema (Pires, 2009).

A temperatura é outro fator que influencia a termodinâmica das reações de acetogénese. A formação de H<sub>2</sub> a partir da oxidação de ácidos orgânicos é energeticamente mais favorável a temperaturas mais elevadas, enquanto o consumo de H<sub>2</sub> pelas bactérias metanogénicas é menos favorável a temperaturas superiores. No entanto, a velocidade de degradação dos ácidos orgânicos aumenta normalmente com temperaturas mais elevadas devido ao aumento da atividade bacteriana, da sua taxa de crescimento e da degradação do substrato (De Bok *et al.*, 2004; citado por Silveira, 2009).

### 4.1.4 Metanogénese (Bactérias Metanogénicas)

A metanogénese é a última fase do processo de digestão anaeróbia, onde se dá a produção de metano. O metano é produzido pelas bactérias acetotróficas a partir do ácido acético ou pelas bactérias hidrogenotróficas usando dióxido de carbono e hidrogénio.

Por outro lado, a metanogénese é frequentemente a fase limitante da taxa global de digestão anaeróbia, devido à maior sensibilidade das bactérias metanogénicas às condições e variações do meio, embora a baixas temperaturas a fase limitante seja a hidrólise (Van Haandel & Lettinga, 1994). Estas bactérias são estritamente anaeróbias. Apresentam taxas de crescimento muito lentas, o que tem como consequência serem frequentemente consideradas como o fator limitante no tratamento anaeróbio de resíduos orgânicos (Tchobanoglous *et al.*, 2003).

Nesta etapa atuam dois tipos principais de bactérias metanogénicas, cuja denominação depende do tipo de substrato utilizado:

- Metanogénese acetotrófica: As bactérias acetotróficas são consideradas a espécie mais importante que intervém nesta etapa. Estas são responsáveis pela produção de cerca de 70% do total de gás metano produzido, participando ainda no controlo do pH no digestor, uma vez que a remoção de ácido acético está associada à produção de CO<sub>2</sub> que se dissolve no meio, formando uma solução tampão de bicarbonatos, o que provoca a neutralidade dos valores de pH (Pires, 2009).
- Metanogénese hidrogenotrófica: Através das bactérias hidrogenotróficas que, apesar de serem as espécies mais abundantes nos digestores, são também responsáveis pela produção de apenas 30% do metano gerado a partir do H<sub>2</sub> e CO<sub>2</sub>.
- Existem ainda as bactérias que realizam a inter-conversão entre acetato, hidrogénio e dióxido de carbono, denominadas de bactérias homoacetoclásticas.

#### 4.1.5 Sulfidogénese

De acordo com Silveira (2009), durante o tratamento anaeróbio de efluentes com concentrações elevadas de sulfato ( $\text{SO}_4^{2-}$ ), sulfito ( $\text{SO}_3^{2-}$ ), ou outras formas oxidadas de enxofre, ocorre um processo em simultâneo com as outras fases, designado por sulfidogénese, em que as bactérias redutoras de sulfato reduzem estes compostos convertendo-os em sulfuretos.

Em conformidade com Lens *et al.*, (1998), a presença de concentrações elevadas de sulfuretos apresenta efeitos tóxicos na atividade das bactérias metanogénicas, acetogénicas, e redutoras de sulfato.

Parte da matéria orgânica da água residual é utilizada pelas bactérias redutoras de sulfato, reduzindo, conseqüentemente, o potencial de produção de metano por parte das bactérias metanogénicas. Para além disso, a qualidade do biogás produzido fica reduzida devido ao aumento da fração de  $\text{H}_2\text{S}$  no biogás resultante da produção de sulfuretos na fase líquida.

Os sulfuretos, em concentrações elevadas, apresentam um odor desagradável e provocam problemas de corrosão em condutas, motores e queimadores. A minimização destes efeitos requer custos acrescidos de manutenção e de investimento. Parte dos sulfuretos estão presentes no efluente do reator anaeróbio, provocando uma diminuição da eficiência do tratamento, uma vez que os sulfuretos contribuem para a carência química de oxigénio (CQO) da água residual.

## 4.2 VANTAGENS E DESVANTAGENS DA DIGESTÃO ANAERÓBIA

De acordo com Mendes (2014), embora existam outros processos possíveis para a estabilização das lamas, o processo a digestão anaeróbia apresenta vantagens que levam a ser o mais utilizado. As suas vantagens podem ser resumidas em:

- Existência de produção de biogás, que pode ser utilizado para produzir energia elétrica para sustentar total ou parcialmente os equipamentos da ETAR ou para vender essa energia à rede elétrica. Também é produzida energia térmica, gerada na combustão do biogás, que pode ser aproveitada para o aquecimento das lamas na digestão, melhorando as condições de funcionamento, a produtividade e o desempenho.

## DIGESTÃO ANAERÓBIA

- Redução da massa e volume total de lamas através da conversão em metano, dióxido de carbono e vapor de água. Da quantidade afluyente ao digestor, a quantidade de sólidos voláteis destruídos é cerca de 50% segundo (Tchobanoglous & Burton, 1991), o que pode proporcionar uma redução significativa no custo de desidratação e deposição final de lamas.
- Produção de lamas digeridas que podem ser utilizadas para correção de solos, por conterem nutrientes, como azoto, fósforo, matéria orgânica, entre outros e que podem contribuir para o aumento da fertilidade e textura dos solos (Turovskiy & Mathai, 2006).

Por outro lado, as desvantagens da DA podem ser resumidas em:

- Os custos de instalação e manutenção são elevados, devido às grandes dimensões dos digestores e equipamentos associados ao seu funcionamento.
- Os microrganismos presentes na digestão anaeróbia são sensíveis a pequenas variações de diversos fatores ambientais, tornando-se necessário fazer uma monitorização do desempenho e controlo do processo para prevenir distúrbios (Turovskiy & Mathai, 2006).
- Digestores anaeróbios que não são agitados, ou cujo conteúdo não é homogeneizado, estão na origem de sobrenadantes com alta concentração de sólidos suspensos, azoto e fósforo (Turovskiy & Mathai, 2006).

### **4.3 FATORES QUE INTERFEREM NO PROCESSO DE DIGESTÃO ANAERÓBIA**

A digestão anaeróbia um processo biológico, não só depende do potencial metabólico dos microrganismos, mas também da existência de condições ambientais adequadas que permitam a sua atividade (Pereira, 2013).

Existem variados fatores que podem afetar o desenvolvimento do processo de digestão anaeróbia, sendo os mais importantes a temperatura, pH, alcalinidade, razão Carbono/Azoto (C/N), tipo e concentração do substrato, entre outros (Khalid *et al.*, 2011).

### 4.3.1 Temperatura

A temperatura é um dos fatores com maior influência no processo de digestão anaeróbia, influenciando a atividade biológica, o tipo de bactérias anaeróbias que se desenvolvem, a sua velocidade de crescimento, a quantidade de biogás produzido, o grau de utilização do substrato e a sua capacidade de resposta a variações na carga afluyente.

Consoante a temperatura de digestão, verifica-se que cada tipo de bactéria tem um intervalo de temperatura ótima para o seu desenvolvimento e é classificada de acordo com essa gama de temperatura (Lettinga *et al.*, 2001; citado por Mendes, 2014). Podem ser definidas três regimes principais de funcionamento do processo de estabilização anaeróbia que se encontram na seguinte

#### Tabela 2.

**Tabela 2** - Regimes de temperatura do processo de digestão anaeróbia (Fonte: Tchobanoglous & Burton, 1991)

Regime	Temperatura (°C)	
	Gama	Intervalo Ideal
<b>Psicrófilo</b>	[-10;30]	[12;18]
<b>Mesófilo</b>	[20;50]	[25;40]
<b>Termófilo</b>	[35;75]	[55;65]

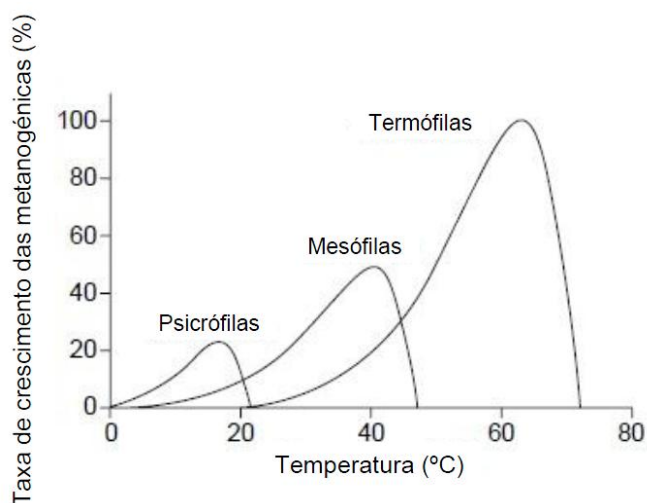
No regime psicrófilo ocorrem dificuldades no arranque e no funcionamento dos digestores, dada a reduzida velocidade de crescimento das bactérias. Khalid *et al.* (2011) referenciam que temperaturas baixas durante o processo originam uma atrofia das taxas de crescimento dos microrganismos, do grau de utilização dos substratos e da produção de biogás.

Por outro lado, temperaturas muito elevadas podem também diminuir a produção de biogás, devido à diminuição da concentração dos AGV por causa do aumento da sua volatilização para a fase gasosa, o que diminui os substratos disponíveis para a digestão anaeróbia (Pereira, 2013). Um aumento da temperatura de regime mesofílico para termofílico pode provocar uma diminuição na produção de biogás devido às bactérias termofílicas que são mais sensíveis e instáveis (Pereira, 2013).

## DIGESTÃO ANAERÓBIA

No entanto, a gama termófila apresenta certas vantagens como uma maior velocidade de degradação dos resíduos orgânicos, destruição dos microrganismos patogênicos, podendo, nestes casos, originar uma maior produção de biogás (Khalid *et al.*, 2011). De acordo com Pereira (2013), a determinação da temperatura mais favorável a um sistema de digestão anaeróbia depende, entre outros fatores, dos diferentes valores ótimos de temperatura para o desenvolvimento das diversas populações microbianas intervenientes no processo.

Na **Figura 6**, é demonstrada uma relação entre a taxa de crescimento das bactérias metanogénicas e o aumento de temperatura.



**Figura 6** - Taxa de crescimento das bactérias metanogénicas psicrófilas, mesófilas e termófilas (adaptado de Wiegel, 1990; citado por Mendes, 2014)

### 4.3.2 pH

O pH é definido pelas concentrações de bases e ácidos presentes no meio anaeróbio. Este parâmetro tem efeitos na atividade enzimática dos diversos grupos de microrganismos. Cada grupo apresenta uma gama ótima de pH para o seu desenvolvimento no meio, indicada na **Tabela 3**.

As bactérias metanogénicas são extremamente sensíveis ao pH do meio, em que valores de pH inferiores a 6,2, provocam uma inibição da sua atividade. (Tchobanoglous *et al.*, 2003). No caso das bactérias acidogénicas, estas apresentam uma maior tolerância a valores baixos de pH. Os valores ótimos de pH para a população acidogénica situam-se entre 5,5 e 6,0 (Pires, 2009).

Estes microrganismos acidogénicos são significativamente menos sensíveis a baixos ou altos valores de pH, pelo que a acidogénese pode continuar mesmo quando há inibição da metanogénese, levando a uma contínua redução do pH, possivelmente conduzindo à falha do processo, por acidificação do digestor (Van Haandel & Lettinga, 1994). Durante a DA, a acidogénese e a metanogénese, exigem diferentes valores ótimos de pH, que devidamente ajustados, permitem uma maior otimização de todo o processo. Por esta razão, é aconselhável proceder-se à divisão do processo anaeróbio em duas fases distintas, utilizando dois digestores (Pereira, 2013).

Num primeiro digestor decorrem as duas primeiras etapas do processo anaeróbio (hidrólise e acidogénese) procedendo-se à correção do pH para valores mais favoráveis às bactérias fermentativas. As duas fases seguintes do processo (acetogénese e metanogénese) ocorrem num segundo digestor, em que se ajusta o pH para valores próximos da neutralidade, mais favoráveis às bactérias metanogénicas.

**Tabela 3** - Valores de pH ótimos em diversos grupos de bactérias intervenientes no processo de digestão anaeróbia (Fonte: Di Berardino, 2006)

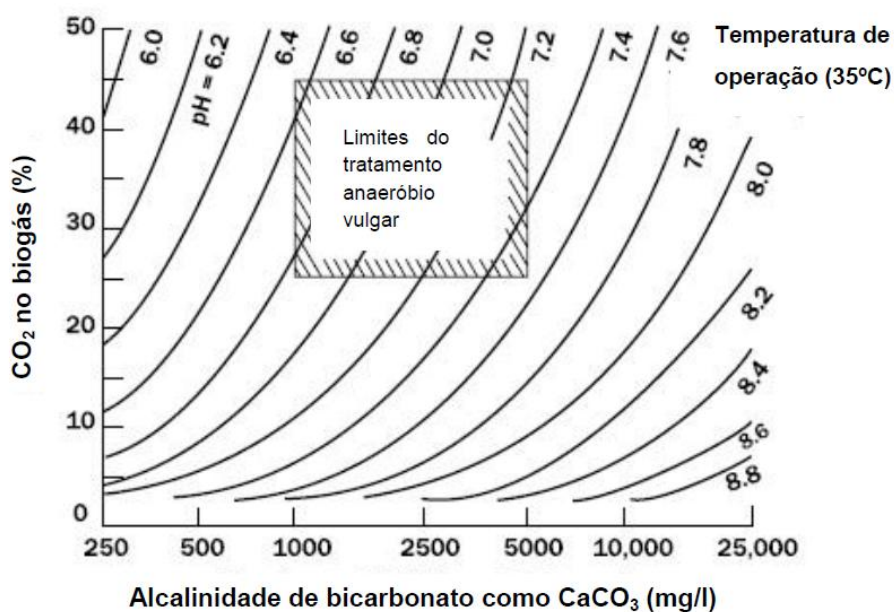
<b>Grupo Bacteriano</b>	<b>pH ótimo</b>
<b>Hidrolíticas</b>	7,2 – 7,4
<b>Acidogénicas</b>	≈ 6
<b>Acetogénicas</b>	7,0 – 7,2
<b>Metanogénicas</b>	6,5 – 7,5
<b>Redutoras de Sulfato</b>	7,3 – 7,6

Nos casos em que se dispõe apenas de um digestor, são as bactérias metanogénicas que, sendo as mais sensíveis a alterações dos valores de pH, obrigam a manter os valores de pH do digestor mais próximos das suas condições favoráveis, no sentido de evitar a sua inibição. Nessa situação, para que a metanogénese ocorra nas melhores condições, ajustam-se os valores de pH para valores próximos de 7, mais especificamente entre 6,8 e 7,2 (Khalid *et al.*, 2011).

### 4.3.3 Alcalinidade

Mendes (2014) refere que a alcalinidade representa a capacidade de resistência oferecida à variação do pH na presença de substâncias com características para o alterar, designando-se como o poder tampão do meio.

Uma parte da alcalinidade deve-se à dissolução de  $\text{CO}_2$  e formação de bicarbonato, sendo que a alcalinidade depende da relação dióxido de carbono-bicarbonato. A dissolução do  $\text{CO}_2$  no meio é proporcional à sua pressão parcial no biogás e a sua conversão depende do pH do meio, portanto a concentração em bicarbonatos, o pH e a pressão parcial do  $\text{CO}_2$  relacionam-se entre si. Quanto maior a concentração de bicarbonato, maior a alcalinidade. A **Figura 7** mostra a relação entre o pH e a concentração da alcalinidade, à medida que a alcalinidade baixa, o pH do meio também diminui.



**Figura 7** - Relação entre o pH e a concentração de bicarbonato, a uma temperatura de 35°C (adaptado de U.S.

EPA, 1979; citado por Mendes, 2014)

#### 4.3.4 Nutrientes

Os microrganismos presentes na digestão anaeróbia têm necessidades de nutrientes. Estas necessidades são aferidas através da composição química do material celular, apresentando-se na **Tabela 4** a composição típica das células bacterianas.

**Tabela 4** - Composição típica de células bacterianas (adaptado de Tchobanoglous *et al.*, 2003)

Elemento	Porcentagem em massa seca	
	Intervalo	Típico
<b>Carbono</b>	45 – 55	50
<b>Oxigénio</b>	16 – 22	20
<b>Azoto</b>	12 – 16	14
<b>Hidrogénio</b>	7 – 10	8
<b>Fósforo</b>	2 – 5	3
<b>Enxofre</b>	0,8 - 1,5	1
<b>Potássio</b>	0,8 - 1,5	1
<b>Sódio</b>	0,5 - 2,0	1
<b>Cálcio</b>	0,4 - 0,7	0,5
<b>Magnésio</b>	0,4 - 0,7	0,5
<b>Cloro</b>	0,4 - 0,7	0,5
<b>Ferro</b>	0,1 - 0,4	0,2
<b>Outros</b>	0,2 - 0,5	0,3

De acordo com Mendes (2014), os principais elementos necessários à síntese do material orgânico são o carbono, o oxigénio, o azoto e o hidrogénio.

Relativamente ao carbono, durante o processo de digestão anaeróbia, este representa a fonte de energia dos microrganismos, o azoto estimula o crescimento microbiano e o enxofre a síntese de aminoácidos (Carrilho, 2012; citado por Pereira, 2013).

O enxofre, embora em menor quantidade, também é necessário para a síntese de aminoácidos e de fósforo. Relativamente ao enxofre, quando existe em elevadas quantidades no meio, poderá estimular o desenvolvimento excessivo das bactérias sulfato-redutoras, provocando a formação de gás sulfídrico e inibição das bactérias metanogénicas (Gadelha, 2005; citado por Pereira, 2013).

Outro macronutriente relevante no processo anaeróbio é o fósforo, que deve estar presente numa relação C/P de 150/1. O processo não é afetado por concentrações de fósforo elevadas, mas é inibido caso não haja presença do mesmo (Mendes, 2014).

### **4.3.5 Razão Carbono/Azoto (C/N)**

Dos macronutrientes referidos, o azoto assume uma importância elevada pois é necessário a todos os organismos vivos para a formação das suas proteínas.

Quando um resíduo não contém quantidades suficientes de azoto, este deve ser adicionado, no entanto, se este existir em concentrações demasiado elevadas, pode provocar inibição do processo de digestão, visto que uma porção considerável do azoto é transformada, dentro dos digestores, em amónia (Souza, 1984).


No decorrer do processo de digestão anaeróbia, o carbono disponível no meio é utilizado pelas bactérias cerca de 30 a 35 vezes mais rapidamente, quando comparado ao azoto.

### **4.3.6 Tempo de Retenção Hidráulica (TRH)**

Tchobanoglous & Burton (1991) referem que o TRH indica o tempo médio que um determinado volume de lamas permanece no digestor anaeróbio, sendo um parâmetro fundamental para o dimensionamento de um sistema de tratamento anaeróbio pois determina o tempo de contacto entre o substrato e as bactérias.

Como as bactérias metanogénicas são de crescimento lento e são microrganismos determinantes na produção de biogás, o TRH deve ser sempre superior ao tempo de duplicação dessas bactérias, de modo a garantir uma degradação total da matéria. Tal como é evidenciado na **Figura 8**, o tempo de

retenção hidráulico do digestor também é influenciado pela temperatura no seu interior. Esta proporcionalidade é inversa, sendo que, quando a temperatura é aumentada, menor é o tempo de retenção hidráulico, que pode variar entre os 10 e os 60 dias (Mendes, 2014).



**Figura 8** - Influência da temperatura e do tempo de retenção na eficiência de digestão anaeróbia de lamas primárias (adaptado de O'Rourke, 1968; citado por Mendes, 2014)

#### 4.3.7 Agitação

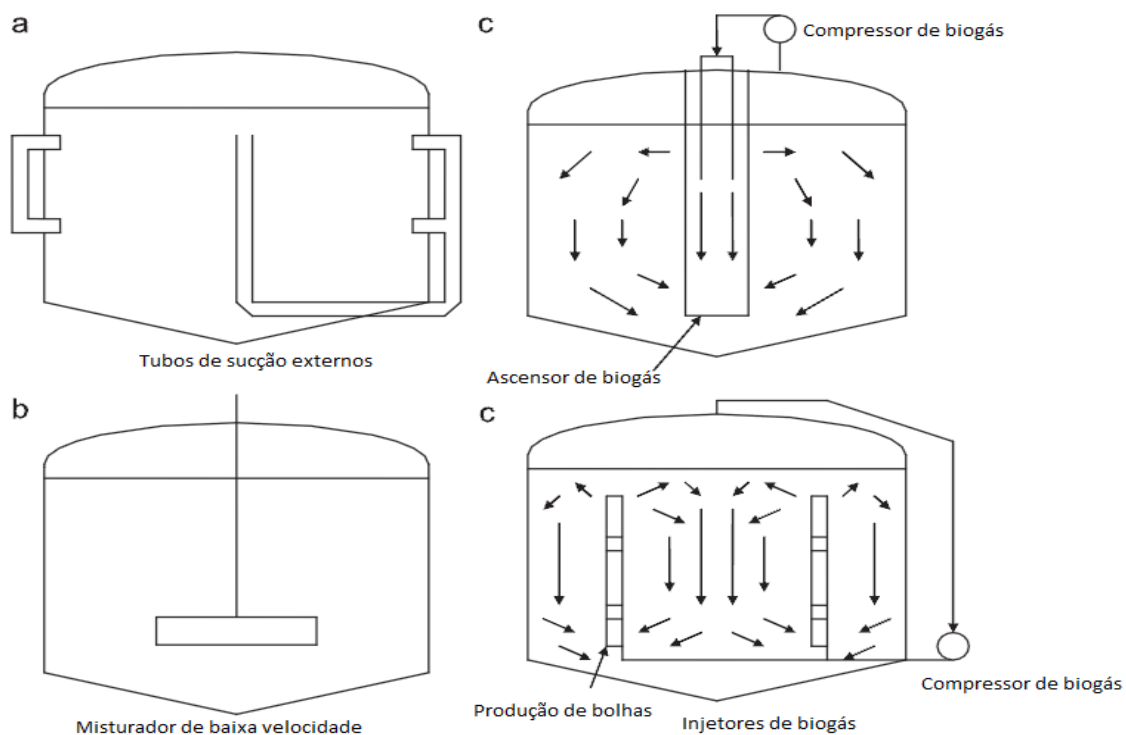
A agitação (ou mistura) dum digestor é um dos fatores que mais influencia o desempenho da digestão anaeróbia, pelo que este parâmetro operacional se reveste de grande importância quando se pretende obter um elevado rendimento de conversão de matéria orgânica.

O objetivo da agitação é melhorar o contato entre o substrato do afluente com a biomassa no interior do digestor, evitando temperaturas variadas dentro do digestor e mantendo uma uniforme

## DIGESTÃO ANAERÓBIA

concentração de substrato. Para além disso, a agitação evita a formação de camadas de espuma superficiais e a deposição de lama no fundo do digestor (Rocha, 2013).

Os métodos de agitação auxiliares utilizados são a recirculação bombeada externa, agitação mecânica interna ou injeção interna do biogás produzido, esquematizados na **Figura 9**. (Igoni *et al.*, 2008 e Appels *et al.* 2008).



**Figura 9** - Tipos de agitação dos digestores (a) recirculação bombeada externa, (b) agitação mecânica interna e (c) recirculação externa de biogás. (Fonte: Appels *et al.*, 2008)

Nos sistemas de agitação mecânica geralmente são utilizados agitadores em forma de hélice ou propulsores, que são colocados submersos no conteúdo do digestor ou montados no topo do digestor com o eixo submerso.

Nos sistemas de recirculação de lamas, o conteúdo do digestor é recirculado por bombas internas ou externas ao digestor. Ao utilizar este sistema externamente, é possível promover o aquecimento das

lamas, mediante permutadores de calor. A grande desvantagem deste sistema é ter um consumo energético muito elevado (Qasim, 1999).

Nos sistemas de recirculação de biogás, o biogás produzido é recolhido no topo da cobertura, sendo uma parte deste, comprimido e injetado novamente no interior do digestor. A injeção do biogás pode ser feita recorrendo a difusores distribuídos pelo fundo ou por tubos amovíveis pendentes a partir do topo do digestor. Este tipo de mistura/agitação também tem a desvantagem de ter um elevado consumo energético (Mendes, 2014).

#### **4.3.8 Carga volúmica**

A carga volúmica dum digestor é definida pela quantidade matéria volátil (MV) que entram no digestor por unidade de volume do digestor ( $m^3$ ) e unidade de tempo (dia), podendo ser expressa por  $(kg \text{ de MV}) \cdot m^{-3} \cdot dia^{-1}$  (Turovskiy & Mathai, 2006).

A carga volúmica que é aplicada nos digestores anaeróbios está relacionada com a taxa de degradação de matéria orgânica da biomassa ativa presente no seu interior. Quanto maior a taxa de degradação de matéria orgânica, maior poderá ser a carga volúmica, mantendo um bom funcionamento da digestão anaeróbia (CCE, 2000; citado por Mendes, 2014).

Na fase de arranque da digestão anaeróbia, este parâmetro é crítico, devido à biomassa presente ainda não estar adaptada ao tipo de substrato e condições ambientais. A carga volúmica deve ser função da quantidade de inóculo utilizado no arranque, devendo manter-se baixa e aumentar gradualmente, sem prejudicar a adaptação da biomassa. Esta fase varia consoante as condições ambientais e operacionais e pode ir de semanas a largos meses (CCE, 2000; citado por Mendes, 2014).

### **4.3.9 Metais alcalinos e alcalinoterrosos**

Os metais alcalinos e alcalinoterrosos, como o Sódio, Potássio, Cálcio e Magnésio podem estar presentes nos resíduos ou serem adicionados aos digestores para uma correção do pH (Souza, 1984).

Estes podem ser benéficos ao processo anaeróbio, estimulando as bactérias. No entanto, quando é feita uma adição excessiva de sais ao digestor, com o objetivo de controlar o valor de pH, pode resultar na inibição do processo anaeróbio (Silveira, 2009).

A toxicidade provocada pelo potássio pode ser limitada através da combinação dos íons cálcio com o sódio. No que respeita ao sódio, a toxicidade deste pode ser reduzida pela combinação dos íons cálcio e potássio ou até mesmo pela utilização de magnésio (Silveira, 2009).

## **4.4 FATORES QUE PREJUDICAM O PROCESSO DE DIGESTÃO ANAERÓBIA**

Existem muitas substâncias potenciais que podem estar presentes, seja como componentes de um reator de alimentação ou como subprodutos do metabolismo anaeróbico, o que pode abrandar a taxa de digestão (toxicidade) ou provocar a paragem do processo (inibição) (Mara & Horan, 2003).

As condições tóxicas normalmente ocorrem devido à sobrealimentação e excessiva adição de agentes químicos. As condições tóxicas podem também ocorrer por contribuição de águas residuais industriais com compostos tóxicos (Mendes, 2014).

### **4.4.1 Metais Pesados**

Embora os metais pesados sejam necessários para a síntese celular dos microrganismos envolvidos na digestão anaeróbia, estes mesmos microrganismos têm limites de tolerância para o teor dos mesmos. Ultrapassar esses valores resulta em toxicidade e pode estar na origem de falhas no processo de digestão anaeróbia (Mendes, 2014).

Os principais metais pesados presentes nas redes de drenagem de águas residuais são o crómio, ferro, cobalto, cobre, zinco, cádmio e níquel podendo, a presença destes, tornar-se problemática a partir de determinadas concentrações. As lamas resultantes do tratamento de águas residuais municipais têm, normalmente, concentrações baixas de metais. Contudo, havendo contribuições

significativas de descargas industriais, esta situação pode provocar o aumento dos seus níveis de toxicidade.

O efeito de estimulação ou inibição dos microrganismos anaeróbios é determinado pela concentração total de metais, as formas químicas em que se encontram os metais, pH e potencial redox (Zayed & Winter, 2000). Existe uma proporcionalidade inversa entre a solubilidade dos metais e os valores de pH, ou seja, quando estes últimos diminuem, a solubilidade aumenta (Lopes *et al.*, 2007; citado por Silveira, 2009). Assim sendo, as bactérias fermentativas e as bactérias acetogénicas são mais resistentes à toxicidade causada por metais pesados do que as bactérias metanogénicas (Zayed & Winter, 2000).

#### **4.4.2 Ácidos Gordos Voláteis (AGV)**

Os ácidos gordos voláteis são os principais produtos intermediários formados durante o processo de digestão anaeróbia (Gerardi, 2003).

A fração não dissociada tem a capacidade de atravessar as membranas celulares, dissociando-se no interior. Quando esta fração sofre um aumento, provoca uma descida do pH intracelular. Esta situação provoca um aumento da toxicidade dos AGV. Para além do pH, a concentração inibitória dos AGV depende também da capacidade tampão no reator, sendo esta uma propriedade que mantém a neutralidade do pH.

Os ácidos gordos voláteis podem acumular-se nos digestores anaeróbios devido a diversos fatores, tais como variações bruscas de pH e de temperatura, sobrecarga orgânica (aumentos súbitos na carga orgânica aplicada), sobrecarga hidráulica (aumentos repentinos na vazão de despejo, a níveis que resultem em lavagem das bactérias metanogénicas) e sobrecarga tóxica (aumentos repentinos nas concentrações de compostos potencialmente tóxicos à digestão) (Souza, 1984).

Nestes casos, as bactérias metanogénicas são incapazes de remover o hidrogénio e os AGV's produzidos pelas bactérias fermentativas e acetogénicas. Face a esta situação, ocorre a acumulação de ácidos no digestor que leva a uma descida do pH a níveis que podem ser inibitórios para as bactérias metanogénicas, que ficam ainda mais inibidas. A acumulação de ácidos no digestor pode resultar na paragem de todo o processo (Silveira, 2009).

### 4.4.3 Oxigénio

Os microrganismos anaeróbios são muito sensíveis à exposição ao oxigénio, sobretudo as bactérias metanogénicas. O oxigénio pode causar uma irreversível dissociação de algumas enzimas.

Por outro lado, a produção de metano é possível, mesmo na presença de oxigénio, porque muitas das bactérias fermentativas envolvidas nas etapas iniciais são facultativas e irão consumir o oxigénio que poderá estar presente no digestor (Mara & Horan, 2003).

### 4.4.4 Amónia

A concentração de amónia livre depende essencialmente da concentração total de amónia ( $\text{NH}_4^+ + \text{NH}_3$ ), da temperatura, do pH e da pressão do  $\text{CO}_2$  (Vavilin *et al.*, 1995).

Um aumento de temperatura ou uma subida do valor de pH provocam um aumento do nível de toxicidade associada ao aumento da fração de amónia livre comparativamente à sua forma ionizada (Borja *et al.*, 1996; citado por Silveira, 2009). Uma diminuição da pressão parcial de  $\text{CO}_2$  tem o mesmo efeito (Vavilin *et al.*, 1995).

A amónia é libertada pela fermentação de proteínas e aminoácidos e a repartição de metilamina e outros compostos azotados. Apesar de a amónia atuar para tamponar alguma da acidez gerada pela digestão anaeróbia e ser benéfica para as bactérias anaeróbias quando se encontra em baixas concentrações, ela pode levar à inibição do processo de digestão quando se encontra em concentrações elevadas, devido à sensibilidade das bactérias metanogénicas.

Silveira (2009) afirma que a inibição das bactérias metanogénicas provoca a acumulação de AGV's provocando uma instabilidade no processo de digestão. Essa acumulação de AGV's provoca uma descida do pH e, conseqüentemente, diminui a concentração de amónia livre (Vavilin *et al.*, 1995). Com esta sucessão de fenómenos, o processo de digestão mantém-se estável, embora com uma produção de metano inferior devido à inibição das bactérias metanogénicas.

#### 4.4.5 Sulfuretos

As formas inorgânicas de enxofre presentes na alimentação do digestor, principalmente o sulfato, são rapidamente convertidas pelas bactérias redutoras de sulfato para as formas reduzidas de sulfureto ( $S_2^-$ ) e sulfureto de hidrogénio ( $H_2S$ ), que são classificados como inibidores importantes da digestão anaeróbia.

De um modo geral, a redução do sulfato nos digestores anaeróbios é um processo considerado indesejável, dado que a formação de sulfureto causa uma série de problemas como toxicidade, corrosão, odor, aumento da CQO efluente, além de diminuir a qualidade e quantidade do biogás produzido.

Em certas estações de tratamento, para combater a formação de sulfuretos, é utilizado não só Cloreto Férrico, mas também uma ínfima percentagem de oxigénio (<1%), sendo que na utilização deste último tem que haver um maior controlo devido ao risco de, não só provocar a total inibição do processo de digestão anaeróbia, mas também haver uma possível explosão do digestor anaeróbio na presença de  $O_2$ .

#### 4.4.6 Cianetos

O cianeto é classificado como um inibidor de enzimas irreversível, sendo considerado um composto tóxico. A inibição do cianeto ocorre através do bloqueio do local ativo das enzimas e, portanto, limita a absorção de substrato.

Algumas pesquisas sobre digestão anaeróbia mostram que, entre as fases do seu processo, a metanogénese é a mais sensível à toxicidade do cianeto. Por outro lado, a toxicidade dos cianetos pode ser reduzida em certo grau pela adição de ferro, devido à formação de compostos não tóxicos como ferricianeto de potássio (Souza, 1984).

### 4.4.7 Nitratos

A adição de nitratos aos digestores pode resultar em conversões elevadas dos mesmos a  $N_2$  (gás azoto), através da desnitrificação. A inibição da metanogénese geralmente é mínima a concentrações de nitrato correspondentes a 10 mgN/l mas quando agitem os 50 mg/l, a inibição é certa (Souza, 1984).

### 4.4.8 Tensioativos

Souza (1984) refere que os tensioativos (ou surfatantes) são os agentes ativos dos detergentes, sendo geralmente constituídos por sulfonatos de alquilbenzeno (detergentes não biodegradáveis) ou por sulfonatos de alquilbenzeno linear (detergentes biodegradáveis).

Estes últimos, embora sejam aerobicamente biodegradáveis, degradam-se com alguma dificuldade sob condições anaeróbias.

## 4.5 PRINCIPAIS MODELOS DE DIGESTÃO

Os modelos de digestão anaeróbia de lamas dividem-se em três configurações: baixa carga, alta carga e duas fases (utilizando dois digestores):

### 4.5.1 Digestão anaeróbia em baixa carga

Também denominada de digestão não contínua ou convencional (Gurjar, 2001), a digestão anaeróbia em baixa carga ocorre normalmente num tanque com forma cilíndrica, com fundo inclinado e cobertura plana ou côncava, como demonstra a **Figura 10** (Turovskiy & Mathai, 2006).

O conteúdo do digestor geralmente não é aquecido e não tem agitação, o que leva a que ocorra estratificação da lama em quatro zonas distintas. Uma camada de escumas, uma camada de

sobrenadante, uma camada ativa de digestão de lamas e uma camada de sólidos digeridos e inertes (Qasim, 1999).

A alimentação da lama é feita intermitentemente, assim como a remoção das lamas digeridas e sobrenadantes, que é feita periodicamente. É um modelo de digestão caracterizado por ser pouco eficiente, instável e com necessidade de tempos de digestão longos, entre 30 e 60 dias (Qasim, 1999).

O biogás é produzido na camada ativa de digestão, que corresponde a menos de 50% do volume total do digestor, sobe à superfície do líquido e é recolhido na cobertura do digestor (Tchobanoglous & Burton, 1991). Mendes (2014), refere que, devido a todas estas limitações, a digestão anaeróbia em baixa carga é considerada apenas para ETAR de pequena dimensão.

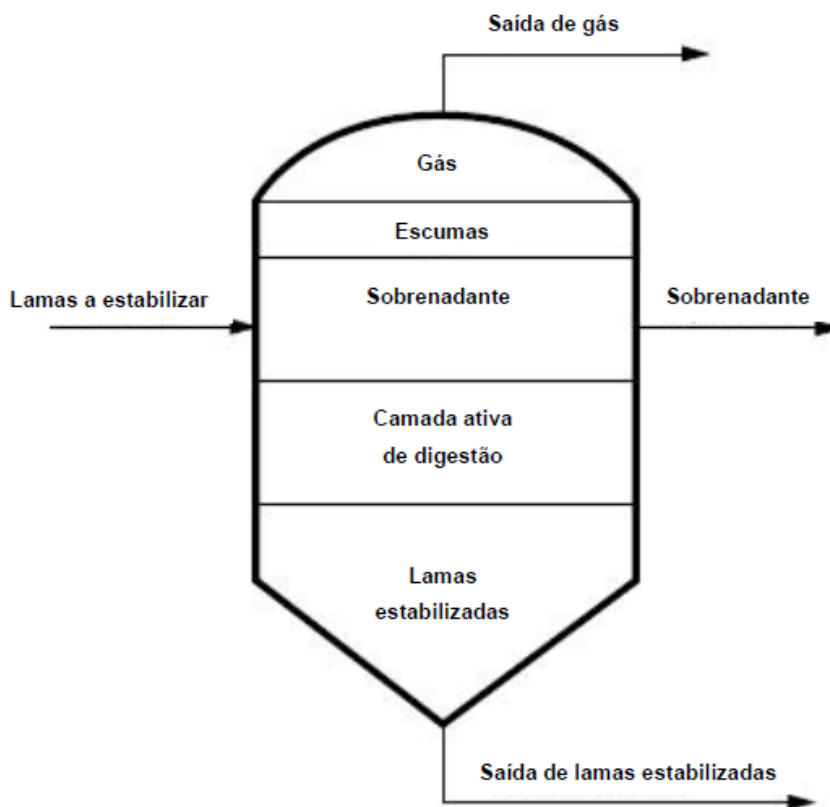


Figura 10 - Digestão anaeróbia em baixa carga (Fonte: Turovskiy & Mathai, 2006)

### 4.5.2 Digestão anaeróbia em alta carga

O modelo de digestão anaeróbia em alta carga, esquematizado na **Figura 11**, difere da digestão em baixa carga principalmente pela maior carga volúmica afluyente, agitação e aquecimento do conteúdo do digestor, e alimentação contínua de lamas. Estes fatores proporcionam condições de funcionamento uniformes em todo o volume do digestor, resultando num menor volume de digestão, maior estabilidade e eficiência do processo (Tchobanoglous & Burton, 1991).

O aquecimento das lamas é essencial para aumentar a taxa de crescimento dos microrganismos, taxa de digestão e produção de biogás. A digestão anaeróbia em alta carga pode ser operada em gamas de temperatura mesófilas (30 a 38°C) ou termófilas (50 a 57°C) (Turovskiy & Mathai, 2006).

A agitação das lamas contribui para a redução da estratificação térmica e física, dispersão das lamas para melhor contacto com a biomassa ativa, reduz a formação de escumas, dilui as substâncias inibidoras ou o pH e temperatura de lamas afluentes, aumenta o volume efetivo de digestão do tanque face à digestão em baixa carga, permite que os gases provenientes da reação se separem mais facilmente, e mantém em suspensão mais matéria inorgânica, que tem tendência para assentar. A agitação de lamas geralmente é feita por recirculação do biogás, recirculação de lamas ou agitação mecânica (Turovskiy & Mathai, 2006).

A alimentação contínua a um digestor anaeróbio de alta carga é benéfica, pois contribui para um funcionamento em condições mais estáveis e constantes. Os microrganismos metanogénicos são sensíveis a alterações às condições de funcionamento. No entanto, neste modelo de digestão, não existe a camada de sobrenadante e somente 50% dos sólidos voláteis serão destruídos (Gurjar, 2001).

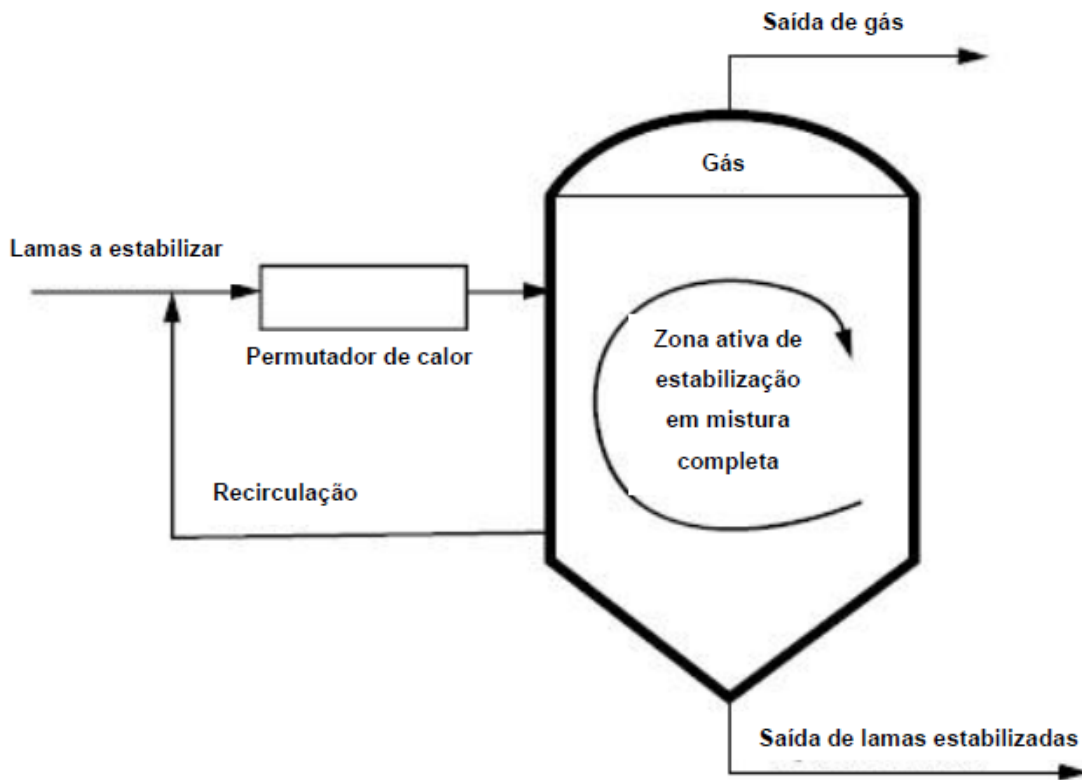


Figura 11 - Digestão anaeróbica em alta carga (Fonte: Turovskiy & Mathai, 2006)

### 4.5.3 Digestão anaeróbica em duas fases

Tchobanoglous & Burton (1991) referem que, neste modelo, existe um digestor primário de alta carga que é acoplado em série com um segundo digestor. Neste processo, o primeiro tanque é usado para a digestão, é aquecido e equipado com instalações para promover a agitação.

O segundo tanque não tem qualquer sistema de aquecimento ou agitação, sendo apenas usado para o armazenamento e concentração de lamas digeridas e para a formação de um sobrenadante relativamente límpido.

Evidenciado na **Figura 12**, ambos os tanques são idênticos, logo, qualquer um dos digestores pode ser o primário. Noutros casos, o segundo tanque pode ser um tanque aberto, um tanque sem aquecimento ou uma lagoa de lamas (Tchobanoglous & Burton, 1991).

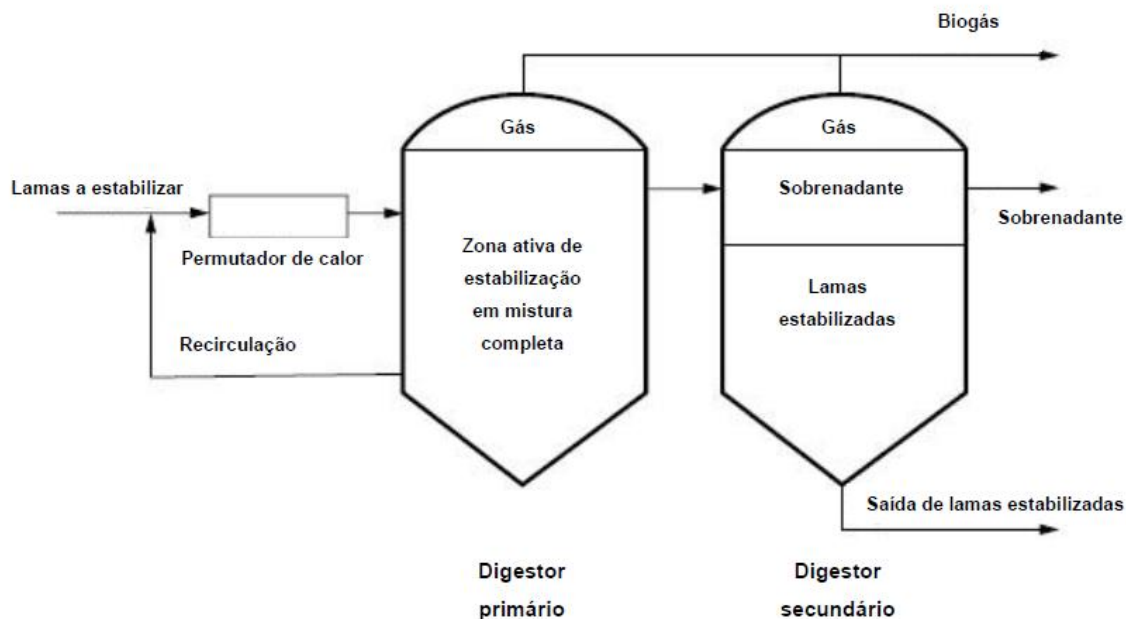


Figura 12 - Digestão anaeróbia em duas fases (Fonte: Turovskiy & Mathai, 2006)

#### 4.6 DIGESTORES ANAERÓBIOS

O digestor anaeróbio é um equipamento utilizado para o processamento da matéria orgânica que funciona como um digestor químico em que as reações químicas são de origem biológica, feitas através de bactérias que digerem a matéria orgânica em condições anaeróbias.

Um dos objetivos principais deste equipamento é produzir o máximo de volume possível de biogás, no qual também é possível produzir outros produtos com qualidade através das lamas resultantes, como os fertilizantes ou o biocarvão. Em situação de normal funcionamento, um digestor anaeróbio pode proporcionar uma redução de 60 a 80% da matéria orgânica (Adene, 2003; citado por Crespo, 2013).

Existem dois tipos básicos de digestores que podem ser utilizados para processos de digestão anaeróbia, denominados de processos em contínuo e descontínuo.

#### 4.6.1 Processo em Contínuo

Os sistemas em contínuo são, atualmente, os mais utilizados. Nestes sistemas, a matéria orgânica está continuamente a ser adicionada ao digestor com conseqüente saída contínua de matéria tratada, permitindo que o volume se mantenha constante ao longo do tempo (Crespo, 2013).

Como a entrada e saída de lamas são feitas em simultâneo, visto o reator estar a funcionar a nível constante, as partículas de lamas têm no geral um tempo de retenção médio igual dentro do digestor (Mendes, 2014). Nesse sentido, todas as fases da digestão anaeróbia ocorrem em simultâneo, produzindo biogás de forma contínua.

Os sistemas de digestão anaeróbia contínuos dividem-se em dois grupos, digestores de matéria suspensa e matéria fixa, sendo a principal diferença entre eles a forma de retenção da biomassa.

##### 4.6.1.1 Reatores de Matéria Suspensa

Este tipo de digestor anaeróbio é o mais indicado para o tratamento de resíduos semi-sólidos, como as lamas de ETAR. Pode ser dotado de agitação e de aquecimento de lamas.

A biomassa encontra-se suspensa no líquido do digestor, de tipo fechado com alimentação semi-contínua ou contínua.

Os modelos mais comuns deste tipo de digestor encontram-se na seguinte **Figura 13**.





Figura 13 - Modelos de reatores anaeróbios de matéria em suspensão mais comuns (Fonte:CCE, 2000; citado por Mendes, 2014)

#### 4.6.1.2 Reatores de Matéria Fixa

Os digestores de matéria fixa são particularmente indicados para o tratamento de resíduos de maior solubilidade. Este tipo de digestores usa um meio de suporte para que as bactérias se fixem, aumentando assim o tempo de retenção da biomassa. Por ser um processo com retenção de biomassa, permite aplicar cargas orgânicas bastante superiores às aplicadas nos digestores anaeróbios de mistura completa. O tempo de retenção de sólidos é elevado e o efluente tratado apresenta geralmente baixos teores de sólidos devido ao risco de colmatção.

Assim sendo, estes reatores de biomassa fixa não são utilizados na etapa de estabilização de lamas resultantes do tratamento de águas residuais em ETAR municipais (Mendes, 2014). Os modelos mais comuns deste tipo de digestor encontram-se na seguinte **Figura 14**.



**Figura 14** - Modelos de reatores anaeróbios de matéria fixa mais comuns (Fonte: CCE, 2000; citado por Mendes, 2014)

#### 4.6.2 Processo em Descontínuo (ou “Batch”)

No processo em descontínuo ou “*batch*”, a matéria orgânica (afluente) é introduzida no digestor, ficando retida durante um determinado período de tempo até ao final da degradação. Neste processo, as diferentes fases de degradação ocorrem sequencialmente e a produção de biogás é processada de forma intermitente. Quando esse período de residência de lamas acaba, parte destas são retiradas e é introduzida uma nova quantidade de lamas, repetindo-se o processo.

Os sistemas em descontínuo podem não ser os mais utilizados, no entanto, a simplicidade, facilidade de operação e baixos custos de investimento, tornam estes sistemas atrativos para os países em desenvolvimento (Crespo, 2013). Por outro lado, os processos descontínuos apresentam normalmente produções de biogás inferiores aos processos contínuos, isso deve-se à dificuldade na fase de arranque e ao aparecimento de canais preferenciais na massa de resíduos, devido à reduzida mistura, levando assim a uma desvantagem significativa para estes processos (Crespo, 2013). Os modelos mais comuns deste tipo de digestor encontram-se na **Figura 15**.




Figura 15 - Tipos de digestores anaeróbios descontínuos (Fonte: Vandevivere *et al.*, 2001; citado por Crespo, 2013)

#### 4.6.3 Escolha do tipo de reator

As diversas características do resíduo influenciam a escolha do tipo de reator. A Tabela 5 evidencia as principais diferenças operacionais dos principais reatores que podem ser utilizados num processo de digestão anaeróbia.

Tabela 5 - Condições operacionais das várias configurações de reatores anaeróbios (Mara & Horan, 2003)

Tipo de reator	Alimentação (kg CQO/m <sup>3</sup> .dia)	TRH (h)	Remoção CQO (%)
Reator de mistura completa	1-5	240-360	60-80
Reator anaeróbio de contacto	1-6	24-120	70-95
Reator anaeróbio descontínuo sequencial	1-10	6-24	75-90
Reator de filtro anaeróbio	2-15	10-85	80-95
Reator de leito fluidizado	2-50	1-4	80-90
Reator UASB	2-30	2-72	80-95
Reator com anteparas	3-35	9-32	75-95
Digestão anaeróbia em 2 fases	5-30	20-150	70-85

De referir que, normalmente, se opta pela inclusão de DA em ETAR que abrangem populações iguais ou superiores a 50.000 hab.eq, devido ao elevado custo de exploração deste processo (Rocha, 2013).

## 5 REDES NEURONAIS ARTIFICIAIS


Neste capítulo, faz-se uma descrição das Redes Neurais Artificiais, sendo estas inspiradas nas Redes Neurais Biológicas para resolver problemas de predição. Silva (2013) refere que, as Redes Neurais Artificiais (RNA) são modelos matemáticos ou ferramentas computacionais que operam de forma análoga aos processos biológicos de um cérebro, possuindo capacidade para entender relações complexas existentes num determinado conjunto de dados. Estas redes são constituídas por unidades de processamento (nós ou neurónios), ligações entre estas, algoritmos de treino e algoritmos de ativação.

De acordo com Haykin (1999) e citado por Matos (2008), as RNA podem ser definidas como sendo um processador massivamente distribuído em paralelo constituído por unidades de processamento simples, tendo a propensão natural para armazenar conhecimento experimental e torná-lo disponível para ser utilizado. A semelhança relativamente ao modelo biológico compreende dois aspetos:


- O conhecimento é adquirido pela rede a partir do meio envolvente através de um processo de aprendizagem;
- As intensidades das ligações entre neurónios, conhecidas como pesos sinápticos, são usadas para armazenar o conhecimento adquirido.

Citando Rocha (2013) e referido em Moreira (1997), é feita a seguinte comparação: o sistema nervoso central biológico recebe informação do exterior, armazenando e processando essa informação, que depois é transmitida uma resposta/reacção para o exterior. A observação do desempenho que este apresenta tem revelado uma extraordinária capacidade para executar tarefas de grande complexidade, tais como, o processamento em paralelo da informação, a memória associativa e a capacidade para classificar e generalizar conceitos.

Na **Figura 16** e na **Figura 17** são evidentes as semelhanças que existem entre o modelo biológico e o modelo artificial.



**Figura 16** - Rede Neuronal Biológica (Fonte: Greenspine.ca, 2015)




**Figura 17** - Rede Neuronal Artificial (Fonte: Codeproject.com, 2012)

Segundo Rocha (2013), matemáticos e cientistas, numa tentativa de compreender o funcionamento do cérebro humano, desenvolveram modelos matemáticos capazes de imitar a capacidade de generalização e reconhecimento de padrões do cérebro humano. Estes modelos matemáticos, quando devidamente treinados, são capazes de compreender padrões subjacentes a um determinado conjunto de dados de aprendizagem e podem generalizar e fornecer informação fiável e precisa em relação aos dados que não foram vistos anteriormente pelo modelo. Este processo é semelhante à maneira como o cérebro humano assimila e regista determinados padrões na sua memória e reconhece novos padrões que são semelhantes aos padrões anteriormente observados (Lingireddy & Brion, 2005).

A utilidade dos modelos de redes neuronais reside no facto de poderem ser usadas para inferir uma função não-linear apenas a partir de observações. Isto é particularmente útil em aplicações nas quais a complexidade dos dados ou das tarefas a serem processados torna a modelação de tal função impraticável (Rocha, 2013).

## 5.1 MODELO BIOLÓGICO

O neurónio é a unidade base do sistema nervoso. São unidades celulares independentes que constituem o córtex cerebral, que comunicam entre si através de ligações sinápticas, também designadas por sinapses. Todas as sensações, pensamentos e sentimentos são resultado de sinais que atravessam e são processadas pelos neurónios (Lingireddy & Brion, 2005). Composto por cerca de dez mil milhões de neurónios, cada neurónio pode estabelecer ligações sinápticas com cerca de dez mil outras células (Matos, 2008). Os neurónios diferem segundo as suas funções e localização, contudo, podemos afirmar que o neurónio típico (**Figura 18**) apresenta três componentes: o corpo celular ou soma, que inclui o núcleo celular, as dendrites e o axónio.



**Figura 18** – Esquema representativo de um neurónio biológico (Fonte: Sobiologia.com.br, 2015)

Como refere Rocha (2013), os neurónios apresentam uma estrutura simples em que cada um permite efetuar três funções básicas: entrada, processamento e saída de sinais nervosos. As dendrites são conexões através das quais os neurónios recebem os estímulos nervosos de outros neurónios ou órgãos sensoriais que depois são processados no núcleo do neurónio. Estes impulsos passam através do corpo da célula e são transmitidos por um único axónio para outro neurónio ou outros órgãos. A região na qual o sinal passa do axónio de um neurónio (pré-sináptico) para a dendrite de outro neurónio (pós-sináptico) é designada por sinapse. O tamanho de uma sinapse altera-se em função da frequência com que os sinais passam através dessa área. O tamanho da

sinapse controla a intensidade do sinal transmitido aos neurónios adjacentes. As sinapses não são ligações físicas, mas sim ligações químicas temporárias que acontecem por intermédio de substâncias denominadas por neurotransmissores.

A comunicação é realizada unidireccionalmente por sinais nervosos elétricos (predominantemente no interior de cada neurónio) e químicos através de impulsos. Estes últimos são desencadeados em cada neurónio sempre que um certo potencial de ativação é ultrapassado em resultado da receção de um ou mais sinais nervosos nas sinapses. De referir que os sinais nervosos são, em geral, amplificados (ou pesados) de forma diferenciada ao atravessar as diferentes sinapses de um neurónio (Moreira, 1997).

De acordo com Matos (2008) e citado por Rocha (2013), quando, em 1943, McCulloch & Pitts conceberam o seu modelo computacional de um neurónio biológico e lançaram as fundações das RNA, pretendiam desenvolver um sistema que permitisse imitar o funcionamento do cérebro humano. O desenvolvimento destes sistemas foi acompanhado pelo progresso do conhecimento na área da neurologia, o que contribuiu para a criação de modelos com características semelhantes aos sistemas biológicos. Assim como o sistema nervoso, a estrutura de uma rede neuronal é composta por unidades conectadas designadas como nós ou neurónios, em que cada um recebe valores de *inputs*, efetua cálculos relativamente simples com os mesmos e gera um *output*. Assim sendo, o valor de *output* de um neurónio é transmitido como um dos *inputs* de outro neurónio ou como *output* final de todo o sistema. No seu conjunto, uma RNA é um sistema que recebe *inputs*, computa-os e devolve um ou mais *outputs* (Palisade, 2013). A arquitetura típica das redes neuronais apresenta diferentes camadas, nomeadamente, a camada de entrada ou de *inputs*, a camada de saída ou de *output* e, pelo menos, uma camada intermédia ou oculta.

Apesar das RNA demonstrarem potencialidades interessantes, o sistema nervoso é uma rede de complexidade admirável, incomparavelmente superior às RNA modernas sob todos os pontos de vista. As construções mentais derivam do processamento de informação a vários níveis, desde interações moleculares até circuitos inter-regionais e ao próprio sistema nervoso central. Tal como os neurónios artificiais são básicos quando comparados com os biológicos, também as RNA são básicas quando comparadas com os circuitos locais encontrados no cérebro (Haykin, 1999; citado por Matos, 2008).

## 5.2 CARACTERÍSTICAS E DESCRIÇÃO DA RNA

De acordo com Fernandes (2014), várias características das RNA fazem destas uma ferramenta bastante útil e atrativa na construção de um modelo de previsão. Em oposição aos métodos tradicionais de previsão, as RNA são um método “orientado para os dados” e que se adaptam a estes, sendo, então necessários poucos pressupostos do modelo em estudo. Elas aprendem a partir dos exemplos e capturam relações funcionais existentes nos dados fornecidos, mesmo que essas mesmas relações sejam desconhecidas ou difíceis de descrever.

Deste modo, as RNA são bastante apropriadas para o uso em problemas cujas soluções requerem conhecimentos que sejam difíceis de especificar mas que existam dados ou observações suficientes.

Outra particularidade das RNA, é a de serem um método não linear. Os modelos de previsão são, na sua maioria, compostos por métodos estatísticos lineares. Os modelos lineares possuem grandes vantagens tais como: a sua facilidade de abordagem e implementação.

Contudo, os métodos de previsão lineares podem ser totalmente inapropriados em sistemas com um mecanismo não linear. Os problemas de sistemas reais são muitas vezes não lineares, deste modo, como as RNA são abordagens não lineares e direcionadas para os dados, são capazes de modelar sistemas não lineares sem conhecimento, à partida, das relações existentes entre as entradas e as saídas.

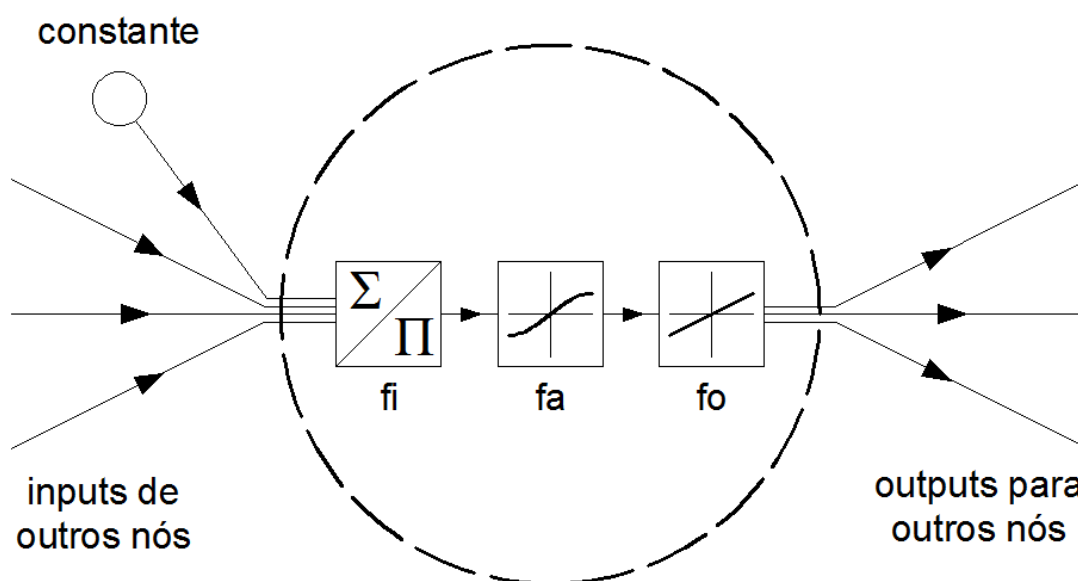
## 5.3 ESTRUTURA DE UMA RNA

Uma rede neuronal é, por definição, um sistema de elementos de processamento simples, neurónios ou nós, que estão ligados a uma rede por um conjunto de pesos sinápticos. A rede é definida pela sua arquitetura, pela magnitude dos pesos e pelo modo de operação dos elementos de processamento (Rocha, 2013).

O neurónio é um elemento de processamento que recebe um número de *inputs*, pesa-os, soma-os, adiciona constantes e utiliza o resultado como o argumento para uma função de transferência, que resulta no *output* do neurónio. Os neurónios estão interligados por canais de comunicação

(conexões) que transportam dados numéricos e operam apenas com os seus dados locais e com os valores de entrada que recebem através dessas conexões. Todos os nós da rede produzem uma soma ponderada dos seus *inputs*, transformam esse valor através da função de transferência e transmitem um valor de *output*.

De acordo com Matos (2008), o nó (**Figura 19**) é a unidade base de uma RNA. Como tal, é necessário conhecê-lo para compreender o funcionamento da totalidade da rede.




**Figura 19** - Modelo de um nó de uma RNA (Fonte: Matos, 2008)

O nó apresentado recebe ligações de três nós a montante e está ligado a três nós para jusante. As funções de transformação que podem ocorrer no interior do nó são as seguintes:

- Função de *Input* (*fi*) – normalmente, corresponde ao somatório dos *inputs* num único valor real, mas outras conceções podem ser aplicadas (produto).
- Função de ativação (*fa*) – esta função faz corresponder o resultado da função de *input* a um nível de ativação do nó, variando normalmente entre -1 e 1 ou entre 0 e 1.
- Função de *output* (*fo*) – aplica-se esta função para produzir um sinal a partir do nível de ativação. Na maioria dos casos esta função não é aplicada, pois, geralmente, transmite-se simplesmente o nível de ativação.

Conforme referido por Silva (2013) e citado por Rocha (2013), existem vários tipos de RNA, diferindo na estrutura, no género de computações realizadas dentro dos neurónios ou até nos algoritmos de treino. No entanto, as redes mais comuns são constituídas por neurónios ordenados em camadas, fazendo com que cada neurónio receba, como *inputs*, apenas os *outputs* dos neurónios das camadas anteriores ou *inputs* externos, ou seja, não existem ligações entre neurónios da mesma camada. Um desses exemplos é o da rede multicamada, demonstrada na **Figura 20**. As redes neuronais conseguem modelar funções de, praticamente, qualquer complexidade, estando o número de camadas e de nós em cada camada, associado à complexidade da função.



**Figura 20** - Exemplo de uma rede multicamada (Fonte: Lillesand *et al.*, 2002)

O conhecimento destas redes é adquirido a partir de condições reais (conjunto de dados), através de um processo de aprendizagem (algoritmo de treino). Ou seja, para determinar os valores dos pesos sinápticos é necessário um conjunto de dados que permitam aferir a relação entre os valores de entrada da rede e os valores de saída.

## 5.4 APRENDIZAGEM (TREINO)

A propriedade mais importante das RNA é a capacidade de aprender e com isso melhorar seu desempenho, isto é feito através de um processo iterativo designado de treino. O treino consiste na modificação dos pesos das conexões entre os neurónios, os pesos iniciais (sinapses) são modificados de forma iterativa, por um algoritmo de treino.

O algoritmo de treino é um conjunto de regras bem definidas para a solução de um problema de treino. Existem algoritmos de treino específicos para determinados modelos de RNA, estes algoritmos diferem entre si principalmente pelo modo como os pesos são modificados (Moreira, 1997).

### 5.4.1 Treino supervisionado

O processo de aprendizagem de uma RNA pode ser realizado sob supervisão. Neste tipo de aprendizagem são conhecidas, *a priori*, as respostas corretas correspondentes a um certo conjunto de dados de entrada. Ainda de acordo com Moreira (1997), é de destacar os seguintes algoritmos de treino com supervisão, como sendo os mais utilizados:

- Regra de aprendizagem de Widrow-Hoff ou método do gradiente aplicado em redes neurais lineares;
- Treino por retro propagação do erro (*error backpropagation*) que constitui uma generalização da anterior regra a redes lineares ou não lineares e com três ou mais camadas;
- Método do gradiente e seus aperfeiçoamentos. De referir a existência de técnicas destinadas a melhorar a convergência destes métodos, tais como, a técnica do momento e da taxa adaptativa de aprendizagem;
- A aprendizagem através do método de Levenberg-Marquardt aplicável a redes não lineares;
- A aprendizagem recorrendo a técnicas heurísticas, como por exemplo, os algoritmos evolutivos.

O algoritmo utilizado pode classificar a rede em que se aplica. As redes mais conhecidas, não lineares com camadas ocultas e com alimentação direta, são denominadas por redes de retro propagação com alimentação direta (*standart feedforward backpropagation networks*).

#### 5.4.2 Treino não supervisionado

Como refere Moreira (1997) e citado por Pires (2014), a aprendizagem sem supervisão é, essencialmente, aplicada em sistemas com memória associativa e para reconhecimento de padrões. Nestas redes o treino é realizado sem se conhecer antecipadamente as respostas consideradas corretas. Os algoritmos de treino sem supervisão mais conhecidos são:


- Algoritmos de estimulação pela entrada (*reinforcement algorithms*) também designados por algoritmos de aprendizagem associativa. Neste tipo de algoritmos, a entrada de cada vetor na rede estimula um reajuste dos pesos, de modo a tornar favorável uma saída com determinadas características. As regras de Hebb, de Instar e de Outstar são alguns exemplos deste tipo de algoritmos;
- Algoritmos de aprendizagem competitiva, tais como a regra de Kohonen. Neste caso, as unidades computacionais de saída da rede competem entre si pelo direito de serem ativadas (isto é, fornecerem uma dada resposta) quando uma dada entrada é fornecida. Em geral só a ativação de uma única unidade de saída é autorizada.

Tal como no caso anterior, algumas redes podem ser classificadas com base no algoritmo de treino utilizado. De referir, por exemplo, as redes de Kohonen e as redes competitivas.

## 5.5 PERCEPTRÃO

O perceptrão (**Figura 21**) é um tipo de rede apenas com uma camada, sendo que neste caso, geralmente, a rede é constituída por um único neurónio e um polarizador, com pesos ajustáveis. Possui o tipo de arquitetura mais simples de rede neuronal capaz de classificar padrões linearmente separáveis (Matos, 2008).

O algoritmo de treino do perceptrão foi o primeiro modelo de treino supervisionado, isto é, para efetuar o treino é necessário deter a classificação desejada para cada um dos vetores que fazem parte dos dados. Este modelo é, também, caracterizado por ter, como função de ativação, uma função em degrau com valores binários de entrada/saída [-1,+1] (Velasco, 2007).



**Figura 21** - Representação esquemática de um perceptrão (Fonte: Silva, 2013)

Pelo teorema da convergência do perceptrão, Rosenblatt estabeleceu que caso os padrões utilizados no treino do perceptrão pertençam a duas classes linearmente separáveis, o algoritmo do perceptrão converge e posiciona a superfície de decisão no hiperplano entre essas classes (Brandão, 2014).

Mais tarde, provou-se que aumentando o número de nós, o número de classes que o perceptrão permite separar também sofre um aumento. Mesmo tendo constituído uma importante inovação, o perceptrão apresenta limitações associadas ao comportamento linear, as limitações que Minsky & Pappert formalizaram em 1969. O perceptrão foi paradigmático e é interessante na introdução a redes mais complexas, em particular ao perceptrão multicamada que, como o nome indica, é nele inspirado (Brandão, 2014).

### 5.5.1 Perceptrão Multicamada (PMC)

Este tipo de rede (Figura 22) constitui o modelo de redes neurais mais popular na literatura.

Como refere Matos (2008) e citado por Brandão (2014), a retropropagação aplicada ao (PMC), desenvolvida por Rumelhart (1986), veio resolver o problema da atribuição de crédito que descredibilizou as RNA nas décadas de 70 e 80. Um PMC é uma RNA do tipo *feed-forward*, constituída por uma camada de *input*, um número arbitrário de camadas ocultas e uma camada de *output*, organizadas sequencialmente, em que cada nó está ligado a todos os neurónios da camada seguinte.




Figura 22 - Esquema de uma rede PMC de 3 camadas. (Fonte: Silva, 2013)

Como refere Pires (2014), uma rede do tipo PMC possui três características essenciais:

- Os neurónios das camadas intermédias possuem uma função de ativação não-linear. A não linearidade é do tipo suave, ou seja, diferenciável em qualquer ponto. Um exemplo de funções com estas características, são as funções de transferência do tipo sigmoidal, como é o caso da função logística ou da tangente hiperbólica. A não-linearidade é importante, caso

contrário, a relação de entrada-saída da rede acabaria por ser reduzida à forma existente numa rede de camada única.

- A rede possui uma ou mais camadas de neurónios ocultos que não são parte nem da entrada, nem da saída da rede. Estes neurónios da camada oculta capacitam a rede a aprender tarefas complexas, extraíndo, progressivamente, as características mais significativas dos padrões de entrada.
- A rede exhibe um alto grau de conectividade determinado pelos seus pesos sinápticos. Uma modificação na conectividade da rede requer modificações nos pesos.

Trata-se, portanto, de uma generalização do perceptrão simples estudado anteriormente. O treino deste tipo de rede foi, originalmente, feito com um algoritmo de retropropagação do erro, conhecido como *backpropagation* (Velasco, 2007).

O algoritmo de retropropagação consiste numa propagação positiva do sinal funcional e numa retropropagação do erro. Quando se dá a propagação positiva do sinal funcional, todos os pesos sinápticos da rede são mantidos fixos e o seu efeito propaga-se através da rede, camada por camada, até produzir o conjunto de saída. Quando se dá a retropropagação do erro, os pesos sinápticos da rede são ajustados de acordo com uma regra de correção de erro e o sinal é propagado para trás através da rede.

Assim sendo, este algoritmo consiste em calcular o erro na saída da rede e retropropagá-lo pela rede, modificando os pesos para minimizar o erro da próxima saída. Sendo que o sinal de erro é propagado em sentido oposto ao de propagação do sinal funcional, daí a sua designação de retropropagação do erro. O algoritmo de retropropagação do erro é o algoritmo de treino supervisionado mais conhecido e utilizado.

O PMC apresenta vantagens em relação a soluções de aproximação tradicionais (polinomiais ou trigonométricas), pois a degradação da qualidade da aproximação com o aumento de dimensões do problema é bastante menor. Por outro lado, a complexidade que os PMC podem adquirir é substancial e as operações que ocorrem no interior da rede complexas, pelo que o treino, deve seguir procedimentos que evitem, tanto quanto possível, problemas na solução final (Matos, 2008).

## 5.6 TIPOS DE RNA

Existem diferentes tipologias de redes neuronais que se diferenciam pela estrutura, pelos tipos de cálculos efetuados dentro dos neurónios e pelos algoritmos de treino.

De acordo com Palisade (2013), existem fatores que determinam o comportamento da rede, tais como:

- Topologia de rede define o número de camadas ocultas e o número de nós das camadas;
- “Pesos” das conexões (um parâmetro atribuído a cada conexão) e termos de viés (um parâmetro atribuído a cada neurónio);
- Função de ativação/transferência usada para converter os *inputs* de cada neurónio no *output* correspondente.

As RNA têm capacidade de aprender as relações complexas existentes entre os dados. Por meio de uma imitação das funções do cérebro, as redes discernem padrões existentes nos dados e depois, quando são fornecidos novos dados, fazem extrapolações para gerar previsões.

Os tipos de problemas em que as RNA são empregues podem ser divididos em dois grupos gerais (Palisade,2013):

- Problemas de classificação: problemas em que se tenta determinar a que tipo de categoria pertence um item desconhecido. Exemplos: diagnósticos médicos e previsão da capacidade de pagamento de débitos.
- Problemas numéricos: situações em que é necessário prever um resultado numérico específico. Exemplos: previsão de preços de ações e previsão do nível de vendas durante um período futuro.

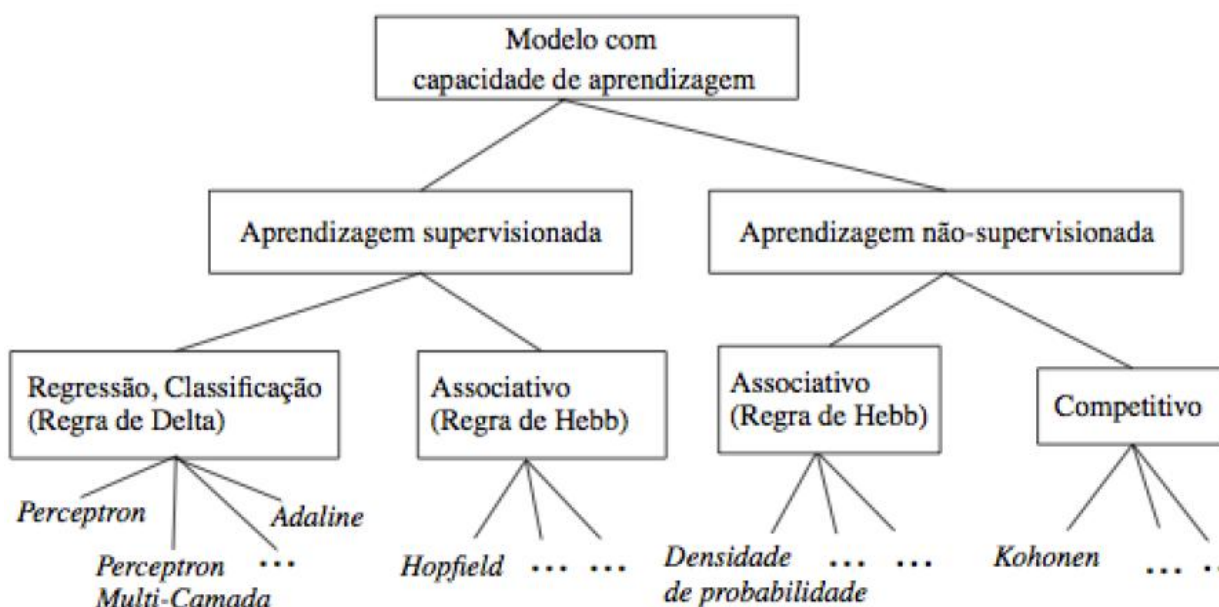
O *software* NeuralTools™ da Palisade™, que irá ser utilizado no presente trabalho, utiliza redes neuronais *Multilayer Feed-Foward* (MLFNN ou MLF) ou Perceptrão Multicamada (MLP), redes de

Regressão Generalizada (GRNN) – para previsões numéricas – e rede Probabilística (PNN ou PN) – para previsões de categoria.

Com as redes MLF é possível especificar se deve haver uma ou duas camadas de neurónios ocultos e quantos neurónios as camadas ocultas devem conter.

As redes GRNN e as redes PN interrelacionam-se estreitamente. As redes GRNN são usadas para previsão numérica/aproximação de funções, enquanto as redes PN são utilizadas para classificação/previsão de categorias. No caso das redes GRNN/PN, não é necessário tomar nenhuma decisão quanto à estrutura da rede, uma vez que estas redes sempre têm duas camadas ocultas de neurónios (Brandão, 2014).

No esquema da **Figura 23** pode-se observar a classificação quanto ao tipo de aprendizagem e quanto a tipo de regra de aprendizagem.



**Figura 23** - Classificação estrutural e funcional de redes neuronais artificiais (Fonte: Rauber, 2005; citado por Fernandes, 2014)

### 5.6.1 Redes multi-layer feedforward (MLFN)

De acordo com Rocha (2013), uma rede neuronal multicamada é tipicamente composta por camadas alinhadas de neurónios ou nós. Este tipo de sistema é capaz de efetuar aproximações de funções complexas, podendo modelar relações complexas entre variáveis independentes e uma variável dependente. Relativamente à arquitetura, estas redes apresentam uma camada de entrada (*input*), uma camada de saída (*output*) e, pelo menos, uma camada intermédia ou oculta (*hidden layer*) (Brandão, 2014).

Esta camada distribui as informações de entrada para as camadas seguintes, as camadas ocultas ou intermediárias. A última camada é camada de saída (*output*), na qual a solução do problema é obtida (Rocha, 2013). Além disso, os neurónios de uma camada estão conectados apenas aos neurónios da camada imediatamente posterior, não existindo conexões entre neurónios da mesma camada e a comunicação é efetuada unidireccionalmente.

Ainda em concordância com Rocha (2013), o número de nós na camada de entrada corresponde ao número de variáveis que serão usadas para alimentar a rede neuronal e os nós assumem o valor dos dados de entrada. Geralmente, são selecionadas as variáveis mais relevantes para o problema em estudo.

### 5.6.2 Redes de regressão generalizada (GRNN)

De acordo com Palisade (2013), as redes PNN e GRNN funcionam de forma idêntica, distinguindo-se pelo tipo de problema a que podem ser aplicadas. Se a variável dependente for categórica utiliza-se a rede PNN. Caso a variável dependente for numérica, recorre-se a uma rede GRNN. Esta última será a rede a ser utilizada devido a este caso de estudo utilizar a variável dependente numérica.

As redes GRNN são estruturadas da seguinte maneira: uma camada de *inputs*, duas camadas ocultas e uma camada de *output*. Na camada de *input* cada nó representa uma variável de entrada. A primeira camada oculta – camada padrão – contém um nó para cada caso de treino. A segunda camada oculta – camada de soma – é constituída por nós de numeradores e denominadores e o seu tamanho depende de diversos fatores relacionados com os dados de treino. Cada neurónio da camada de padrões calcula a sua distância em relação ao caso apresentado. Os valores passados aos

nós de numeradores e denominadores são funções da distância e do valor dependente. Os nós da camada de soma efetuam a soma de seus *inputs*, enquanto o nó de *output* os divide para gerar a previsão. Quando um caso é apresentado à rede, esta calcula o valor dependente previsto utilizando os valores dependentes de cada caso de treino, sendo que os casos de treino mais próximos contribuem de forma mais significativa ao valor do *output* (Rocha (2013), citado por Brandão (2014)).

De acordo com a Palisade (2013) e citado por Rocha (2013), quanto mais próximo um caso conhecido está de um desconhecido, mais peso é dado ao estimar o valor dependente desconhecido. São nestes conceitos intuitivos que a GRNN se baseia.

A função de distância calculada nos neurónios da camada padrão usa fatores de suavização. O treino de uma rede GRNN consiste em otimizar os fatores de suavização para minimizar o erro no conjunto de treino. A medida de erro, usada durante o treino, para avaliar diferentes conjuntos de fatores de suavização é o erro médio quadrático (EMQ) (Rocha, 2013).

### 5.6.3 Comparação entre redes MLF e PN/GRN

Em conformidade com Palisade (2013), as vantagens das redes GRNN/PNN, quando comparadas às MLFNN, são as seguintes:

- Treino rápido;
- Não necessitam de configuração;
- Não requerem especificação da topologia (número de camadas ocultas e nós);
- Além de efetuar classificação, as redes PNN retornam as probabilidades de o caso se enquadrar em diferentes categorias dependentes.

Por outro lado, as redes MLF oferecem outro tipo de vantagens, tais como:

- São menores, portanto as previsões são mais rápidas;

- São mais confiáveis fora dos intervalos dos dados de treino (por exemplo, quando o valor de uma variável independente não pertence à gama de valores usados nos dados de treino). Contudo a previsão com redes MLF fora do intervalo dos dados de treino é arriscada.
- São capazes de fazer generalizações a partir de conjuntos de treino muito pequenos.

## 5.7 FASES DA RNA PARA A RESOLUÇÃO DE PROBLEMAS DE PREVISÃO

A implementação de uma RNA abrange 4 fases distintas: preparação dos dados, treino da rede, teste e previsão.

### 5.7.1 Fase de Preparação dos dados

A seleção e o tratamento de informação são a base de qualquer aplicação de redes neuronais, em que o processo de preparação dos dados é crucial para o sucesso da aplicação (Matos, 2008).

Uma aplicação bem-sucedida de um modelo de RNA solicita uma estudo adequado dos dados de *input*, assim como, uma sólida compreensão do processo a ser modelado, que é essencial para a correta seleção das variáveis de entrada. Esta compreensão fundamental não só ajudará na escolha de dados de *input* adequados, mas também ajudará a evitar a seleção de dados com erros ou dados menos fiáveis, que poderão confundir o processo de treino (Lingireddy & Brion., 2005; citado por Rocha, 2013).

Assim, numa primeira fase da metodologia, prevê-se uma análise criteriosa dos dados disponíveis, identificando-se quais os objetivos a alcançar. Em função dos dados disponíveis e dos objetivos traçados, deverá ser examinada a adequação e aplicabilidade das RNA ao problema.

De acordo com Rocha (2013), os dados disponíveis são subdivididos em dois ou três conjuntos. O conjunto com a maior quantidade de dados (entre 70 a 80%) é usado para o treino, outro conjunto é usado para o teste e, se necessário, poderá existir um terceiro conjunto para validação.

O conjunto de treino é composto por casos conhecidos que serão usados no processo de aprendizagem da rede, isto é, para ajustar os parâmetros ou pesos da rede. O conjunto de teste é utilizado para avaliar a capacidade de generalização da rede. O conjunto de validação permite confirmar resultados considerados aceitáveis na fase de teste, atestando a capacidade de generalização da rede.

A quantidade de dados disponíveis é um fator muito importante para o sucesso de uma rede neuronal. Normalmente, quanto maior for a quantidade de casos melhor será o treino da rede ou, pelo menos, com um maior número de casos será mais fácil para a rede perceber as relações existentes entre os dados. Com um número insuficiente de exemplos, tanto o desempenho da rede como a sua capacidade de generalização serão pobres. No entanto, não importa apenas a quantidade de dados, a qualidade dos mesmos também tem de ser garantida.

### **5.7.2 Fase de Treino da RNA**

O processo de treino de uma rede neuronal é feito a partir de um conjunto de dados dos quais conhecemos os valores de *output*.

-Silva (2013) refere que, após a definição de um conjunto de dados que contenha casos com valores históricos conhecidos, procede-se ao treino de uma RNA com esses mesmos dados.

O treino é o processo de aprendizagem que permite ajustar os parâmetros de computação da rede, tendo como objetivo, fazer com que a RNA retorne valores aproximadamente corretos face a dados *inputs* (Rocha, 2013). Existem variadas opções para estabelecer o tipo de rede que será gerada. Dependendo do tipo de dados, diferentes opções geram redes treinadas com melhor desempenho (isto é, redes que efetuam previsões mais eficazes) (Brandão, 2014).

O processo é orientado pelos dados fornecidos para treino e pelo algoritmo de treino. Este último seleciona vários conjuntos de parâmetros e avalia cada um aplicando a RNA a cada caso de treino (uma linha da informação) e vendo quão boas são as respostas da rede. Cada conjunto de parâmetros designa-se por "*trial*" (tentativa). O algoritmo seleciona novos conjuntos de parâmetros face aos resultados das anteriores tentativas. Não são disponibilizados todos os dados conhecidos para o processo de treino da rede, guardando-se parte para o teste e, se necessário, para a validação (Silva, 2013).

### 5.7.3 Fase de Teste da RNA

Durante a fase de teste, a rede neuronal que foi previamente treinada, é usada para verificar o seu desempenho, isto é, a sua capacidade de previsão de valores de *output* conhecidos. A informação usada na fase de teste é, geralmente, um subconjunto de dados históricos que não tenha sido utilizado na fase do treino, mas que contenha valores de *output* conhecidos.

Após o teste, o desempenho da rede é medido estatisticamente para verificar a percentagem de respostas conhecidas que foram previstas corretamente. Também é determinado o erro médio quadrático com base no qual é escolhida a melhor rede, assim sendo, a rede que apresentar o menor valor de erro na fase de teste, é considerada a rede com maior garantia de sucesso na previsão de novos valores desconhecidos (Palisade, 2013; citado por Rocha, 2013).

### 5.7.4 Fase de Previsão da RNA

De acordo com Palisade (2013), nesta fase final, a rede neuronal já treinada e testada é usada para prever valores de *output* desconhecidos, sendo este, o principal objetivo das RNA. Depois de treinada e testada, a rede adquiriu capacidade de generalização, por isso, pode ser usada para prever valores de novos casos com um determinado grau de confiança.

O processo de treino e teste são interativos e, por vezes, longos. Normalmente, o treino pode ser efetuado várias vezes, com configurações diferentes, até gerar uma rede neuronal que apresente os melhores resultados ao ser testada. Depois de se obter a melhor rede, esta pode ser usada para efetuar previsões rapidamente (Rocha, 2013).

## 5.8 MOTIVOS DA APLICAÇÃO DAS RNA

De acordo com Matos (2008) e citado por Rocha (2013), existem diversos campos, entre os quais o setor económico-financeiro, que têm vindo a desenvolver e a utilizar as RNA para previsões em várias vertentes como o mercado de ações, atribuição de grau de risco para empréstimos e crédito, deteção de fraude de crédito, previsão de vendas, previsão de negócios em geral, risco de investimentos.

Outro campos como a medicina, a ciência e engenharia, também utilizam as RNA para as mais diversas finalidades.

Ainda em Matos (2008), as razões da crescente utilização das RNA em todos estes campos prende-se com as propriedades e capacidades que lhes estão associados:

- Aprendizagem – uma RNA pode ser iniciada “sem conhecimento” e treinada com um dado conjunto de exemplos. Através do treino, as intensidades das ligações entre neurónios alteram-se de tal forma que a rede aprende a produzir o resultado desejado para os dados introduzidos;
- Generalização – capacidade da rede aprender através de um conjunto relativamente reduzido de exemplos e posteriormente dar respostas coerentes para dados não conhecidos,
- Paralelismo massivo potencial - no decurso do processamento da informação, vários neurónios “disparam” simultaneamente;
- Robustez – se alguns neurónios “falharem”, o sistema pode ainda ter um bom desempenho;
- Correspondência parcial – na maior parte dos casos uma correspondência total não é necessária.

Outra característica importante é a capacidade de auto-organização e de processamento temporal que faz das RNA uma ferramenta computacional extremamente poderosa e atrativa para a solução de problemas complexos. Estes benefícios permitem que as RNA consigam encontrar boas soluções mesmo com dados sujeitos a ruídos, falhas, informações imprecisas ou corrompidas.

De acordo com Rocha (2013) e citado por Brandão (2014), o interior de um digestor anaeróbio funciona como uma “caixa negra” da qual não se consegue obter informação, em tempo real, que permita a monitorização e controlo do processo de digestão. Atualmente, o controlo do processo é efetuado apenas com base na experiência adquirida no passado e nos conceitos teóricos do processo anaeróbio conhecidos. O resultado de qualquer opção ou decisão não é conhecido no imediato, tornando complexa a monitorização do processo.

A aplicação de modelos matemáticos, como as RNA, a esta problemática da DA, pode ser um contributo para a compreensão do processo de digestão e otimização da produção de biogás, constituindo ainda um sistema de apoio à decisão na gestão do processo anaeróbio.

## 6 APRESENTAÇÃO DO CASO EM ESTUDO

Como referido anteriormente, este estágio traduziu-se numa continuidade de estágios anteriores idênticos a este, decorridos na empresa AdCL e aplicados às ETAR de Cacia e de Ílhavo, em que, desta vez, a empresa anfitriã foi a Noraqua e a contribuição da AdCL foi no âmbito de disponibilizar a informação necessária relativamente às suas ETAR de Espinho e de Ílhavo.

Inicialmente, a ETAR de Espinho seria o único caso de estudo para este projeto. Somente a partir do final de Maio é que foi adicionada a ETAR de Ílhavo, com a finalidade de incrementar o conteúdo deste trabalho, face aos poucos dados disponíveis na ETAR de Espinho, e comprovar a eficácia das Redes Neurais Artificiais.

Esta situação ocorreu devido a diversas anomalias nos dados históricos da ETAR de Espinho que foram disponibilizados. Estes dados, fornecidos pela entidade exploradora, eram bastante reduzidos, em termos de quantidade e de qualidade. Foi nesta fase de tratamento de dados que se decidiu a agregação dos dados históricos da ETAR de Ílhavo (trabalho já elaborado por Hélder Rocha, embora os dados fornecidos para este trabalho ainda estavam intactos) para que este trabalho obtivesse resultados fidedignos, o que, com os dados fornecidos pela ETAR de Espinho, seria pouco provável.

Outro dos objetivos que levaram a cabo a introdução desta ETAR foi verificar a influência do aumento da quantidade de dados no processo de RNA, visto que houve uma inserção de 2 anos de dados analíticos desde o trabalho de Rocha (2013) ao presente trabalho.

Esta situação é bastante importante para sensibilizar as entidades exploradoras dos sistemas de tratamento de águas residuais, uma vez que as informações que os equipamentos fornecem, podem, um dia, vir a ser cruciais quando for necessário consultar os dados históricos.

O apoio da AdCL em fornecer os dados históricos de outra sua ETAR (Ílhavo), foi determinante para o prosseguimento deste trabalho.

### 6.1 RECOLHA DOS DADOS

No decorrer do processo de operação da ETAR são recolhidos diversos dados, através de um plano de amostragem, relacionados com o funcionamento da ETAR. Até Março de 2012, os dados analíticos da ETAR de Espinho eram armazenados em papel. Só a partir dessa data é que foi implementado, na estação de tratamento, um *software* (NAVIA™) que permite o armazenamento dos dados recolhidos ao longo do tempo, criando, assim, uma considerável base de dados disponíveis para o treino das RNA.

Antes dessa data, alguns dados, como o volume de lamas que entravam no digestor e o biogás consumido (2 variáveis imprescindíveis para o processo de RNA), não se encontravam informatizados. Esta situação provocou 2 dias de deslocação às instalações da ETAR para recolher e informatizar esses dados.

Quanto aos dados analíticos da ETAR de Ílhavo, o seu histórico iniciou em Maio de 2011, em que a empresa AdCL implementou o *software* NAVIA™, facilitando a recolha desses mesmos dados.

De acordo com Rocha (2013), a quantidade e qualidade dos dados disponíveis é um fator muito importante para o sucesso do treino de RNA. Parte-se do princípio que, quanto maior a base de dados, melhor será o treino e a capacidade de previsão da rede ou, pelo menos, espera-se que, com um maior número de casos, seja mais acessível para a rede compreender as relações existentes entre os dados. Com um número insuficiente de exemplos, tanto o desempenho da rede como a sua capacidade de generalização serão pobres. Um dos principais objetivos deste trabalho é validar esta suposição, aplicando o processo de RNA a uma ETAR já reincidente neste processo (ETAR de Ílhavo através de Rocha, 2013). Também é de salientar que a escassez de dados fornecidos para a DA da ETAR de Espinho, ajuda a comprovar que um défice da quantidade de dados despromove a eficácia das RNA.

Existem diferentes tipos de dados recolhidos e com periodicidades diferentes. Alguns dados são recolhidos *in loco* e outros são obtidos através de análises laboratoriais às amostras de efluente e lamas recolhidas pelos operadores. Os resultados dessas análises são carregados no mesmo programa. Este *software* NAVIA™ permite consultar o histórico dos dados recolhidos ao longo dos últimos anos.

Na definição das variáveis e dados a recolher, foram considerados alguns critérios importantes como a disponibilidade e fiabilidade dos dados e o impacto esperado das variáveis no processo de digestão. Na prática, a seleção dos *inputs* de uma rede neuronal deve ser baseada nas seguintes considerações:

- Conhecimento prévio sobre o processo a modelar;
- Disponibilidade e qualidade dos dados necessários para o conjunto de treino.

Sendo assim, as primeiras semanas de estágio na Noraqua foram dedicadas à compreensão do processo de digestão anaeróbia.

De acordo com Lingireddy & Brion (2005) e citado por Rocha (2013), uma aplicação bem-sucedida de um modelo de RNA, requer uma preparação adequada dos dados de *input*, assim como, uma sólida compreensão do processo a ser modelado é essencial para a correta seleção das variáveis de entrada. Esta compreensão fundamental, não só ajudará na escolha de dados de *input* apropriados, mas também ajudará a evitar a escolha de dados com erros ou dados menos fiáveis, que poderão confundir o processo de treino.

## 6.2 PREPARAÇÃO E TRATAMENTO DOS DADOS

Relativamente à ETAR de Espinho, apesar de, apenas existirem dados a partir de 2009, o conjunto de dados final pertence, somente, ao período entre Agosto de 2013 e Novembro de 2014. Esta situação deveu-se à análise efetuada à temperatura das lamas, que não correspondia à temperatura dentro do digestor, mas sim à da amostra em laboratório, e algum tempo após a recolha da mesma. Com isto, existe um enorme desfalque de temperatura comparativamente com a informação necessária. Como este dado é um dos que tem maior influência no processo de digestão anaeróbia, iria afetar a eficiência do processo de RNA, portanto, houve a obrigação de descartar todos os conjuntos de dados, à exceção de 50 recolhas de temperatura no período já referido, em que a análise à temperatura foi efetuada dentro do digestor.


## APRESENTAÇÃO DO CASO EM ESTUDO

Quanto às restantes variáveis, também houve alguns percalços, em que a análise dos seus valores foi bastante atribulada com alguns equívocos no registo dos dados, como por exemplo, escalas mal efetuadas, dados mal registados, valores apontados nas variáveis erradas, etc.

No que diz respeito à ETAR de Ílhavo, a abordagem aos seus dados históricos foi diferente. O empenho da AdCL, nesta ETAR, fez com que se conseguisse obter 400 conjuntos de dados históricos para um digestor, e 534 para o outro digestor. Esta mais-valia é importante porque uma RNA requer o maior conjunto de dados possível. Quanto a esta ETAR, não houve nenhum contratempo relativamente ao tratamento dos dados.

O método do tratamento, eliminação e validação dos dados foi o mesmo para ambas as ETAR. Inicialmente, foi calculada a média e, através do auxílio de gráficos, registaram-se os valores mais dispersos e duvidosos.

Um exemplo desses gráficos é o da **Figura 24**, que apresenta os valores do pH das lamas mistas espessadas da ETAR de Espinho. Neste caso, são evidentes 4 valores mais invulgares. Estes foram registados, para serem, depois, analisados. Caso houvesse prova que tinha sido um erro na introdução do valor, proceder-se-ia à respetiva correção, caso contrário, esse valor seria eliminado.



**Figura 24** - Exemplo de gráfico dos valores de pH da ETAR de Espinho

Com a ajuda do Eng<sup>o</sup> Milton Fontes da AdCL e da Eng<sup>a</sup> Alexandra Silva da Lusagua, procedeu-se à 1<sup>a</sup> eliminação definitiva de dados nas ETAR de Ílhavo e Espinho, respetivamente.

Foram também calculados os rácios MV/MS e AGV/Alcalinidade (FOS/TAC) para uma melhor orientação das variações dos valores registados. Estes rácios são tipicamente utilizados neste tipo de estudos pois fornecem uma boa análise relativamente às variações dos dados analíticos.

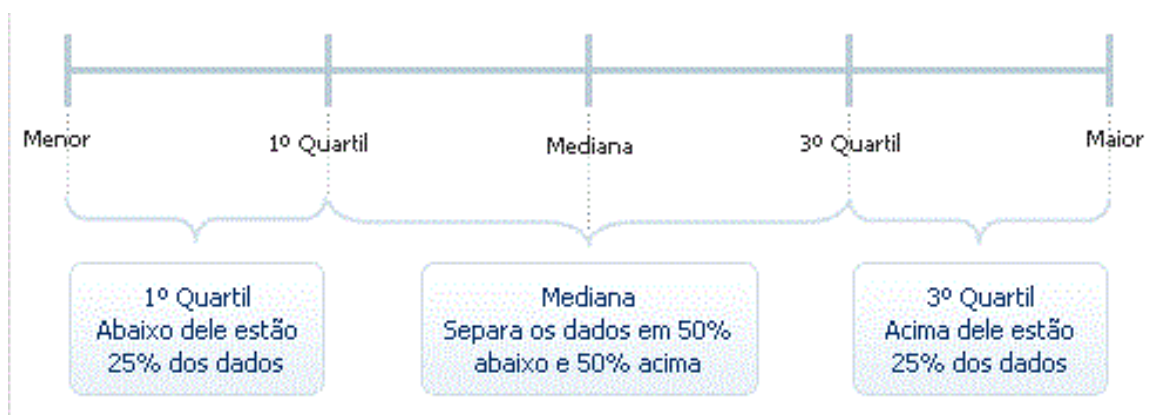
Relativamente ao rácio MV/MS, este permite verificar qual o potencial do resíduo para a digestão. Também foram eliminados os dados que obtivessem uma percentagem inferior a 50%, uma vez que é necessária uma boa quantidade de matéria volátil para ser digerida.

O rácio FOS/TAC é o mesmo que o rácio AGV/Alcalinidade. Uma vez que os AGV provocam a diminuição da alcalinidade, este rácio foi importante para localizar os valores mais anormais, não devendo ser superiores a 0,2.

O passo seguinte consistiu na utilização do método dos *outliers*. Na bibliografia existem várias metodologias, pelo que, neste caso, se utilizou a Amplitude Interquartil (*Interquartile Range – IQR*).

### 6.2.1 Amplitude Interquartil

A Amplitude interquartil de uma amostra de dados de tipo quantitativo é uma medida da variabilidade ou dispersão dos dados. Representa-se, geralmente, por IQR e define-se como sendo a diferença entre o 3º quartil e o 1º quartil ou quartil inferior. Os quartis e a mediana dividem a distribuição de uma amostra em 4 partes iguais, como demonstra a **Figura 25**.



**Figura 25** - Distribuição de uma amostra

## APRESENTAÇÃO DO CASO EM ESTUDO

Para o cálculo os quartis 1 e 3, procedeu-se à fórmula [QUARTIL] do Microsoft Excel™, em que esta devolve o quartil do conjunto de dados que se fornece ao *software*. De seguida foi calculado o IQR, fazendo a diferença entre o 3º e o 1º quartil.

Com os seguintes cálculos, determinou-se os valores limites, mínimo e máximos, para delimitar os valores aceitáveis:

$$\text{Valor máximo} = \text{Quartil 3} + \text{IQR} * 1,5$$

$$\text{Valor mínimo} = \text{Quartil 1} - \text{IQR} * 1,5$$

Os valores registados que estivessem fora deste intervalo foram considerados como *outliers*.

Por razões óbvias, houve dados em que não se considerou limites mínimos ou máximos, como por exemplo a quantidade de biogás. Uma vez que se pretende otimizar a quantidade de biogás, nesta variável não foi efetuado o cálculo do limite máximo.

Mais uma vez, com o auxílio do Engº Milton Fontes da AdCL e da Engª Alexandra Silva da Lusagua, procedeu-se à 2ª eliminação definitiva de dados nas ETAR de Ílhavo e Espinho, respetivamente.

### 6.3 RESULTADO DO PROCESSO DE TRATAMENTO DE DADOS

Com o processo de tratamento dos dados analíticos das duas ETAR, resultou em 3 folhas de cálculo do Microsoft Excel™:

- ETAR de Espinho – 14 variáveis com cerca de 50 registos cada;
- ETAR de Ílhavo (Digestor 1) – 12 variáveis com cerca de 400 registos cada (exceto Potencial Redox com apenas 112 e  $\text{NH}_4^+$  com 77 registos);
- ETAR de Ílhavo (Digestor 2) – 12 variáveis com cerca de 534 registos cada (exceto Potencial Redox, Condutividade elétrica e  $\text{NH}_4^+$  com apenas 88 registos cada).

Os parâmetros utilizados e as ETAR que os recolhem serão descritos em seguida:

- %MS [ETAR de Espinho e Ílhavo] – representa a percentagem de matéria sólida presente nas lamas. Foram, para ambas as ETAR, efetuadas análises a este parâmetro à entrada e saída de lamas do digestor.
- %MV [ETAR de Espinho e Ílhavo] – representa o conteúdo em matéria volátil da lama, isto é, a razão passível de ser digerida. Foram, para ambas as ETAR, efetuadas análises a este parâmetro à entrada e saída de lamas do digestor.
- pH [ETAR de Espinho e Ílhavo]– representa o valor do pH das lamas completamente misturadas dentro do digestor. No caso da ETAR de Espinho, houve também uma recolha deste parâmetro nas lamas mistas espessadas (antes da entrada no digestor).
- Alcalinidade [ETAR de Espinho] – representa a capacidade de resistência a alterações de pH causadas pela adição de ácidos (acidificação). Este parâmetro foi recolhido à entrada e saída do digestor.
- Ácidos Gordos Voláteis (AGV) [ETAR de Espinho] – são os principais produtos intermédios formados durante o processo de digestão anaeróbia. Este parâmetro foi recolhido à entrada e saída do digestor.
- FOS/TAC (razão AGV/Alcalinidade) [ETAR de Ílhavo] – FOS/TAC é um equipamento que, através de titulação, determina o quociente entre os ácidos gordos voláteis e a alcalinidade. FOS representa *Flüchtige Organische Säuren*, ou seja, ácidos gordos voláteis, enquanto TAC representa *Totales Anorganisches Carbonat*, isto é, a alcalinidade (capacidade tampão). Até 10 de Março de 2013, era utilizado o quociente entre as variáveis AGV e Alcalinidade. A partir dessa data até ao momento, passou a ser utilizado a razão FOS/TAC. Uma vez que os AGV provocam a diminuição da alcalinidade, este rácio é importante para monitorizar o processo, não devendo ser superior a 0,2.
- Caudal (volume diário) de entrada no digestor [ETAR de Espinho e Ílhavo] – representa o volume de lamas que entram no digestor ao longo de um dia. É, por isso, apresentado em m<sup>3</sup>/dia. Está dependente da quantidade e características de efluente que é encaminhado para a ETAR.

## APRESENTAÇÃO DO CASO EM ESTUDO

- Temperatura (°C) [ETAR de Espinho e Ílhavo] – refere-se à temperatura das lamas dentro do digestor. Conforme já foi referido no presente trabalho, o controlo e a manutenção de uma temperatura constante no digestor é crucial para o bom funcionamento do processo anaeróbio. Em ambas as ETAR, os digestores operam em regime mesófilo num intervalo de temperaturas entre 30 a 35 °C. A operação fora deste intervalo pode provocar inibição do processo de digestão.
- Potencial Redox [ETAR de Ílhavo] - Constitui um indicador importante do estado da digestão anaeróbia e da termodinâmica das reações que ocorrem no meio pois exprime a capacidade de uma molécula receber ou doar eletrões (Gerardi, 2003).
- Condutividade elétrica [ETAR de Ílhavo] - A condutividade elétrica reflete o conteúdo em sais dissolvidos presentes na lama.
- NH<sub>4</sub><sup>+</sup> [ETAR de Ílhavo] - Este parâmetro refere-se à amónia presente na lama. Dependendo do pH, em solução, há um equilíbrio entre amónia e amoníaco, este último tóxico para as bactérias.
- Carga Mássica Volúmica (CMV) [ETAR de Espinho e Ílhavo] – a CMV é um parâmetro fundamental para a operação do processo de digestão anaeróbia e relaciona a quantidade de matéria orgânica alimentada num dia com o volume do digestor, pela seguinte expressão:

$$CMV = \frac{Caudal * \%MV * 10}{Volume}$$

- Volume de biogás [ETAR de Espinho e Ílhavo] – este parâmetro representa o caudal diário de produção do biogás que é produzido pela digestão anaeróbia, sendo apresentado em m<sup>3</sup>/dia.

Como o principal objetivo deste trabalho é a otimização da produção de biogás, o volume de biogás foi definido como *output* das RNA e as restantes variáveis representam os *inputs*.

Deste modo, foi possível elaborar as bases de dados para cada digestor, podendo estas serem consultadas no **Anexo I**.

## 6.4 ABORDAGEM AO SOFTWARE DE RNA

A fase seguinte baseou-se na abordagem do *software* a ser utilizado para a criação das RNA: o NeuralTools™ da empresa Palisade™.

Este *software* trabalha sobre folhas de cálculo do Excel™, permitindo estruturar os dados por casos e variáveis. As variáveis estão dispostas em colunas, com o nome das mesmas na primeira linha do conjunto de dados. Cada linha do conjunto de dados é um caso e cada caso contém um conjunto de valores de variáveis independentes e um valor conhecido ou ausente para a variável dependente do *output*.

### 6.4.1 Gestor do Conjunto de Dados

O NeuralTools™ disponibiliza o Gestor do Conjunto de Dados, para preparação dos dados, através deste, é possível editar ou excluir variáveis que podem ser usadas para o treino, teste e previsão de RNA, adicionar ou remover conjuntos de dados e ainda identificar o tipo de variável no conjunto de dados.

As opções disponíveis no gestor do conjunto de dados para definir o tipo de variável são:

- Catagórica dependente - é uma variável dependente ou de *output* cujos valores possíveis são tomados de um conjunto de possíveis categorias.
- Catagórica independente - é uma variável independente cujos valores possíveis são tomados de um conjunto de possíveis categorias.
- Numérica dependente - é uma variável dependente ou de *output* cujos valores possíveis são numéricos.
- Numérica independente - é uma variável independente cujos valores possíveis são numéricos.

## APRESENTAÇÃO DO CASO EM ESTUDO

- Tag - é uma variável que assume possíveis valores de treino, teste ou previsão. Este tipo de variável é escolhido pelo utilizador para identificar casos a serem usados especificamente para treino, teste e previsão.
- Não usada - é uma variável que não será usada na RNA.

Como, neste trabalho, todos os dados são valores numéricos, foram selecionadas as opções “Numérica independente” e “Numérica dependente” para os *inputs* e *output*, respetivamente.

### 6.4.2 Treino e Teste das Redes Neurais

Depois de definido um conjunto de dados, procede-se ao treino e teste da rede neuronal.

Rocha (2013) afirma que o treino permite treinar uma rede neuronal a partir de um conjunto de dados com valores de *output* conhecidos. O processo de teste, que é realizado após o treino, permite medir o desempenho da rede treinada, na previsão dos valores de *output*. Os processos de treino e teste são iterativos e, por vezes, bastante longos. Depois de se obter a melhor rede, esta pode ser usada para efetuar previsões de valores de *output* desconhecidos.

Apesar de, na diversa bibliografia sobre RNA, estas duas etapas serem descritas em separado, o NeuralTools™ permite que estas aconteçam em simultâneo. Isso é bastante útil no uso da ferramenta, por tornar desnecessária mais uma intervenção do utilizador, embora internamente a ferramenta desenvolva o treino primeiro e o teste depois. Para beneficiar dessa solução, quando se procede à definição de um conjunto de dados, é possível escolher as percentagens ou quantidade de casos do conjunto de dados que serão reservadas para o treino e para o teste da rede neuronal. No presente estudo, foi sempre considerada a escolha predefinida de reservar 20% dos casos selecionados apenas para a fase de teste.

No final desta fase, o *software* disponibiliza um relatório completo no qual são indicados os valores das diferentes medições de erro para as redes treinadas e analisa o impacto de cada variável na modelação da rede.

#### 6.4.2.1 Treino das RNA

De acordo com o que foi mencionado no capítulo anterior, o NeuralTools™ permite usar diferentes configurações de RNA, a fim de propiciar as melhores previsões possíveis. Para a previsão de classificação/categoria (em que a variável dependente é um tipo de categoria) há dois tipos de redes disponíveis: redes PNN e redes MLF. A previsão numérica pode ser realizada usando-se redes MLF assim como GRNN, que são estreitamente relacionadas às redes PNN (Brandão, 2014).

O NeuralTools™ permite, ainda, a seleção da configuração de rede com o recurso à busca da melhor rede. Quando essa opção é selecionada, são treinadas e testadas uma variedade de configurações de RNA até gerar a que produz as melhores previsões. A melhor configuração é determinada com base nos dados obtidos por meio do teste.

O treino é interrompido quando é alcançado um dos critérios de paragem, como, por exemplo, a duração máxima do treino, o número de iterações que se deve executar durante a fase de treino ou a variação do erro. Durante o treino da RNA, o programa informa o andamento do mesmo mostrando gráficos que são atualizados. Normalmente, a RNA melhora à medida que o treino continua, pois são geradas redes que fazem melhores previsões com menos erros (Brandão, 2014).

#### 6.4.2.2 Teste das RNA

Após a fase de treino sucede-se a fase de teste, em que a RNA treinada é usada para analisar a qualidade da previsão de valores de *output* conhecidos. Os dados utilizados nesta fase são um subconjunto de dados históricos com valores de *output* conhecidos que não foram usados na fase de treino, para serem, propositadamente, aproveitados nesta fase de teste.

Quando os dados do teste se encontram num conjunto de dados separado, o NeuralTools™ faz a correspondência das variáveis do conjunto de dados do teste e dos dados de treino. O NeuralTools™ informa qual foi a qualidade da previsão de respostas conhecidas nos dados do teste. Isto ajuda a saber se a rede fará boas previsões quando aplicada a casos com valores de *output* desconhecidos (Palisade, 2013).

### 6.4.3 Procura da melhor RNA de cada digestor

Para encontrar a melhor rede neuronal resultante para cada digestor, foi definida uma série de passos que resultaram numa divisão de 3 conjuntos de RNA resultantes para cada digestor. Nos seguintes subcapítulos irão ser descritos os procedimentos aplicados a cada conjunto.

É de salientar que a escolha dos *inputs* colocados para a elaboração das RNA, os critérios de paragem e os tipos de redes a escolher foram variando conforme os resultados obtidos, sempre com vista a diminuir o erro médio quadrático (EMQ) da fase de teste. A definição deste dado, entre outros fornecidos pelo NeuralTools™, apresenta-se de seguida:

- % previsões inadequadas – uma previsão é considerada “inválida” se estiver fora da margem definida em torno do valor efetivo;
- Erro médio quadrático – medida do desvio das previsões em relação ao valor efetivo. É calculado fazendo a raiz quadrada do desvio quadrático médio;
- Erro médio absoluto – desvio médio das previsões em relação aos valores efetivos;
- Impacto das variáveis – exhibe o impacto relativo das variáveis independentes ou de *input* nas respostas previstas.

#### 6.4.3.1 Primeiro conjunto de RNA

Numa primeira abordagem ao *software*, as redes inicialmente criadas com os dados dos 3 digestores foram praticamente similares, com o objetivo de uma melhor compreensão e adaptação ao *software*.

Neste conjunto inicial, a escolha do tipo de rede foi sempre com recurso à busca da melhor rede. Esta é a escolha ideal pois permite a comparação dos erros obtidos nas redes GRNN e MLFN de 2 a 6 nós numa camada oculta, sendo, a única desvantagem, o tempo despendido para cada rede criada.

O critério de paragem de treino para este primeiro conjunto de redes foi a imposição de um limite máximo de 1 milhão de tentativas.

A 1ª rede foi criada com todos os *inputs* que foram fornecidos, com o objetivo de averiguar as variáveis com maior impacto e também de facilitar o primeiro contacto com o NeuralTools™. Os

resultados obtidos só seriam credíveis se os valores do EMQ e das percentagens de previsões inadequadas fossem aceitáveis.

As 2ª e 3ª redes foram produzidas com base nos resultados obtidos nos relatórios de estágio efetuados nos anos anteriores por Hélder Rocha (2013) e Joana Brandão (2014), na ETAR de Ílhavo e na ETAR de Cacia, respetivamente. Nestas redes, foram introduzidas as variáveis que obtiveram os melhores resultados nos seus casos em estudo, que foram, para o primeiro, SL4 MV, Volume de lamas, Temperatura de lamas e CMV. Já a melhor rede obtida por Brandão (2014) foi com as 5 seguintes variáveis: SL4 MV, pH, FOS/TAC, Volume de lamas e Temperatura de lamas.

Após esta etapa inicial, e com uma maior adaptação ao *software*, os procedimentos foram semelhantes para os 3 digestores: foram criadas umas redes apenas para ensaio com variáveis aleatórias, com o objetivo de averiguar a variação dos impactos que cada variável teria.

O passo seguinte consistiu em descartar as variáveis com menor impacto, utilizando os *inputs* com maior “peso”, sempre tendo em conta a credibilidade dos resultados obtidos, através da análise ao EMQ obtido.

Visto que 20% dos dados são direcionados para a fase de teste, o *software* escolhe aleatoriamente o conjunto para essa fase. Esta situação provoca uma variação dos resultados obtidos se uma mesma rede for corrida várias vezes, devido a esse conjunto também variar. Posto isto, foram selecionadas, para o 2º conjunto de RNA, as redes que obtiveram não só melhor EMQ na fase de teste, mas também na fase de treino (apenas resultados credíveis).

Como seria de esperar, os resultados obtidos para os digestores da ETAR de Ílhavo e para o digestor em funcionamento da ETAR de Espinho foram-se diversificando, assim como a estratégia aplicada.

Os subcapítulos seguintes irão descrever mais pormenorizadamente os procedimentos para a escolha das variáveis de cada digestor. Os resultados obtidos podem ser consultados no **Anexo II**.

**Nota:** Os códigos **SL4** e **SL5** presentes em algumas variáveis referem-se à localização da recolha das amostras:

- **SL4** – entrada do digestor;
- **SL5** – ponto na recirculação de lamas.

## APRESENTAÇÃO DO CASO EM ESTUDO

### 6.4.3.1.1 ETAR de Espinho

Relativamente ao digestor desta ETAR, nunca houve muita credibilidade nos resultados obtidos nas RNA. Um dos principais motivos deveu-se ao facto de haverem apenas 50 valores para cada variável resultantes da fase de tratamento dos dados, quando uma RNA necessita de uma abundante quantidade de dados. Apesar de tudo, o procedimento para as RNA aplicadas a este digestor, consistiram na insistência em escolher as variáveis com maior impacto e desconsideração das que tivessem menor “peso”.

Na 1ª rede criada com todas as variáveis obteve-se um EMQ para a fase de teste bastante alto. Este resultado seria de esperar, mas esta 1ª rede foi necessária para um contacto inicial com o *software* e para avaliar o impacto das variáveis, como já referido anteriormente.

As 2ª e 3ª redes foram produzidas com base nos resultados obtidos por Rocha (2013) e Brandão (2014), utilizando as suas variáveis, sendo que esta última obteve um EMQ satisfatório no Treino.

Da 4ª rede até à 13ª, o procedimento baseou-se numa aleatória escolha de variáveis, de forma a avaliar o impacto das mesmas. De salientar que a rede 6 obteve um EMQ satisfatório, utilizando as seguintes variáveis: SL4 MV, SL4 MS, SL4 Alcalinidade, SL4 AGV, Caudal de entrada, Temperatura.

Da rede 14ª à 20ª, houve uma insistência na escolha das variáveis com maior impacto nas redes obtidas anteriormente.

Para o 2º conjunto de redes seguiram as seguintes redes:

- RNA 3 (SL4 MV, Caudal, Temperatura, SL5 pH, SL5 Alcalinidade, SL5 AGV) [EMQ Treino: 16,0];
- RNA 5 (SL5 MS, SL5 MV, SL5 Alcalinidade, CMV) [EMQ Treino: 82,11];
- RNA 6 (SL4 MV, SL4 MS, SL4 Alcalinidade, SL4 AGV, Caudal, Temperatura) [**EMQ Teste: 250,94**];
- RNA 10 (SL4 pH, SL4 MV, Caudal, SL5 MS, SL5 MV, SL5 Alcalinidade, CMV) [EMQ Treino: 45,34];
- RNA 16 (SL4 pH, Caudal, Temperatura, SL5 MS, SL5 MV) [EMQ Treino: 98,73];
- RNA 19 (SL4 pH, Caudal, Temperatura, SL5 pH, CMV) [**EMQ Teste: 252,67**].

#### 6.4.3.1.2 ETAR de Ílhavo (Digester 1)

Este digester é o mesmo que Rocha (2013) teve como tema no seu relatório de estágio. Foi com base nos seus resultados obtidos que se basearam a escolha das primeiras variáveis para a procura da melhor RNA. Com novos dados, que na sua época de estágio não eram recolhidos, foi feita uma avaliação dos seus impactos, de forma a procurar uma redução do EMQ.

Embora baseado noutra ETAR, os resultados obtidos por Brandão (2014) também foram tidos em conta, com o objetivo de verificar o impacto das variáveis que foram utilizadas na sua melhor RNA.

A 1ª rede, com todas as variáveis, obteve resultados inaceitáveis com as únicas variáveis a terem impacto serem o pH e  $\text{NH}_4^+$ , o que seria impossível.

A 2ª rede, com as variáveis de Rocha (2013), obteve um EMQ no teste aceitável, como seria de esperar.

Já na 3ª rede, com as variáveis de Brandão (2014), os resultados foram bons na fase de treino.

Da 4ª à 9ª rede, sendo estas criadas com uma aleatória escolha de variáveis, foi possível verificar que, utilizando variáveis com poucos registos como  $\text{NH}_4^+$  e Potencial Redox, o número de casos é demasiado baixo para criar uma RNA robusta, o que levou a que não se utilizassem mais estas variáveis. A única exceção foi nas redes 13 e 19 em que se voltou a insistir na utilização da variável  $\text{NH}_4^+$  devido a esta ter tido um impacto considerável o que se comprovou nestas 2 redes.

À exceção das redes 13 e 19, as redes 10 até 20 alcançaram bons resultados, sendo que as que passaram para o 2ª conjunto foram as seguintes:

- Rede 2 (SL4 MV, Volume de lamas, Temperatura de lamas, CMV) [**EMQ Teste: 245,18**];
- Rede 3 (SL4 MV, pH, FOS/TAC, Volume, Temperatura) [EMQ Treino: 195,73];
- Rede 5 (SL4 MV, pH, Volume, Temperatura, CMV) [EMQ Treino: 206,46];
- Rede 10 (SL4 MV, pH, FOS/TAC, Volume, Temperatura, CMV) [**EMQ Teste: 276,47**];
- Rede 11 (SL4 MV, FOS/TAC, Volume, Temperatura) [EMQ Treino: 206,17];
- Rede 14 (SL5 MS, SL5 MV, FOS/TAC, Volume, Temperatura) [**EMQ Teste: 239,88**];

## APRESENTAÇÃO DO CASO EM ESTUDO

- Rede 15 (=12) (SL4 MV, FOS/TAC, Volume, Temperatura, CMV) [EMQ Treino: 200,77];
- Rede 16 (SL4 MV, FOS/TAC, Temperatura, CMV) [**EMQ Teste: 220,02**];
- Rede 17 (SL4 MV, pH, FOS/TAC, Temperatura) [**EMQ Teste: 224,18**];
- Rede 18 (SL4 MV, pH, FOS/TAC, Temperatura, CMV) [**EMQ Teste: 252,65**];

### 6.4.3.1.3 ETAR de Ílhavo (Digestor 2)

Este digestor, tal como o da ETAR de Espinho, nunca foi caso de estudo neste tema, embora a qualidade dos seus dados seja bastante diferente. À semelhança do digestor 1 da ETAR de Ílhavo, a qualidade dos seus dados foi assegurada.

Tal como nos 2 digestores anteriormente comentados, o procedimento para a procura da melhor rede foi bastante semelhante, em que os resultados obtidos por Rocha (2013) e Brandão (2014) serviram como arranque para uma busca pela RNA mais eficaz.

Tal como no digestor 1, redes criadas com variáveis com poucos registos, como Potencial Redox, Condutividade elétrica e  $\text{NH}_4^+$ , tiveram um número de casos reduzido comparando com a ausência das mesmas. Assim sendo, apenas as RNA sem estes *inputs* é que foram tidas em conta, em que as que obtiveram melhores resultados foram as seguintes:

- Rede 2 (SL4 MV, Volume, Temperatura, CMV) [EMQ Treino: 144,87];
- Rede 3 (SL4 MV, pH, FOS/TAC, Volume, Temperatura) [**EMQ Teste: 181,47**];
- Rede 12 (SL4 MV, pH, SL5 MS, SL5 MV, FOS/TAC, Volume, Temperatura) [EMQ Treino: 89,25];
- Rede 13 (SL4 MV, FOS/TAC, Volume, Temperatura) [**EMQ Teste: 160,30**];
- Rede 14 (SL4 MS, SL4 MV, pH, Volume, Temperatura) [EMQ Treino: 115,45];
- Rede 16 (SL5 MS, Volume, Temperatura, CMV) [**EMQ Teste: 198,70**];
- Rede 17 (SL4 MV, FOS/TAC, Volume, Temperatura, CMV) [**EMQ Teste: 129,43**];

### 6.4.3.2 Segundo conjunto de RNA

Os resultados obtidos anteriormente permitiram definir um conjunto mais reduzido de variáveis com maiores garantias de sucesso na modelação do processo de digestão anaeróbia dos 3 digestores.

As RNA que obtiveram melhores resultados no 1º conjunto foram corridas mais 3 vezes cada, de maneira a verificar a tendência dos valores dos erros médios quadráticos das fases de treino e teste.

Tal como no conjunto anterior, na escolha do tipo de rede foi sempre selecionado o recurso à busca de melhor rede e o critério de paragem redes foi a imposição de um limite máximo de 1 milhão de tentativas.

Após verificação dos resultados deste conjunto, as redes que seguiram para o 3º conjunto foram as 3 de cada digestor que obtiveram melhor EMQ na fase de teste. Foi também calculada a média do EMQ de teste para os 4 subconjuntos de cada RNA já corridos com o objetivo de verificar a tendência da redução do mesmo. Os resultados obtidos podem ser consultados no **Anexo III**.

#### 6.4.3.2.1 ETAR de Espinho

Conforme já referido as 6 RNA que obtiveram melhores resultados no 1º conjunto de redes, foram corridas mais 3 vezes. As que obtiveram melhor resultado no EMQ de Treino foram as seguintes:

- Rede 6 (SL4 MV, SL4 MS, SL4 Alcalinidade, SL4 AGV, Caudal, Temperatura) [**Melhor EMQ Teste (250,94) – Rede 6.0 GRNN**; Média do EMQ Teste: 318,10];
- Rede 16 (SL4 pH, Caudal, Temperatura, SL5 MS, SL5 MV) [Melhor EMQ Teste (301,33) – Rede 16.1 GRNN; **Média do EMQ Teste: 343,85**];
- Rede 19 (SL4 pH, Caudal, Temperatura, SL5 pH, CMV) [**Melhor EMQ Teste (252,67) – Rede 19.0 GRNN**; Média do EMQ Teste: 292,87].

## APRESENTAÇÃO DO CASO EM ESTUDO

### 6.4.3.2.2 ETAR de Ílhavo (Digestor 1)

Após serem corridas mais 3 vezes as 10 melhores redes obtidas no 1ª conjunto, os resultados mais satisfatórios foram obtidos nas seguintes RNA:

- Rede 2 (SL4 MV, Volume de lamas, Temperatura de lamas, CMV) [**Melhor EMQ Teste (242,73) – Rede 2.2 GRNN**; Média do EMQ Teste: 343,85];
- Rede 11 (SL4 MV, FOS/TAC, Volume, Temperatura) [**Melhor EMQ Teste (210,39) – Rede 11.1 GRNN**; Média do EMQ Teste: **245,08**];
- Rede 15 (SL4 MV, FOS/TAC, Volume, Temperatura, CMV) [Melhor EMQ Teste (235,94) – Rede 15.1 MLFN 2 nós; **Média do EMQ Teste: 251,64**].

### 6.4.3.2.3 ETAR de Ílhavo (Digestor 2)

O procedimento para a procura da melhor RNA para este digestor foi semelhante ao dos anteriores.

É de salientar que, embora para o digestor 1 e para Rocha (2013), as variáveis utilizadas na Rede 2 tenham criado resultados satisfatórios, o mesmo não se aplica neste digestor da mesma ETAR. Apesar desta averiguação, achou-se necessária a insistência em melhorar o seu erro médio quadrático, daí se ter incluído a Rede 2 no 3º conjunto de RNA.

Posto isto, as redes que seguiram para o próximo conjunto são as seguintes:

- Rede 2 (SL4 MV, Volume, Temperatura, CMV) [Melhor EMQ Teste (239,97) – Rede 2.2 GRNN; Média do EMQ Teste: 258,83];
- Rede 13 (SL4 MV, FOS/TAC, Volume, Temperatura) [Melhor EMQ Teste (160,30) – Rede 13.0 MLFN 2 nós; **Média do EMQ Teste: 194,11**];
- Rede 16 (SL5 MS, Volume, Temperatura, CMV) [Melhor EMQ Teste (198,70) – Rede 16.0 GRNN; Média do EMQ Teste: 220,10];
- Rede 17 (SL4 MV, FOS/TAC, Volume, Temperatura, CMV) [**Melhor EMQ Teste (129,43) – Rede 17.0 GRNN**; Média do EMQ Teste: **197,18**].

### 6.4.3.3 Terceiro conjunto de RNA

A metodologia aplicada neste último conjunto foi um pouco distinta das anteriores. Como os melhores resultados obtidos anteriormente foram com redes do tipo GRNN, optou-se pela seleção apenas deste tipo, e não pela busca da melhor rede. Como estas redes possuem uma fase de treino bastante rápida, não foi selecionado qualquer tipo de critério de paragem.

Para as melhores redes obtidas no anterior conjunto, foram corridas mais 12 vezes cada uma, com o objetivo de reduzir ainda mais o EMQ na fase de teste. Os resultados obtidos podem ser consultados no **Anexo IV**.

Sendo assim, as RNA com resultados mais satisfatórios para cada digestor foram as seguintes:

- **ETAR de Espinho** – Rede 16 (SL4 pH, Caudal, Temperatura, SL5 MS, SL5 MV) [**Melhor EMQ Teste (214,34)** – Rede 16.12 GRNN];
- **ETAR de Ílhavo (Digestor 1)** – Rede 11 (SL4 MV, FOS/TAC, Volume, Temperatura) [**Melhor EMQ Teste (210,39)** – Rede 11.1 GRNN];
- **ETAR de Ílhavo (Digestor 2)** – Rede 17 (SL4 MV, FOS/TAC, Volume, Temperatura, CMV) [**Melhor EMQ Teste (129,43)** – Rede 17.0 GRNN];

Na tentativa de verificar uma maior redução dos seus EMQ, estas 3 melhores redes foram corridas mais 15 vezes cada uma, no qual apenas se verificou uma variação do EMQ para a Rede 16 da ETAR de Espinho, enquanto que nas outras duas, o erro não reduziu.

Logo, a RNA com melhor resultado para a ETAR de Espinho foi a seguinte:

- **ETAR de Espinho** – Rede 16 (SL4 pH, Caudal, Temperatura, SL5 MS, SL5 MV) [**Melhor EMQ Teste (173,44)** – Rede 16.25 GRNN.

Os relatórios de Treino/Teste das melhores RNA para os digestores em estudo encontram-se disponíveis para consulta nos Anexos **V**, **VI** e **VII**.

É de salientar, o facto da Rede 2 (utilizando as mesmas variáveis que Rocha (2013)) não obteve os melhores resultados para nenhum dos dois digestores da ETAR de Ílhavo. Ainda assim, na insistência de reduzir o seu erro, pelo menos para o digestor 1, a rede foi corrida mais 15 vezes, tendo, apenas, baixado de 235,65 para 227,84, o que não foi suficiente para ser apurada como melhor RNA.

Outra particularidade é a questão do EMQ de Teste para o digestor 1 obtido por Rocha (2013), utilizando a Rede 2 (Rede GRNN com erro de 139,66), ter sido inferior ao EMQ de Teste da melhor rede obtida neste trabalho, para o mesmo digestor (Rede 11 do tipo GRNN com erro de 210,39) numa fase em que a sua quantidade de dados era inferior à do presente trabalho.

### **6.4.3.4 Utilização da base de dados da RNA de Rocha (2013)**

Numa tentativa de se obter melhores resultados que Rocha (2013) para o digestor 1 da ETAR de Ílhavo, utilizou-se a sua base de dados (após tratamento) e acrescentou-se os dados que não existiam no seu período. Deste modo, foi criada uma nova rede com as seguintes características:

- Mesmas variáveis independentes: SL4 MV, Volume de Lamas, Temperatura e CMV;
- Base de dados de 853 dias com dados tratados: 681 foram tratados por Rocha (2013) e 172 tratados pelo autor deste trabalho.

Tal como as melhores redes obtidas no 3º conjunto, esta RNA também foi corrida 30 vezes, em que a escolha do tipo de rede foi GRNN. Surpreendentemente, os resultados não foram os esperados, em que o melhor EMQ que se alcançou na fase de teste foi de 214,09. Como, no 3º conjunto de RNA, a rede 11.1 tinha obtido um melhor resultado, esta rede criada não foi aceite na seguinte etapa de Previsão.

Numa possibilidade de existir alguma anomalia do *software* ou algum lapso na configuração do mesmo por parte do utilizador, os dados que Rocha (2013) utilizou para construir a sua melhor RNA, foram novamente utilizados para este trabalho com o objetivo de verificar se haveria alguma alteração nos resultados. Para isso, foi corrida a sua base de dados no *software* cerca de 30 vezes, utilizando a configuração utilizada para o 3º conjunto de redes. O resultado obtido (EMQ de Teste: 143,78) foi bastante aproximado ao de Rocha (2013) (EMQ de Teste: 139,66).

Posto isto, conclui-se que não havia qualquer problema com o *software* ou com o seu manuseamento. Sendo assim, não existe uma justificação concreta para este aumento do EMQ de Teste, com uma maior base de dados fornecida ao *software*. Apesar de ter sido um resultado bastante semelhante ao de Rocha (2013), um lapso não verificado na fase de tratamento dos dados, assim como erros induzidos durante a recolha de amostras ou valores recolhidos podem estar na causa desta situação. Uma anomalia qualquer no processo de digestão anaeróbia ou nos pontos de recolha dos dados também podem ser os motivos para este resultado. Evidentemente que estas são apenas suposições e que, até ao fim do presente trabalho, não foi encontrada a sua causa.

#### 6.4.4 Previsão

Apesar de ter sido referido que o NeuralTools™ tem a capacidade de fazer com que as fases de Treino e Teste ocorram em simultâneo, na verdade, este *software* tem a aptidão de conseguir correr as fases de Treino, Teste e Previsão numa só etapa. Deste modo, sempre que é criada uma RNA, são criados os relatórios de Treino e Teste, e os dados usados nesta última etapa são também utilizados na Previsão. Um exemplo desse relatório de Previsão pode ser consultado no **Anexo VIII**.

Foi também feita uma prova ao *software*, em que se ocultou os mesmos dados de biogás que foram usados na fase de Teste, numa tentativa de verificar se os valores de Previsão se alterariam, o que não ocorreu. Face a esta situação, confirma-se que não é necessário reservar informação para a fase de Previsão, pelo que se pode consentir todos os dados possíveis ao *software*.

De modo a verificar a capacidade de generalização e desempenho das melhores redes neuronais encontradas para modelar o processo de digestão anaeróbia de cada um dos 3 digestores em estudo, procedeu-se, então, à análise do resultado da Previsão dessas RNA. Foram criados gráficos de comparação entre os valores reais e valores previstos pelas RNA e também das variações dos seus valores residuais. Esses elementos encontram-se disponíveis para consulta no **Anexo IX**.

Após a análise dos resultados obtidos nesta fase, constata-se o espectável, tendo em vista todo este processo ao longo do estudo. É notável a aproximação que as RNA conseguem ter do processo de digestão anaeróbia. Os gráficos resultantes dessa previsão comprovam isso mesmo.

## APRESENTAÇÃO DO CASO EM ESTUDO

Embora com resultados menos satisfatórios, a RNA criada para o digestor da ETAR de Espinho, com apenas 50 dados conseguiu aproximar-se dos valores reais de biogás. Ainda assim, fica muito aquém, quando comparada com as RNA resultantes dos digestores da ETAR de Ílhavo. Já estas últimas, com melhor qualidade em termos de base de dados produziram um resultado satisfatório. No que respeita à comparação entre os dois digestores da mesma ETAR, a diferença entre o valor de biogás real e o previsto para o digestor 2, sofre menos oscilações que o digestor 1. Este motivo pode estar associado ao facto da sua base de dados conter mais informação e, consequentemente, um EMQ na fase de Teste inferior ao do digestor 1.

## 7 CONSIDERAÇÕES FINAIS

### 7.1 CONCLUSÕES

Este trabalho constituiu, por si só, um desafio aliciante e enriquecedor, por se enquadrar numa temática que não é habitualmente abordada no curso de Engenharia Civil como foram os casos da Digestão Anaeróbia e das Redes Neurais Artificiais. Por outro lado, poderá promover a utilização de energias renováveis com baixo custo associado, como o biogás, apresentando vantagens sob o ponto de vista económico, ecológico e ambiental.

Compreendendo-se a complexidade do processo anaeróbio – do qual não se conhecem perfeitamente as relações existentes entre as diversas variáveis intervenientes, assim como, qual o contributo efetivo de cada uma na produção de biogás – as redes neuronais apresentam-se como uma ferramenta com enorme potencial para a modelação deste processo, devido à capacidade para entender relações complexas existentes num determinado conjunto de dados. Por imitação das funções do cérebro, as RNA conseguem discernir padrões existentes nos dados e, quando são fornecidos dados novos, são capazes de gerar previsões com base nas relações e nos padrões apreendidos durante o treino e teste da rede.

Neste trabalho, explorou-se a aplicação dessas redes à modelação do processo de digestão anaeróbia, através do *software* NeuralTools™ da Palisade™. Esta aplicação informática permite desenvolver redes neuronais de forma rápida e bastante intuitiva, num ambiente de trabalho bem conhecido, o Microsoft Excel™.

As redes neuronais desenvolvidas neste estudo – do tipo MLF e GRNN – produziram resultados que se podem considerar bastante interessantes, tendo-se encontrado redes com bom desempenho na modelação do processo de digestão. Analisando os resultados obtidos, as que obtiveram melhores

## CONSIDERAÇÕES FINAIS

resultados foram maioritariamente do tipo GRNN, entre as quais, as que foram escolhidas para melhor RNA de cada digestor em estudo.

Assim, a melhor rede para a DA da ETAR de Espinho foi obtida com a utilização das seguintes variáveis: pH medido à entrada do digestor, caudal de entrada de lamas, temperatura de lamas, % de MS e MV à saída do digestor. Esta rede obteve um erro médio quadrático na fase de Teste de 173,44. Por sua vez, quanto às variáveis utilizadas para criar a melhor RNA para o digestor 1 da ETAR de Ílhavo foram as seguintes: % MV à entrada do digestor, FOS/TAC, volume diário de lamas à entrada do digestor e temperatura de lamas. No caso desta rede, o seu EMQ na fase de Teste foi de 210,39. Relativamente ao digestor nº 2 da mesma ETAR, a melhor rede criada teve os seguintes *inputs*: % de MV à entrada do digestor, FOS/TAC, volume diário de lamas à entrada do digestor e temperatura de lamas e CMV. Com estas variáveis, o valor do EMQ de Teste conseguiu baixar para 129,43.

Na fase de previsão, foi notável a aproximação que as RNA conseguiram ter aos valores reais de biogás produzido. Embora com menos sucesso, a rede criada para a ETAR de Espinho conseguiu aproximar-se, relativamente, dos valores reais. No caso da RNA para o digestor nº2 da ETAR de Ílhavo, o resultado foi surpreendente, tendo obtido o melhor EMQ de Teste atingido deste trabalho. Quanto ao digestor 1 da mesma ETAR, o resultado foi positivo, embora, comparando a sua RNA associada à que foi obtida por Rocha (2013), este desilude um pouco, por não ter melhorado o erro com uma base de dados mais robusta. Mais ingrato é para este projeto, o não ter sido descoberta a sua justificação para este comportamento.

Por ultimo ressalva-se o facto deste estudo ter sido desenvolvido no âmbito de um estágio curricular, representa uma mais-valia, por permitir o primeiro contacto num ambiente empresarial, ficando a conhecer a organização e o funcionamento da empresa, nomeadamente, através do acompanhamento das atividades desenvolvidas em alguns departamentos. De salientar o agradável ambiente de trabalho e a cordialidade de todos os colaboradores da Noraqua, o que facilitou a integração na empresa.

## 7.2 DESENVOLVIMENTOS FUTUROS

De facto, as redes neuronais artificiais, ainda pouco divulgadas, apresentam-se como uma ferramenta com muita potencialidade, com aplicações de sucesso em diferentes áreas, como a engenharia e ambiente, mas também no setor económico-financeiro ou, até, no apoio a diagnóstico médico, conforme se deduz da bibliografia consultada. No âmbito da área de estações de tratamento de águas residuais, esta ferramenta poderá ter outras aplicações, não só no tema da digestão anaeróbia, como prever a qualidade do biogás, mas também noutras áreas do tratamento de águas residuais.

Conforme referido no presente relatório, a qualidade e quantidade dos dados analíticos é bastante importante devido às Redes Neuronais Artificiais necessitarem de uma abundante base de dados. Esta situação sentiu-se principalmente nos dados da ETAR de Espinho, que provocou enormes dificuldades no âmbito do seu tratamento e aplicação.

No caso da ETAR de Ílhavo, o facto de algumas variáveis que apresentaram impacto significativo no processo de aprendizagem das redes, existirem em menor número, condicionou, em certa parte, a quantidade de dados disponíveis para treinar as redes neuronais. Um desses exemplos é a variável FOS/TAC, que não foi recolhida com a mesma frequência que outras variáveis como %MS, %MV, caudal de entrada de lamas, temperatura e CMV. Estas variáveis, como forneceram bons resultados a Rocha (2013) e Brandão (2014), foram tidas em atenção, incentivando a uma recolha diária desses mesmos dados. Embora com uma quantidade de dados recolhidos inferior à das variáveis já referidas, as variáveis Potencial Redox, Condutividade elétrica e  $\text{NH}_4^+$  aparentaram ter um impacto considerável nos resultados de algumas RNA. Logicamente que, com tão pouca informação, não é possível haver certezas quanto a este facto.

Com o intuito de aumentar o número de dados disponíveis para futuros desenvolvimentos destas redes, sugere-se que, caso seja viável e comportável para a entidade exploradora, sejam recolhidas e analisadas uma maior quantidade de amostras destas variáveis. Considera-se que, um conjunto de dados com maior número de casos, poderá contribuir para a obtenção de melhores resultados na imitação do processo de digestão anaeróbia.

No término deste trabalho, em Outubro de 2015, decorreu um Workshop sobre Redes Neuronais Artificiais no ISEP, organizado pelo próprio orientador, Eng<sup>o</sup> Jaime Gabriel Silva. Na altura, foram

## CONSIDERAÇÕES FINAIS

convidados a debater e a expor os seus casos, vários elementos que participaram em diversas dissertações sobre RNA nos últimos anos, quer alunos, quer orientadores, entre outros.

Embora tenha sido na fase final da elaboração deste relatório de estágio, este Workshop foi bastante importante para enriquecer algumas ideias para desenvolvimentos futuros. Matos (2008), ao longo da sua apresentação, referenciou outros métodos de previsão bastante interessantes, mencionando que cada estudo pode ter o seu modelo de previsão mais adequado. Posto isto, fica a sugestão que, como o objetivo deste caso de estudo é otimizar a quantidade de biogás, a utilização das Redes Neurais Artificiais pode estar a limitar essa otimização, já que este modelo apenas funciona bem na interpolação de valores. Matos (2008) referenciou um modelo bastante interessante, que tem uma boa capacidade de extrapolação, denominado de *Support Vector Machine* (SVM), em que, no seu estudo, atingiu resultados bastante satisfatórios.

A utilização deste modelo de previsão no processo de digestão anaeróbia é uma sugestão para um desenvolvimento futuro de uma dissertação, visto que, ao ter capacidade para extrapolar, pode trabalhar com valores fora da gama de valores já obtidos, isto é, valores máximos de volume de biogás ainda não atingidos.

Outra sugestão para um futuro trabalho sobre este tema, é a agregação de um elemento coorientador mais especializado na ferramenta de redes neuronais, de modo a consolidar êxito dos resultados deste modelo de previsão aplicado ao processo de digestão anaeróbia.

Conforme resulta das observações aqui mencionadas, a abordagem a este tema terminada, podendo ser desenvolvida no futuro, com possibilidade de melhorar o trabalho aqui apresentado. Espera-se que a reunião destes dois temas ajude a promover a utilização de outras energias renováveis.

## REFERÊNCIAS BIBLIOGRÁFICAS

**Appels, L., Baeyens, J., Degrève, J. and Dewil, R. (2008).** *Principles and potential of the anaerobic digestion of waste-activated sludge.* Progress in Energy and Combustion Science, 34(6), pp.755-781.

**Di Bernardino, S. (2006).** *Desenvolvimento de um processo tecnológico inovador para o tratamento dos efluentes do processamento de sementes de alfarroba.* Doutor. Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa.

**Brandão, J. (2014).** *Otimização da produção de biogás com recurso a redes neuronais artificiais.* Mestre. Instituto Superior de Engenharia do Porto.

**Carreira, A. (2014).** *Utilização de Redes Neuronais Artificiais na gestão do processo de Digestão Anaeróbia.* Mestre. Escola de Engenharia da Universidade do Minho.

**Codeproject.com, (2012).** *JavaScript Machine Learning and Neural Networks with Encog - CodeProject.* [online] Available at: <http://www.codeproject.com/Articles/477689/JavaScript-Machine-Learning-and-Neural-Networks-wi> [Accessed 12 Sep. 2015].

**Crespo, E. (2013).** *Digestão Anaeróbia de resíduos agroalimentares: Reutilização das frações líquidas e sólidas (state-of-art).* Mestre. Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa.

**Fernandes, L. (2014).** *Modelação da digestão anaeróbia da ETAR da Guia com Redes Neuronais Artificiais.* Mestre. Instituto Superior Técnico.

**Gerardi, M. (2003).** *The microbiology of anaerobic digesters.* Hoboken, N.J.: Wiley-Interscience.

**Greenspine.ca, (2015).** *Paul De Koninck Lab.* [online] Available at: <http://www.greenspine.ca/> [Accessed 12 Sep. 2015].

**Gurjar, B. (2001).** *Sludge treatment and disposal.* Lisse [The Netherlands]: A.A. Balkema.

## REFERÊNCIAS BIBLIOGRÁFICAS

**Igoni, A., Ayotamuno, M., Eze, C., Ogaji, S. and Probert, S. (2008).** *Designs of anaerobic digesters for producing biogas from municipal solid-waste. Applied Energy*, 85(6), pp.430-438.

**Khalid, A., Arshad, M., Anjum, M., Mahmood, T. and Dawson, L. (2011).** *The anaerobic digestion of solid organic waste. Waste Management*, 31(8), pp.1737-1744.

**Lillesand, T. and Kiefer. R. (2002),** *Remote Sensing and Image Interpretation*, Fourth Edition, John Wiley and Sons, 2002, ISBN 9971-51-427-3.

**Mara, D. and Horan, N. (2003).** *Handbook of water and wastewater microbiology*. London: Academic Press.

**Matos J. (2008).** *Utilização de Redes Neurais Artificiais para a Modelação da Degradação de Sistemas de Distribuição de Água*. Mestre. Instituto Superior Técnico da Universidade Técnica de Lisboa.

**Mendes, R. (2014).** *Contributo para a avaliação da viabilidade do aproveitamento do biogás produzido em digestores anaeróbios a frio para a produção de energia elétrica*. Mestre. Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa.

**Monte, M. (2010).** *Contributo para o Estudo da Valorização Energética de Biogás em Estações de Tratamento de Águas Residuais*. Mestre. Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa.

**Moreira M. (1997).** *Introdução às Redes Neurais Artificiais*. Escola Superior de Tecnologia de Setúbal.

**Palisade (2013).** *NeuralTools - Add-In de Redes Neural para o Microsoft Excel*. Manual do Utilizador. Versão 6. Palisade Corporation. Ithaca. N.Y.

**Pereira, A. (2013).** *Co-digestão anaeróbia de resíduos verdes e lamas de ETAR para produção de biogás*. Mestre. Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa.

**Pires, A. (2009).** *Contribuição para o estudo de avaliação do desempenho de um sistema de estabilização anaeróbia e utilização do gás produzido*. Mestre. Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa.

## REFERÊNCIAS BIBLIOGRÁFICAS

**Pires, A. (2014).** *Modelação da digestão anaeróbia da ETAR de Vila Franca de Xira com Redes Neurais Artificiais*. Mestre. Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa.

**Qasim, S. (1999).** *Wastewater treatment plants*. Lancaster, Pa.: Technomic Pub. Co.

**Rocha, H. (2013).** *Utilização de Redes Neurais Artificiais na gestão de processos de Digestão Anaeróbia*. Mestre. Instituto Superior de Engenharia do Porto.

**Silva J. G. (2013).** *Workshop sobre utilização de Redes Neurais Artificiais em empresa da área do Saneamento Básico, SIMRIA, Aveiro*.

**Silveira, G. (2009).** *Estudo de Co-digestão Anaeróbia de Lamas Domésticas com o Efluente da Indústria da Fermentação da Levedura do Pão da Empresa Mauri Fermentos*. Mestre. Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa.

**Sobiologia.com.br, (2015).** *Células nervosas - Só Biologia ::..* [online] Available at: <http://www.sobiologia.com.br/conteudos/FisiologiaAnimal/nervoso2.php> [Accessed 12 Sep. 2015].

**Souza, M. (1984).** *Fatores que influenciam a digestão anaeróbia*. *Revista DAE*, 44(137), pp.88-94.

**Tchobanoglous, G. and Burton, F. (1991).** *Wastewater engineering*. New York: McGraw-Hill.

**Tchobanoglous, G., Burton, F. and Stensel, H. (2003).** *Wastewater engineering*. Boston: McGraw-Hill.

**Turovskiy, I. and Mathai, P. (2006).** *Wastewater sludge processing*. Hoboken: Wiley Interscience.

**Van Haandel, A. and Lettinga, G. (1994).** *Anaerobic sewage treatment –A practical guide for regions with a hot climate*. London: Wiley.

**Vavilin, V., Rytow, S. and Lokshina, L. (1995).** *Modelling hydrogen partial pressure change as a result of competition between the butyric and propionic groups of acidogenic bacteria*. *Bioresource Technology*, 54(2), pp.171-177.

**Vellasco, M. (2007).** *Redes Neurais Artificiais. Laboratório de Inteligência Computacional Aplicada*. Pontifícia Universidade Católica do Rio de Janeiro.

**Zayed, G. and Winter, J. (2000).** *Inhibition of methane production from whey by heavy metals - protective effect of sulfide*. *Applied Microbiology and Biotechnology*, 53(6), pp.726-731.



# ANEXOS

## ÍNDICE DE ANEXOS

<b>Anexo I .....</b>	<b>98</b>
Anexo I.1 - Dados analíticos da ETAR de Espinho .....	99
Anexo I.2 - Dados analíticos da ETAR de Ílhavo (Digestor 1) .....	100
Anexo I.3 - Dados analíticos da ETAR de Ílhavo (Digestor 2) .....	101
<b>Anexo II .....</b>	<b>102</b>
Anexo II.1 – 1º conjunto de redes da ETAR de Espinho.....	103
Anexo II.2 – 1º conjunto de redes da ETAR de Ílhavo (Digestor 1).....	104
Anexo II.3 – 1º conjunto de redes da ETAR de Ílhavo (Digestor 2).....	105
<b>Anexo III .....</b>	<b>106</b>
Anexo III.1 – 2º conjunto de redes da ETAR de Espinho.....	107
Anexo III.2a – 2º conjunto de redes da ETAR de Ílhavo (Digestor 1) [RNA 2 até 11] .....	108
Anexo III.2b – 2º conjunto de redes da ETAR de Ílhavo (Digestor 1) [RNA 12 até 18] .....	109
Anexo III.3 – 2º conjunto de redes da ETAR de Ílhavo (Digestor 2).....	110

<b>Anexo IV .....</b>	<b>111</b>
Anexo IV.1 – 3º conjunto de redes da ETAR de Espinho .....	112
Anexo IV.2 – 3º conjunto de redes da ETAR de Ílhavo (Digestor 1) .....	113
Anexo IV.3 – 3º conjunto de redes da ETAR de Ílhavo (Digestor 2) .....	114
<b>Anexo V .....</b>	<b>115</b>
Anexo V.1 – Relatório de Treino/Teste da RNA 16.25 e impacto das variáveis .....	116
Anexo V.2 – Outros gráficos provenientes do Relatório da RNA 16.25 .....	117
<b>Anexo VI .....</b>	<b>118</b>
Anexo VI.1 – Relatório de Treino/Teste da RNA 11.1 e impacto das variáveis .....	119
Anexo VI.2 – Outros gráficos provenientes do Relatório da RNA 11.1 .....	120
<b>Anexo VII.....</b>	<b>121</b>
Anexo VII.1 – Relatório de Treino/Teste da RNA 17.0 e impacto das variáveis .....	122
Anexo VII.2 – Outros gráficos provenientes do Relatório da RNA 17.0 .....	123
<b>Anexo VIII Exemplo da Previsão de uma RNA após a fase de Treino/Teste.....</b>	<b>124</b>
<b>Anexo IX.....</b>	<b>126</b>
Anexo IX.1 – Gráficos da fase de Previsão da RNA 16.25 para a ETAR de Espinho .....	127
Anexo IX.2– Gráficos da fase de Previsão da RNA 11.1 para a ETAR de Ílhavo (Digestor 1) .....	128
Anexo IX.3– Gráficos da fase de Previsão da RNA 17.0 para a ETAR de Ílhavo (Digestor 2) .....	129

# **ANEXO I**

## **Dados analíticos da digestão anaeróbia das ETAR, após tratamento**

Anexo I.1 - Dados analíticos da ETAR de Espinho

Anexo I.2 - Dados analíticos da ETAR de Ílhavo (Digestor 1)

Anexo I.3 - Dados analíticos da ETAR de Ílhavo (Digestor 2)

## ANEXO I.1 - DADOS ANALÍTICOS DA ETAR DE ESPINHO

Mês	Dia do mês	Dia	SL4 pH	SL4 MS (%)	SL4 MV (%)	SL4 Alcalinidade	SL4 AGV	SL5 pH	SL5 MS (%)	SL5 MV (%)	SL5 Alcalinidade	SL5 AGV	Caudal de Entrada	T (°C)	CMV	Biogás Consumido
agosto 2013	11	1	5,3	4,28	3,33	831	2745	7,3	1,13	0,71	3057	312	74	38	0,89	1233
	18	2	5,5	3,64	2,84	910	148	7,1	2,89	2,02	3092	148	107	37	1,10	1169
setembro 2013	1	3	5,1	17,18	15,44	735	1210	7,1	0,92	0,59	3105	333	189	38	10,53	792
	8	4		18,09	14,78	730	1201	7,4	1,04	0,65	3103	286	95	38	5,06	1256
	16	5	5,5	1,36	1,11	732	1208	7,2	0,34	0,14	4465	386	73	35	0,29	662
	29	6	5,9	3,94	2,66	656	839	7,2	1,10	0,68	2899	283	15	36	0,14	544
outubro 2013	6	7	5,6	12,69	10,45	521	1756	7,2	1,15	0,69	2875	300	135	35	5,09	1098
	13	8	6,7	5,03	4,65	367	46	6,8			1016	129	7	34	0,12	988
	20	9	5,8	13,10	10,00	1347	5096	7,5	1,21	0,73	2850	292	2	35	0,07	520
	27	10	5,6	4,33	3,05	1087	2192	7,2	1,34	0,80	3101	235	109	34	1,20	918
novembro 2013	3	11	5,6	14,26	12,17	606	3350	7,5	1,52	1,02	3065	232	26	34	1,14	784
	10	12	5,9	4,03	3,12	678	1254	7,3	1,42	0,87	2656	287	159	33	1,79	1440
	17	13	5,2	21,86	20,15	1051	2608	7,2	1,23	0,75	2905	268	34	29	2,47	820
fevereiro 2014	23	14	5,5	18,61	16,60	458	1619	6,7	0,31	0,15	2117	481	74	25	4,43	378
março 2014	9	15	5,1	11,22	9,75	912	2816	7,1	1,21	0,68	2778	285	27	31	0,95	1048
	23	16	4,9	6,05	4,54	1598	4989	7,0	1,38	0,78	3264	468	59	26	0,97	624
	30	17	5,2	4,68	3,53	1264	3525	7,1	1,11	0,66	3134	466	54	29	0,69	719
abril 2014	6	18	5,3	5,39	3,64	1746	3180	7,1	3,04	1,77	3376	349	80	34	1,05	1263
	13	19	5,3	5,37	4,13	2676	2697	7,2	1,82	1,08	4814	420	65	33	0,97	1242
	20	20	5,8	2,45	1,69	2128	1418	7,2	0,80	0,50	4158	507	30	30	0,18	516
	27	21	5,3	5,91	4,49	2282	3516	7,1	2,30	1,58	4128	538	56	33	0,91	1290
maio 2014	4	22	6,3	1,83	1,41	584	511	7,1	1,91	1,21	3091	365	35	33	0,18	1364
	11	23	5,6	4,31	3,32	966	1993	7,2	1,74	1,09	3460	341	132	32	1,58	1701
	18	24	5,6	3,66	2,95	770	817	7,1	1,80	1,14	3538	452	165	34	1,76	1572
	25	25	5,1	8,46	6,44	664	2269	7,1	1,90	1,19	3510	450	65	31	1,51	1137
junho 2014	2	26	5,8	4,67	3,71	1020	2021	7,1	2,01	1,27	3536	432	25	33	0,33	1845
	8	27	6,0	3,74	2,86	862	1192	7,2	1,97	1,23	3616	428	142	35	1,47	1674
	16	28	5,7	4,56	3,71	1516	2227	7,4	1,74	1,11	3676	284	68	33	0,91	398
	23	29	5,4	6,05	4,62	1080	1893	7,3	2,00	1,28	3606	483	14	34	0,23	1309
	30	30	5,1	9,54	7,52		3930	7,1	1,80	1,13	3594	436	84	34	2,28	1434
julho 2014	7	31	5,3	5,30	3,97	1076	2223	7,2	1,76	1,10	3643	522	31	34	0,44	783
	14	32	5,2	6,06	4,79	1146	2971	7,2	1,85	1,17	3026	284	84	35	1,45	1438
	21	33	5,8	3,12	2,39	1100	1816	7,3	1,97	1,26	3624	209	119	34	1,02	1445
	28	34	5,7	3,57	2,81	1451	890	7,2	1,96	1,26	3095	260	55	34	0,56	1032
agosto 2014	4	35	5,3	3,40	2,62	2970	1019	7,0	2,00	1,30	3690	187	134	34	1,27	1391
	11	36	5,1	3,52	2,77	568	1991	7,3	1,37	0,90	3352	272	67	35	0,67	1195
	18	37	6,7	7,95	6,98	680	47	7,3	1,61	1,12	3478	283	85	34	2,14	1720
	25	38	5,8	4,10	3,85	687	861	7,1	1,90	1,50	3950	216	53	34	0,74	1755
setembro 2014	1	39	5,4	4,63	3,64	866	3124	7,4	2,06	1,39	3178	327	130	38	1,71	1713
	8	40	5,4	7,98	6,02			7,4	1,75	1,14		200	69	36	1,50	998
	15	41	5,5	4,89	3,67	912	1735	7,4	2,15	1,41	3192	445	91	38	1,20	1476
	22	42	5,4	3,08	2,14	697	959	7,3	1,92	1,22	3022	327	107	36	0,83	1052
	29	43	5,3	6,01	4,58		1543	7,1	0,91	0,56	3002	366	71	35	1,17	1228
outubro 2014	6	44	6,0	5,29	3,98		2440	7,3	2,00	1,29	3044	294	73	35	1,05	1304
	13	45	5,4	5,03	3,74	520	1733	7,3	2,29	1,44	3096	533	90	34	1,21	1163
	20	46	5,2	5,49	4,01	410	1271	7,2	3,27	2,08	2909	238	86	33	1,24	922
	27	47	5,2	3,48	2,72	531	417	7,3	2,14	1,35	2851		63	33	0,62	912
novembro 2014	3	48	5,2	4,95	3,60	821	1724	7,4	1,78	1,13	2916	267	38	32	0,49	1347
	10	49	5,6	3,52	2,34	617	1018	7,2	1,90	1,18	2767	309	131	29	1,10	707
	17	50	5,5	1,34	0,86	981	1962	7,2	1,90	1,11	2493	269	92	30	0,29	699

## ANEXO I.2 - DADOS ANALÍTICOS DA ETAR DE ÍLHAVO (DIGESTOR 1)

Data	Dia	SL4 %MS	SL4 %MV	SL5A pH	SL5A %MS	SL5A %MV	SL5A REDOX	SL5A FOS/TAC (AGV/ALC)	SL5A NH4+	Volume lamas digestor 1	T (°C) digestão 1	CMV Digestor 1	Volume biogás 1
18-Mai-2011	1	2,3	1,7	7,3	1,8	1,1		0,0609756		173	35,63333	0,980333	1034
25-Mai-2011	2	2,9	2,1	7,5	1,8	1,1		0,0833333		193	36,1	1,351	1262
30-Mai-2011	3	2,8	1,9	7,3	1,6	1,1		0,0489796		180	36	1,14	1337
01-Jun-2011	4	3	2,2	7,3	1,8	1,1		0,0512821		140	35,6	1,026667	1001
06-Jun-2011	5	1,8	1,1	7,2	1,6	1		0,0478261		187	35,73333	0,685667	1131
08-Jun-2011	6	2,8	1,9	7,2	1,7	1		0,0491071		190	35,36667	1,203333	1145
13-Jun-2011	7	1,8	0,9	7,3	1,9	1,3		0,2125604		204	36,4	0,612	846
15-Jun-2011	8	2,8	1,8	7,1	1,7	1		0,0576923		190	35,63333	1,14	1027
20-Jun-2011	9	2,6	1,7	7,3	1,7	1		0,1372549		191	35,9	1,082333	1112
21-Jun-2011	10	2,7	1,8	7	1,8	1		0,1377551		191	36,06667	1,146	1141
27-Jun-2011	11	2,1	1,4	6,7	2,3	1,5		0,2671233		192	36,4	0,896	1221
04-Jul-2011	12	2,51	1,68	7,4	1,87	1,13		0,0531401		184	35,86667	1,0304	1107
06-Jul-2011	13	2,87	1,88	7	1,92	1,14		0,0637255		216	35,96667	1,3536	1287
11-Jul-2011	14	2,78	1,89	7,3	1,9	1,11		0,0681818		211	36	1,3293	964
13-Jul-2011	15	2,03	1,21	6,9	2,6	1,78		0,0585586		216	35,5	0,8712	1225
18-Jul-2011	16	2,9	1,71	7,3	2	1,19		0,0694444		213	36,33333	1,2141	1007
20-Jul-2011	17	2,93	1,84	7,2	2,07	1,22		0,0588235		214	36,13333	1,312533	1095
25-Jul-2011	18	3,21	2,1	7,1	2,39	1,43		0,1023256			36		1213
01-Ago-2011	19	1,93	1,06	7,5	1,7	1,02		0,0765766			35,83333		574
03-Ago-2011	20	2	1,44	7,3	1,82	1,2		0,0590717			31,4		684
08-Ago-2011	21	2,61	1,55	7,3	1,85	1,17		0,0545455			35,4		519
10-Ago-2011	22	3,09	1,95	7,2	2,13	1,22		0,0740741		140	35,33333	0,91	634
15-Ago-2011	23	3,06	2,01	7,1	2,53	1,23		0,3239669		168	36,43333	1,1256	800
17-Ago-2011	24	3,04	1,87	7,2	2,2	1,27		0,0769231		169	35,53333	1,053433	787
22-Ago-2011	25	3,08	2,05	7,1	2,26	1,31		0,0613208		169	33,1	1,154833	1068

(...)

30-Mar-2014	380	5,4	4	6,9		2,1	-297,7	0,14		69	37,4	0,92	1149
01-Abr-2014	381	5	3,8	6,8	2,6	1,8	-323,5	0,15		77	37,4	0,975333	1401
02-Abr-2014	382	4,7	3,6							79	37,3	0,948	1136
06-Abr-2014	383	5,9	4,2	7,5	1,6	0,9	-296,8	0,15		75	36,6	1,05	1361
08-Abr-2014	384	4,6	3,5	7,5	2	1,1	-301,3	0,16		73	38,4	0,851667	1214
09-Abr-2014	385	5	3,8							75	38,6	0,95	1394
13-Abr-2014	386	5,6	4	7,5		1,6	-262,3	0,16		76	38,3	1,013333	1150
15-Abr-2014	387	4,5	3,5	7,5	1,8	1,1	-302,2	0,15		95	39	1,108333	1312
16-Abr-2014	388	4,1	2,9							100	38,8	0,966667	1360
20-Abr-2014	389	3,1	2,4	7,4	2,8	1,5	-246,4	0,17		108	38,2	0,864	959
22-Abr-2014	390	4,4	2,5	7,8	1,7	1,1	-120,8	0,16	1260	110	37,6	0,916667	830
23-Abr-2014	391	3,3	2,5							131	37,3	1,091667	650
27-Abr-2014	392	3,7	2,8	7,5	1,8	1,1	-317,3	0,17	1310	129	36,8	1,204	1353
29-Abr-2014	393	3,9	2,9	7,5	1,8	1,1	-295,4	0,18	1080	126	35,8	1,218	1575
30-Abr-2014	394	4,1	3,1							126	35,3	1,302	1535
04-Mai-2014	395	3,7	2,7	7,1	1,9	1,2	-341,7	0,14	1120	132	36,1	1,188	1173
06-Mai-2014	396	3,8	2,7	7,5	1,9	1,2	-253,4	0,14	1390	136	35,8	1,224	975
07-Mai-2014	397	3,9	2,8							131	35,8	1,222667	1069
13-Mai-2014	398	3,5	2,5	7,3	2,1	1,2	-301,9	0,15	1560	116	35,1	0,966667	1098
14-Mai-2014	399	3,6	2,6							133	35,8	1,152667	854
18-Mai-2014	400	2,9	2,1	7,6	2	1,2	-319,7	0,12	1330	100	36,8	0,7	761

### ANEXO I.3 - DADOS ANALÍTICOS DA ETAR DE ÍLHAVO (DIGESTOR 2)

Data	Dia	SL4 %MS	SL4 %MV	SL5B pH	SL5B %MS	SL5B %MV	SL5B REDOX	SL5B FOS/TAC (AGV/ALC)	Condutividade SL5B	SL5B NH4+	Volume lamas digestor 2	T (°C) digestão 2	CMV Digestor 2	Volume biogás 2
20-Mai-2012	1	3,9	2,8	7,3	2,2	1,3		0,1019108			40	32,6	0,373333	179
22-Mai-2012	2	3,7	2,8	7,3	1,7	1		0,1050725			39	33,2	0,364	175
24-Mai-2012	3	4,3	3,3								36	34,4	0,396	181
27-Mai-2012	4	3,8	2,9	7,3	1,7	1		0,0512821			35	34,9	0,338333	198
29-Mai-2012	5	4,1	2,9	7,3	1,6	1		0,0425532			48	34,8	0,464	196
31-Mai-2012	6	4,8	3,6								70	35	0,84	116
03-Jun-2012	7	3,1	2,8	7,3	2,1	1,1		0,0855263			72	35,3	0,672	822,8
05-Jun-2012	8	3,3		7,2				0,0699301			68	35,7		845,75
07-Jun-2012	9										70	36,3		804,95
10-Jun-2012	10	5	3,6	7,4		1,1		0,0642857			71	36,6	0,852	917
12-Jun-2012	11	4,7	3,7	7,3	1,8	1,1		0,0875			78	36,8	0,962	834
14-Jun-2012	12	3,4	2,6								54	36,9	0,468	635
17-Jun-2012	13	3,3	2,5	7,3	1,9	1,2		0,0608108			70	36,6	0,583333	552
19-Jun-2012	14	3,6	2,8	7,3	2	1,2		0,0641892			67	36,6	0,625333	739
21-Jun-2012	15	3,6	2,6								71	36,3	0,615333	768
24-Jun-2012	16	4,2	3	7,2	2	1,3		0,1280488			73	36,3	0,73	1032
26-Jun-2012	17	3,8	2,8	7,3	2	1,3		0,0609756			81	36,4	0,756	935
28-Jun-2012	18	4,1	3								83	36,4	0,83	1032
01-Jul-2012	19	3,6	2,6	7,3	2,1	1,3		0,0352564			72	35,8	0,624	929
03-Jul-2012	20	3,4	2,5	7,3	2,4	1,5		0,0487805			79	36,1	0,658333	790
05-Jul-2012	21	3,5	2,5								76	35,9	0,633333	942
08-Jul-2012	22	4,5	3,1	7,3	2,6	1,6		0,1830508			79	35,8	0,816333	1089
10-Jul-2012	23	4,3	3	7,4	2,2	1,3		0,0872093			61	35,7	0,61	889
12-Jul-2012	24	3,5	2,4								79	35,6	0,632	864
15-Jul-2012	25	3,9	2,9	7,5	2,2	1,3		0,0615836			77	35,7	0,744333	1006

(...)

01-Abr-2015	514	3,2	2,5								150	38,9	1,25	1572
05-Abr-2015	515	3,7	2,8	6,9	1,8	1,2	-314,1	0,16	9,49	1100	150	38,4	1,4	1958
07-Abr-2015	516	3,6	2,7	7,2	1,9	1,2	-266	0,15	9,7	1160	135	38,2	1,215	1923
08-Abr-2015	517	3,6	2,7								147	38	1,323	1796
12-Abr-2015	518	3	2,2	7,4	1,9	1,2	-315,7	0,13	9,67	1060	151	37,8	1,107333	1757
14-Abr-2015	519	3,4	2,6	7,4	1,5	1	-308,4	0,15	9,58	1090	146	38	1,265333	1897
15-Abr-2015	520	3,5	2,7								144	37,7	1,296	1510
19-Abr-2015	521	3,4	2,5	7,3	1,9	1,3		0,14		858	121	36,3	1,008333	1555
21-Abr-2015	522	3,3	2,5	6,9	2	1,3	-277,1	0,15	9,79	996	120	36,8	1	1352
22-Abr-2015	523	3,3	2,4								120	36,9	0,96	1408
26-Abr-2015	524	3,2	2,4	7,3	2	1,2	-273,9	0,15	9,79	1210	120	37,2	0,96	1935
28-Abr-2015	525	3,4	2,6	7,2	2,1	1,3	-291,6	0,15	8,33	1250	120	36,5	1,04	1602
03-Mai-2015	526	3,1	2,4	7,2	2,1	1,4	-268,8	0,14	9,4	1210	125	37,1	1	1389
05-Mai-2015	527	3	2,3	7	2	1,3	-285,9	0,13	9,3	786	129	37,5	0,989	1589
06-Mai-2015	528	3,3	2,6								133	37,4	1,152667	1532
10-Mai-2015	529	2,9	2,3	7			-311	0,14	9,8	1200	125	37,2	0,958333	1488
12-Mai-2015	530	3,3	2,6	7,3	2	1,3	-299,3	0,14	9,54	1170	106	37,1	0,918667	1513
13-Mai-2015	531	3,1	2,5								150	37,2	1,25	1412
17-Mai-2015	532	3,1	2,4	7,4	2	1,3	-338,8	0,13	8,83	915	141	37,3	1,128	1482
19-Mai-2015	533	3,1	2,4	7,1	2	1,3	-327,2	0,12	8,65	1060	140	37	1,12	1267
20-Mai-2015	534	3	2,5								140	36,7	1,166667	2028

# **ANEXO II**

## **Primeiro conjunto de RNA**

Anexo II.1 – 1º conjunto de redes da ETAR de Espinho

Anexo II.2 – 1º conjunto de redes da ETAR de Ílhavo (Digestor 1)

Anexo II.3 – 1º conjunto de redes da ETAR de Ílhavo (Digestor 2)

## ANEXO II.1 – 1º CONJUNTO DE REDES DA ETAR DE ESPINHO

Nome		1	2	3	4	5	6	7	8	9	10	11	12	13 (=10)	14	15
Tipo de RNA		GRNN	MLFN (4 nós)	MLFN (5 nós)	MLFN (2 nós)	MLFN (5 nós)	GRNN	MLFN (2 nós)	GRNN	GRNN	MLFN (4 nós)	GRNN	GRNN	GRNN	GRNN	MLFN (3 nós)
Variáveis numéricas independentes (Inputs)		Impacto das variáveis														
Entrada do Digestor	SL4 pH	16,76%			15,26%				24,98%	0,02%	12,55%		0,17%	16,26%	36,33%	19,11%
	SL4 MS	0,56%					9,80%	12,56%								
	SL4 MV	13,11%	21,93%	15,20%	7,36%		12,82%	16,22%		32,72%	11,38%		14,26%	0,07%		
	SL4 Alcalinidade	0,04%			13,63%		4,20%									
	SL4 AGV	6,60%			5,39%		0,39%									
Dentro do Digestor	SL5 pH	0,02%		19,91%	10,43%											
	SL5 MS	28,82%				23,32%		32,33%			15,72%	0,51%		17,42%	0,72%	8,31%
	SL5 MV	4,33%				27,16%		28,06%			31,70%	18,41%		34,62%	34,45%	18,91%
	SL5 Alcalinidade	19,32%		16,92%	19,08%	19,67%			1,10%	0,28%	11,33%		0,40%	4,06%	0,13%	
	SL5 AGV	4,64%		16,01%	11,21%									16,62%		17,29%
	Caudal	0,01%	30,44%	15,80%	8,60%		26,73%	7,09%	36,04%	41,83%	4,58%	16,99%	31,43%	11,27%		20,51%
	Temperatura	5,76%	16,88%	16,16%	9,04%		46,06%	3,74%				34,86%	37,12%		11,08%	19,31%
	CMV	0,02%	30,75%			29,84%			37,88%	25,16%	12,75%	29,24%		16,31%		13,61%
Variável numérica dependente	Biogás															
<b>Treino</b>																
Nº de casos	34	40	38	35	38	37	39	38	38	38	39	38	38	37	38	38
Nº de tentativas	157	5E+07	1E+06	3E+07	1E+06	96	4,5E+07	93	177	4E+07	85	154	107	106	1E+06	1E+06
% de prev. inadequadas (15% tol.)	0,00%	12,50%	2,63%	20,00%	10,53%	35,14%	33,33%	57,89%	50,00%	2,63%	38,46%	15,79%	39,47%	10,81%	15,79%	15,79%
Erro médio quadrático	1,767	111,43	16,00	112,82	82,11	262,52	185,23	294,28	278,01	45,34	229,97	143,11	225,81	108,08	156,17	156,17
Erro médio absoluto	0,5786	77,39	7,796	72,57	56,89	192,47	136,15	239,29	211,75	28,57	172,01	84,82	161,68	74,67	94,67	94,67
Desvio padrão de erro absoluto	1,669	80,18	13,97	86,38	59,21	178,52	125,59	171,29	180,15	35,20	152,64	115,26	157,63	78,14	125,59	125,59
<b>Teste</b>																
Nº de casos	9	10	10	9	10	9	10	10	10	9	10	9	9	9	10	10
% de prev. inadequadas (15% tol.)	55,56%	60,00%	70,00%	66,67%	80,00%	44,44%	80,00%	80,00%	70,00%	77,78%	60,00%	66,67%	44,44%	55,56%	40,00%	40,00%
Erro médio quadrático	440,88	409,04	509,39	451,10	377,26	250,94	426,59	389,05	398,05	356,55	330,83	404,96	224,27	426,58	339,04	339,04
Erro médio absoluto	297,85	332,97	404,87	357,11	315,81	199,16	372,12	304,44	319,25	310,05	273,12	311,28	193,31	305,71	227,27	227,27
Desvio padrão de erro absoluto	325,05	237,58	309,13	275,61	206,37	152,67	208,58	242,24	237,76	176,06	186,70	259,04	113,69	297,50	252,52	252,52

## ANEXO II.2 – 1º CONJUNTO DE REDES DA ETAR DE ÍLHAVO (DIGESTOR 1)

Nome		1	2	3	4	5	6	7	8	9	10	11	12	13	14
Tipo de RNA		GRNN	GRNN	GRNN	MLFN (2 nós)	GRNN	MLFN (3 nós)	MLFN (5 nós)	MLFN (3 nós)	MLFN (5 nós)	MLFN (5 nós)	MLFN (5 nós)	MLFN (2 nós)	MLFN (6 nós)	GRNN
Variáveis numéricas independentes (Inputs)		Impacto das variáveis													
Entrada do Digestor	SL4 MS	0,00%					5,66%	8,01%							
	SL4 MV	0,00%	36,09%	26,70%	6,06%	27,28%	17,07%	27,32%			20,21%	37,17%	20,92%	16,82%	
No Digestor	pH	33,34%		5,71%		20,44%			24,79%		18,84%				
	SL5 MS	0,00%			14,34%		1,46%	24,71%							9,15%
	SL5 MV	0,00%			20,11%		13,34%	4,53%		7,65%					10,52%
	REDOX	0,00%			12,02%		7,81%	10,71%	5,69%	7,41%					
	FOS/TAC	0,00%		18,29%			11,56%	19,72%	18,77%	27,10%	13,98%	23,20%	18,76%	10,30%	17,31%
	NH4+	66,66%			19,80%		8,34%	5,00%	12,11%	5,73%				20,04%	
	Volume Lamas	0,00%	28,97%	16,78%	11,92%	1,79%	10,05%		18,16%	9,38%	15,77%	19,86%	20,40%	20,79%	16,45%
	Temperatura (°C)	0,00%	27,94%	32,51%	15,74%	16,72%	14,65%		8,83%	34,24%	15,49%	19,77%	17,68%	17,77%	46,57%
CMV	0,00%	7,01%			33,78%	10,07%		11,65%	8,48%	15,71%		22,23%	14,28%		
Variável numérica dependente		Biogás													
<b>Treino</b>															
Nº de casos		5	315	232	5	233	5	5	5	5	232	233	233	61	228
Nº de tentativas		56	70	66	2E+06	93	1E+06	1E+06	1E+06	1E+06	1E+06	1E+06	1E+06	1E+06	70
% de prev. inadequadas (15% tol.)		0,00	37,46%	27,16%	0,00%	35,19%	0,00%	0,00%	0,00%	0,00%	31,90%	30,47%	36,91%	6,56%	28,07%
Erro médio quadrático		0,00	224,05	195,73	0,00	206,46	0,00	0,00	0,00	0,00	204,41	206,17	241,76	47,31	201,82
Erro médio absoluto		0,00	168,25	143,17	0,00	153,85	0,00	0,00	0,00	0,00	151,47	155,10	182,38	28,89	151,06
Desvio padrão de erro absoluto		0,00	147,95	133,46	0,00	137,68	0,00	0,00	0,00	0,00	137,27	135,83	158,70	37,47	133,84
<b>Teste</b>															
Nº de casos		2	79	58	2	58	2	2	2	2	58	58	58	15	57
% de prev. inadequadas (15% tol.)		50,00%	49,37%	41,38%	0,00%	44,83%	0,00%	0,00%	0,00%	50,00%	44,83%	48,28%	44,83%	20,00%	36,84%
Erro médio quadrático		179,46	245,18	295,89	87,31	280,53	92,25	147,64	82,65	160,88	276,47	303,78	273,47	157,20	239,88
Erro médio absoluto		172,50	188,65	217,77	87,00	205,58	83,25	137,30	72,64	154,96	206,59	243,36	219,19	111,41	183,19
Desvio padrão de erro absoluto		49,50	156,61	200,32	7,442	190,87	39,75	54,30	39,42	43,25	183,72	181,82	163,51	110,90	154,86

### ANEXO II.3 – 1º CONJUNTO DE REDES DA ETAR DE ÍLHAVO (DIGESTOR 2)

Nome		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Tipo de RNA		GRNN	GRNN	GRNN	GRNN	GRNN	MLFN (4 nós)	MLFN (3 nós)	GRNN	GRNN	MLFN (2 nós)	MLFN (4 nós)	GRNN	MLFN (2 nós)	GRNN	MLFN (4 nós)
Variáveis numéricas independentes (Inputs)		Impacto das variáveis														
Entrada do Digestor	SL4 MS	3,40%						10,08%								0,13%
	SL4 MV	1,51%	1,39%	16,31%		30,43%	20,75%	11,83%			22,95%	11,63%	11,49%	24,91%	11,79%	
No Digestor	pH	1,02%		2,42%					9,68%				0,35%		0,21%	
	SL5 MS	1,75%					6,64%	17,70%			15,57%	11,56%	1,57%			16,7%
	SL5 MV	7,65%						3,89%	10,17%				1,92%			9,8%
	REDOX	12,54%			13,29%	33,24%	10,74%	9,26%	1,87%	28,45%	19,77%					
	FOS/TAC	11,32%		15,46%	0,93%	6,15%		12,98%	0,50%	2,39%			5,49%	11,94%		
	Condutividade	10,87%			15,52%	27,86%	13,48%	14,64%	22,23%	17,75%						
	NH4+	7,11%			14,60%	2,33%		13,34%	13,82%	13,53%						
	Volume Lamas	15,23%	52,45%	40,29%	49,66%		19,08%		46,81%	23,58%	25,45%	20,82%	48,02%	38,88%	49,30%	18,3%
	Temperatura (°C)	15,33%	22,22%	25,52%	6,01%		12,08%		5,08%	5,21%	16,25%	34,82%	31,16%	24,27%	38,57%	23,3%
CMV	12,28%	23,95%				13,33%			9,09%		21,18%				31,8%	
Variável numérica dependente		Biogás														
<b>Treino</b>																
Nº de casos		66	186	126	69	69	66	66	69	69	67	124	122	126	127	127
Nº de tentativas		116	81	78	90	76	3E+07	1E+06	90	135	1E+06	1E+06	91	1E+06	76	1E+06
% de prev. inadequadas (15% tol.)		0,00%	20,43%	10,32%	13,04%	21,74%	4,55%	9,09%	4,35%	2,90%	14,93%	32,26%	5,74%	42,06%	11,02%	32,2%
Erro médio quadrático		34,02	144,87	100,79	141,76	189,13	106,43	119,65	98,79	94,85	167,00	170,06	89,25	225,77	115,45	162,3
Erro médio absoluto		18,70	100,67	67,89	108,87	144,56	72,64	85,70	71,49	67,45	125,75	130,51	60,23	173,67	76,52	130,3
Desvio padrão de erro absoluto		28,42	104,17	74,49	90,78	121,95	77,79	83,50	68,17	66,68	109,90	109,03	65,85	144,27	86,45	97,3
<b>Teste</b>																
Nº de casos		16	47	31	17	17	17	16	17	17	17	31	30	31	32	32
% de prev. inadequadas (15% tol.)		62,50%	36,17%	35,48%	17,65%	47,06%	17,65%	31,25%	47,06%	29,41%	52,94%	29,03%	36,67%	38,71%	53,13%	41,3%
Erro médio quadrático		288,60	240,21	181,47	164,86	332,22	207,39	322,98	267,56	225,84	254,68	167,58	249,43	160,30	295,65	214,3
Erro médio absoluto		248,85	167,28	135,21	129,52	249,68	165,40	270,79	218,41	158,05	231,72	125,55	168,15	131,36	215,11	165,3
Desvio padrão de erro absoluto		146,17	172,39	121,03	102,00	219,15	125,11	176,03	154,54	161,33	105,67	111,00	184,23	91,88	202,82	135,3

# **ANEXO III**

## **Segundo conjunto de RNA**

Anexo III.1 – 2º conjunto de redes da ETAR de Espinho

Anexo III.2.1 – 2º conjunto de redes da ETAR de Ílhavo (Digestor 1) [RNA 2 até 11]

Anexo III.2.2 – 2º conjunto de redes da ETAR de Ílhavo (Digestor 1) [RNA 12 até 18]

Anexo III.3 – 2º conjunto de redes da ETAR de Ílhavo (Digestor 2)

### ANEXO III.1 – 2º CONJUNTO DE REDES DA ETAR DE ESPINHO

Nome		3	3.1	3.2	3.3	5	5.1	5.2	5.3	6	6.1	6.2	6.3	10	10.1	10.2	10.3	16	
Tipo de RNA		GRNN	GRNN	GRNN	GRNN	MLFN (5 nós)	MLFN (2 nós)	MLFN (4 nós)	GRNN	GRNN	GRNN	MLFN (2 nós)	GRNN	MLFN (4 nós)	MLFN (5 nós)	GRNN	GRNN	GRNN	
Variáveis numéricas independentes (Inputs)																			
Entrada do Digestor	SL4 pH													12,55%	11,74%	18,91%	12,26%	11,95%	
	SL4 MS									9,80%	13,55%	20,32%	1,42%						
	SL4 MV	15,20%	0,04%	0,53%	0,00%					12,82%	12,36%	14,49%	18,22%	11,38%	12,63%	10,39%	0,98%		
	SL4 Alcalinidade									4,20%	0,09%	15,82%	12,19%						
	SL4 AGV									0,39%	0,11%	10,53%	11,41%						
Dentro do Digestor	SL5 pH	19,91%	29,51%	6,16%	51,17%														
	SL5 MS					23,32%	42,01%	24,13%	20,82%					15,72%	14,55%	0,09%	0,33%	36,78%	
	SL5 MV					27,16%	37,25%	40,62%	19,80%					31,70%	20,20%	22,48%	25,71%	2,05%	
	SL5 Alcalinidade	16,92%	19,68%	0,12%	0,00%	19,67%	7,64%	23,38%	31,93%					11,33%	13,27%	7,37%	30,03%		
	SL5 AGV	16,01%	22,27%	0,05%	0,00%														
	Caudal	15,80%	0,06%	34,65%	0,00%					26,73%	27,69%	17,55%	23,30%	4,58%	12,15%	20,12%	11,13%	19,26%	
	Temperatura	16,16%	28,43%	58,48%	48,83%					46,06%	46,20%	21,29%	33,47%					29,97%	
CMV					29,84%	13,11%	11,87%	27,46%					12,75%	15,45%	20,64%	19,56%			
Variável numérica dependente		Biogás																	
<b>Treino</b>																			
Nº de casos		38	38	38	38	38	38	38	38	37	37	37	37	38	38	38	38	38	
Nº de tentativas		1000000	133	134	88	1E+06	1E+06	1E+06	68	96	93	1E+06	92	4E+07	1E+06	177	123	149	
% de prev. inadequadas (15% tol.)		2,63%	2,63%	39,47%	26,32%	10,53%	39,47%	18,42%	0,00%	35,14%	21,62%	32,43%	27,03%	2,63%	13,16%	18,42%	18,42%	7,89%	
Erro médio quadrático		16,00	69,86	241,20	179,94	82,11	212,76	148,06	0,000	262,52	199,42	234,95	211,83	45,34	76,38	147,94	126,70	98,73	
Erro médio absoluto		7,796	40,84	179,93	126,15	56,89	164,96	92,44	0,000	192,47	125,76	156,08	136,64	28,57	37,76	96,22	87,29	54,07	
Desvio padrão de erro absoluto		13,97	56,68	160,63	128,32	59,21	134,36	115,67	0,000	178,52	154,76	175,62	161,87	35,20	66,40	112,37	91,83	82,61	
<b>Teste</b>																			
Nº de casos		10	10	10	10	10	10	10	10	9	9	9	9	9	9	9	9	10	
% de prev. inadequadas (15% tol.)		70,00%	50,00%	50,00%	70,00%	80,00%	80,00%	50,00%	80,00%	44,44%	66,67%	88,89%	55,56%	77,78%	77,78%	77,78%	77,78%	40,00%	
Erro médio quadrático		509,39	336,87	408,37	310,13	377,26	377,11	296,26	348,83	250,94	374,44	355,07	291,95	356,55	381,91	273,76	477,83	358,71	
Erro médio absoluto		404,87	265,38	314,72	271,96	315,81	308,28	239,15	313,00	199,16	318,69	314,65	232,43	310,05	352,24	246,15	385,97	237,76	
Desvio padrão de erro absoluto		309,13	207,49	260,22	149,05	206,37	217,21	174,86	154,00	152,67	196,57	164,53	176,66	176,06	147,60	119,81	281,69	268,59	
Média EMQ Teste		391,19				349,86				318,10				372,51					

**ANEXO III.2A – 2º CONJUNTO DE REDES DA ETAR DE ÍLHAVO (DIGESTOR 1) [RNA**

Nome		2	2.1	2.2	2.3	3	3.1	3.2	3.3	5	5.1	5.2	5.3	10	10.1		
Tipo de RNA		GRNN	GRNN	GRNN	GRNN	GRNN	GRNN	GRNN	GRNN	GRNN	MLFN (2 nós)	MLFN (3 nós)	GRNN	MLFN (5 nós)	MLFN (3 nós)		
Variáveis numéricas independentes (Inputs)		Impacto das variáveis															
Entrada do Digestor	SL4 MS																
	SL4 MV	36,09%	23,81%	25,62%	25,55%	26,70%	37,00%	22,83%	27,26%	27,28%	19,53%	21,32%	19,90%	20,21%	23,51%		
No Digestor	pH					5,71%	7,54%	8,98%	6,78%	20,44%	16,50%	22,70%	10,34%	18,84%	19,54%		
	SL5 MS																
	SL5 MV																
	REDOX																
	FOS/TAC					18,29%	21,50%	23,42%	25,21%					13,98%	15,41%		
	NH4+																
	Volume Lamas	28,97%	18,43%	16,90%	19,00%	16,78%	9,49%	17,36%	13,52%	1,79%	19,57%	24,75%	4,62%	15,77%	8,91%		
Temperatura (°C)	27,94%	30,35%	31,24%	33,76%	32,51%	24,48%	27,40%	27,23%	16,72%	18,21%	19,87%	41,09%	15,49%	15,89%			
CMV	7,01%	27,40%	26,24%	21,69%						33,78%	26,19%	11,36%	24,05%	15,71%	16,74%		
Variável numérica dependente		Biogás															
<b>Treino</b>																	
Nº de casos		315	315	315	315	232	232	232	232	233	233	233	233	232	232		
Nº de tentativas		70	54	52	62	66	76	75	69	93	1E+06	1E+06	74	1E+06	1E+06		
% de prev. inadequadas (15% tol.)		37,46%	38,41%	37,46%	38,10%	27,16%	24,57%	27,59%	29,31%	35,19%	36,91%	40,34%	26,18%	31,90%	31,03%		
Erro médio quadrático		224,05	229,77	234,08	229,40	195,73	198,07	190,50	212,68	206,46	233,32	237,24	179,49	204,41	233,83		
Erro médio absoluto		168,25	173,37	174,35	171,07	143,17	141,41	136,97	153,97	153,85	181,65	186,06	131,40	151,47	165,34		
Desvio padrão de erro absoluto		147,95	150,78	156,19	152,84	133,46	138,69	132,41	146,72	137,68	146,43	147,19	122,27	137,27	165,35		
<b>Teste</b>																	
Nº de casos		79	79	79	79	58	58	58	58	58	58	58	58	58	58		
% de prev. inadequadas (15% tol.)		49,37%	53,16%	51,90%	44,30%	41,38%	44,83%	41,38%	51,72%	44,83%	50,00%	46,55%	58,62%	44,83%	39,66%		
Erro médio quadrático		245,18	265,90	242,73	246,45	295,89	260,20	245,38	278,19	280,53	311,16	271,76	318,32	276,47	228,56		
Erro médio absoluto		188,65	210,08	194,96	197,08	217,77	204,89	188,71	222,77	205,58	234,43	216,02	240,48	206,59	179,77		
Desvio padrão de erro absoluto		156,61	163,00	144,59	147,97	200,32	160,38	156,84	166,62	190,87	204,60	164,89	208,56	183,72	141,16		
Média EMQ Teste		250,06					269,92					295,44					256,6

**ANEXO III.2B – 2º CONJUNTO DE REDES DA ETAR DE ÍLHAVO (DIGESTOR 1) [RNA 1]**

Nome		12	12.1	12.2	12.3	14	14.1	14.2	14.3	15	15.1	15.2	15.3	16	16.1	16.2	16.3	17	
Tipo de RNA		MLFN (2 nós)	GRNN	GRNN	MLFN (5 nós)	GRNN	GRNN	GRNN	GRNN	GRNN	MLFN (2 nós)	GRNN	GRNN	GRNN	GRNN	GRNN	GRNN	GRNN	
Variáveis numéricas independentes (Inputs)		Impacto das variáveis																	
Entrada do Digestor	SL4 MS																		
	SL4 MV	20,92%	19,36%	22,94%	15,24%						13,93%	24,55%	17,82%	11,43%	24,10%	25,11%	27,16%	12,66%	37,15%
No Digestor	pH																		6,87%
	SL5 MS					9,15%	14,50%	14,68%	13,90%										
	SL5 MV					10,52%	11,28%	10,13%	4,67%										
	REDOX																		
	FOS/TAC	18,76%	21,27%	26,74%	13,15%	17,31%	23,59%	20,66%	15,03%	18,13%	17,91%	20,22%	26,23%	20,98%	23,54%	24,74%	21,25%	20,79%	20,79%
	NH4+																		
Volume Lamas		20,40%	7,15%	17,43%	17,88%	16,45%	18,84%	9,51%	16,89%	9,89%	14,33%	7,10%	0,32%						
	Temperatura (°C)	17,68%	23,94%	29,42%	16,19%	46,57%	31,78%	45,02%	49,52%	38,55%	29,84%	29,51%	33,82%	32,35%	22,34%	25,76%	39,02%	35,20%	35,20%
CMV		22,23%	28,28%	3,46%	37,55%					19,50%	13,37%	25,35%	28,19%	22,57%	29,02%	22,33%	27,07%		
Variável numérica dependente																			
<b>Treino</b>		<b>Treino</b>																	
Nº de casos		233	233	233	233	228	228	228	228	233	233	233	233	233	233	233	233	235	
Nº de tentativas		1E+06	59	62	1E+06	70	67	60	68	67	1E+06	60	89	60	59	59	67	98	
% de prev. inadequadas (15% tol.)		36,91%	30,04%	29,61%	29,18%	28,07%	20,61%	31,14%	36,40%	25,75%	34,33%	32,62%	30,47%	28,33%	27,04%	33,48%	33,48%	32,34%	
Erro médio quadrático		241,76	208,20	213,47	209,22	201,82	161,77	196,72	222,46	200,77	248,47	218,19	222,36	217,62	221,00	225,69	228,85	227,16	
Erro médio absoluto		182,38	150,90	153,52	153,54	151,06	113,11	144,72	165,53	142,72	180,25	159,51	162,07	157,61	157,57	165,92	169,16	161,76	
Desvio padrão de erro absoluto		158,70	143,45	148,33	142,13	133,84	115,65	133,25	148,62	141,21	171,03	148,88	152,25	150,06	154,96	153,00	154,13	159,55	
<b>Teste</b>		<b>Teste</b>																	
Nº de casos		58	58	58	58	57	57	57	57	58	58	58	58	58	58	58	58	59	
% de prev. inadequadas (15% tol.)		44,83%	55,17%	37,93%	43,10%	36,84%	47,37%	52,63%	43,86%	46,55%	39,66%	34,48%	29,31%	29,31%	37,93%	37,93%	29,31%	32,20%	
Erro médio quadrático		273,47	309,96	215,16	268,41	239,88	311,96	324,95	244,42	266,06	235,94	240,83	263,72	220,02	244,90	268,00	276,89	224,16	
Erro médio absoluto		219,19	241,90	161,14	206,23	183,19	234,58	248,15	199,49	204,63	184,76	172,73	179,65	166,55	190,91	200,30	189,31	166,26	
Desvio padrão de erro absoluto		163,51	193,80	142,57	171,79	154,86	205,64	209,80	141,22	170,04	146,74	167,82	193,07	143,77	153,39	178,05	202,07	150,44	
Média EMQ Teste		266,75				280,30				251,64				252,45					

### ANEXO III.3 – 2º CONJUNTO DE REDES DA ETAR DE ÍLHAVO (DIGESTOR 2)

Nome		2	2.1	2.2	2.3	3	3.1	3.2	3.3	12	12.1	12.2	12.3	13	13.1	13.2	13.3	14	14.1	14.2		
Tipo de RNA		GRNN	GRNN	GRNN	GRNN	GRNN	GRNN	GRNN	MLFN (4 nós)	GRNN	GRNN	GRNN	GRNN	MLFN (2 nós)	MLFN (2 nós)	GRNN	GRNN	GRNN	MLFN (4 nós)	MLFN (2 nós)		
Variáveis numéricas independentes (Inputs)		Impacto das variáveis																				
Entrada do Digestor	SL4 MS																		0,13%	16,08%	14,23%	
	SL4 MV	1,39%	19,28%	16,76%	7,65%	16,31%	13,79%	12,37%	13,95%	11,49%	12,94%	11,98%	10,47%	24,91%	23,94%	14,03%	13,94%	11,79%	33,20%	34,40%		
No Digestor	pH					2,42%	0,37%	2,02%	5,65%	0,35%	0,55%	0,94%	0,86%					0,21%	4,66%	2,84%		
	SL5 MS									1,57%	5,24%	0,85%	11,90%									
	SL5 MV									1,92%	4,09%	5,48%	3,15%									
	REDOX																					
	FOS/TAC					15,46%	14,91%	14,41%	16,30%	5,49%	13,55%	12,89%	2,95%	11,94%	12,70%	15,25%	14,32%					
	Condutividade																					
	NH4+																					
Volume Lamas	52,45%	35,47%	44,67%	26,35%	40,29%	48,56%	47,45%	30,84%	48,02%	40,87%	38,85%	39,56%	38,88%	38,30%	46,97%	50,43%	49,30%	31,29%	31,56%			
Temperatura (°C)	22,22%	25,03%	36,20%	41,10%	25,52%	22,37%	23,75%	33,26%	31,16%	22,75%	29,00%	31,10%	24,27%	25,06%	23,75%	21,31%	38,57%	14,77%	16,98%			
CMV	23,95%	20,22%	2,37%	24,90%																		
Variável numérica dependente		Biogás																				
		Treino																				
Nº de casos		186	186	186	186	126	126	126	126	122	122	122	122	126	126	126	126	127	127	127		
Nº de tentativas		81	18177427	64	73	78	75	74	1E+06	91	80	90	88	1E+06	1E+06	61	73	76	1E+06	1E+06		
% de prev. inadequadas (15% tol.)		20,43%	41,94%	15,59%	22,04%	10,32%	14,29%	14,29%	30,16%	5,74%	6,56%	7,38%	1,64%	42,06%	43,65%	11,11%	12,70%	11,02%	37,01%	44,09%		
Erro médio quadrático		144,87	215,04	133,86	164,12	100,79	125,78	112,45	145,55	89,25	83,00	81,45	38,43	225,77	218,06	105,54	108,69	115,45	165,84	216,80		
Erro médio absoluto		100,67	166,85	90,79	116,14	67,89	84,73	75,63	109,18	60,23	52,92	53,63	23,91	173,67	167,97	67,96	74,15	76,52	131,69	170,69		
Desvio padrão de erro absoluto		104,17	135,66	98,37	115,96	74,49	92,96	83,21	96,26	65,85	63,95	61,30	30,08	144,27	139,06	80,75	79,46	86,45	100,81	133,66		
		Teste																				
Nº de casos		47	47	47	47	31	31	31	31	30	30	30	30	31	31	31	31	32	32	32		
% de prev. inadequadas (15% tol.)		36,17%	38,30%	25,53%	46,81%	35,48%	29,03%	25,81%	48,39%	36,67%	23,33%	36,67%	33,33%	38,71%	38,71%	25,81%	32,26%	53,13%	59,38%	40,63%		
Erro médio quadrático		240,21	280,21	239,97	274,91	181,47	210,00	179,79	275,40	249,43	175,65	231,97	305,03	160,30	201,32	206,42	208,40	295,65	229,10	216,68		
Erro médio absoluto		167,28	195,23	166,66	214,96	135,21	151,96	125,92	211,43	168,15	128,24	169,95	201,36	131,36	160,26	159,86	151,35	215,11	197,37	162,26		
Desvio padrão de erro absoluto		172,39	201,01	172,66	171,37	121,03	144,94	128,34	176,49	184,23	120,04	157,89	229,12	91,88	121,84	130,59	143,26	202,82	116,33	143,59		
Média EMQ Teste		258,83				211,67				240,52				194,11				257,82				

# **ANEXO IV**

## **Terceiro conjunto de RNA**

Anexo IV.1 – 3º conjunto de redes da ETAR de Espinho

Anexo IV.2 – 3º conjunto de redes da ETAR de Ílhavo (Digestor 1)

Anexo IV.3 – 3º conjunto de redes da ETAR de Ílhavo (Digestor 2)

### ANEXO IV.1 – 3º CONJUNTO DE REDES DA ETAR DE ESPINHO

Melhores RNA	Variáveis utilizadas															
RNA 6	SL4 MS, SL4 MV, SL4 Alcalinidade, SL4 AGV, Caudal de lamas, Temperatura	Designação	6.0	6.1	6.2	6.3	6.4	6.5	6.6	6.7	6.8	6.9	6.10	6.11	6.12	
		EMQ Treino	262,52	199,42	234,95	211,83	221,22	153,44	213,40	223,55	235,07	264,05	254,26	282,57	282,57	282,57
		EMQ Teste	250,94	374,44	355,07	291,95	353,57	314,53	289,94	469,81	273,57	250,73	245,02	274,57	274,57	274,57
RNA 19	SL4 pH, Caudal de lamas, Temperatura, SL5 pH, CMV	Designação	19.0	19.1	19.2	19.3	19.4	19.5	19.6	19.7	19.8	19.9	19.10	19.11	19.12	
		EMQ Treino	75,40	39,01	198,07	62,95	47,75	121,37	97,00	97,04	249,94	0,07290	91,25	5,25	5,25	5,25
		EMQ Teste	252,67	368,16	279,14	271,50	286,81	542,17	368,92	301,90	432,00	288,39	284,45	397,57	397,57	397,57
RNA 16	SL4 pH, Caudal de lamas, Temperatura, SL5 MS, SL5 MV	Designação	16.0	16.1	16.2	16.3	16.4	16.5	16.6	16.7	16.8	16.9	16.10	16.11	16.12	
		EMQ Treino	98,73	59,72	48,25	122,19	89,05	65,14	65,66	71,42	167,64	100,17	110,63	0,5	0,5	0,5
		EMQ Teste	358,71	301,33	328,03	387,31	407,70	424,71	483,93	229,66	302,99	490,36	366,66	427,57	427,57	427,57
		Designação		16.16	16.17	16.18	16.19	16.20	16.21	16.22	16.23	16.24	16.25	16.26	16.27	
		EMQ Treino		136,92	109,35	96,69	151,86	0,2411	5,351	131,70	48,43	102,88	121,92	195,57	195,57	
		EMQ Teste		189,62	357,50	445,81	275,72	375,92	478,48	199,93	304,62	459,35	173,44	354,57	354,57	

### ANEXO IV.2 – 3º CONJUNTO DE REDES DA ETAR DE ÍLHAVO (DIGESTOR 1)

Melhores RNA	Variáveis utilizadas														
RNA 2	SL4 MV, Volume de Lamas, Temperatura, CMV	Designação	2.0	2.1	2.2	2.3	2.4	2.5	2.6	2.7	2.8	2.9	2.10	2.11	
		EMQ Treino	224,05	229,77	234,08	229,40	226,22	222,84	226,42	211,74	200,31	229,45	228,92	231,2	
		EMQ Teste	245,18	265,90	242,73	246,45	260,22	299,20	261,71	289,05	278,12	250,51	271,22	235,6	
		Designação	2.16	2.17	2.18	2.19	2.20	2.21	2.22	2.23	2.24	2.25	2.26		
		EMQ Treino	232,85	226,49	217,21	218,16	230,38	231,38	211,90	222,25	225,87	211,14	226,0		
		EMQ Teste	242,42	259,49	267,49	256,98	264,77	255,28	277,46	272,78	236,39	281,85	256,1		
RNA 15	SL4 MV, FOS/TAC, Volume de lamas, Temperatura, CMV	Designação	15.0	15.1	15.2	15.3	15.4	15.5	15.6	15.7	15.8	15.9	15.10	15.11	
		EMQ Treino	200,77	248,47	218,19	222,36	214,36	205,83	211,12	222,92	209,03	203,72	206,88	206,3	
		EMQ Teste	266,06	235,94	240,83	263,72	300,60	243,75	274,12	252,66	265,65	296,19	313,84	240,9	
RNA 11	SL4 MV, FOS/TAC, Volume de Lamas, Temperatura	Designação	11.0	11.1	11.2	11.3	11.4	11.5	11.6	11.7	11.8	11.9	11.10	11.11	
		EMQ Treino	206,17	223,89	223,08	198,72	216,16	199,93	209,51	223,41	233,35	219,40	212,21	212,4	
		EMQ Teste	303,78	210,39	214,17	251,97	295,04	307,34	281,29	240,29	258,98	258,83	302,06	289,8	
		Designação	11.16	11.17	11.18	11.19	11.20	11.21	11.22	11.23	11.24	11.25	11.26		
		EMQ Treino	201,77	208,47	215,32	217,79	217,76	203,23	202,41	223,89	224,70	212,10	228,8		
		EMQ Teste	267,01	252,46	277,43	243,24	248,92	257,62	266,72	232,86	278,71	284,33	257,0		

### ANEXO IV.3 – 3º CONJUNTO DE REDES DA ETAR DE ÍLHAVO (DIGESTOR 2)

Melhores RNA	Variáveis utilizadas													
RNA 2	SL4 MV, Volume de Lamas, Temperatura, CMV	Designação	2.0	2.1	2.2	2.3	2.4	2.5	2.6	2.7	2.8	2.9	2.10	2.11
		EMQ Treino	215,04	144,87	133,86	164,12	165,17	152,19	116,36	128,52	103,84	140,14	141,41	108,2
		EMQ Teste	280,21	240,21	239,97	274,91	200,09	201,01	257,74	218,74	248,61	192,91	251,18	277,8
RNA 13	SL4 MV, FOS/TAC, Volume de Lamas, Temperatura	Designação	13.0	13.1	13.2	13.3	13.4	13.5	13.6	13.7	13.8	13.9	13.10	13.11
		EMQ Treino	225,77	218,06	105,54	108,69	118,24	137,19	111,58	105,23	130,22	109,87	116,90	117,8
		EMQ Teste	160,30	201,32	206,42	208,40	161,24	208,25	230,73	252,54	165,87	238,58	253,02	212,3
RNA 16	SL5 MS, Volume de Lamas, Temperatura, CMV	Designação	16.0	16.1	16.2	16.3	16.4	16.5	16.6	16.7	16.8	16.9	16.10	16.11
		EMQ Treino	134,30	174,36	171,28	106,87	113,14	129,32	96,94	103,39	40,67	81,40	132,59	105,0
		EMQ Teste	198,70	217,07	232,40	232,24	217,77	286,32	293,80	274,20	284,48	284,27	258,28	239,7
RNA 17	SL4 MV, FOS/TAC, Volume de Lamas, Temperatura, CMV	Designação	17.0	17.1	17.2	17.3	17.4	17.5	17.6	17.7	17.8	17.9	17.10	17.11
		EMQ Treino	135,48	182,69	171,68	100,21	126,78	121,18	110,65	131,74	126,39	93,89	112,76	121,6
		EMQ Teste	129,43	225,44	235,72	198,13	231,74	206,44	196,48	159,22	207,21	227,35	236,59	176,4
		Designação		17.16	17.17	17.18	17.19	17.20	17.21	17.22	17.23	17.24	17.25	17.26
		EMQ Treino		118,11	103,97	83,92	124,88	116,81	135,61	100,71	120,31	126,60	127,30	120,2
		EMQ Teste		172,38	204,97	248,07	180,11	197,70	136,25	211,24	213,80	165,83	192,16	247,1

# **ANEXO V**

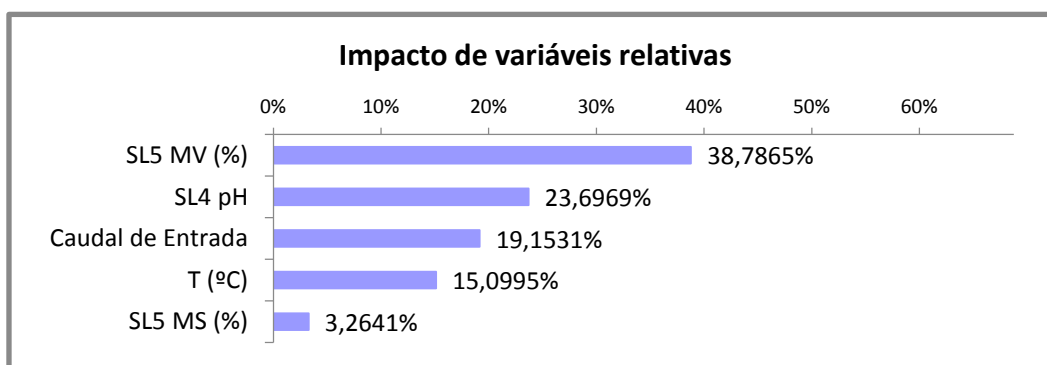
## **Informação resultante das fases Treino/Teste da melhor RNA para a ETAR de Espinho**

Anexo V.1 – Relatório de Treino/Teste da RNA 16.25 e impacto das variáveis

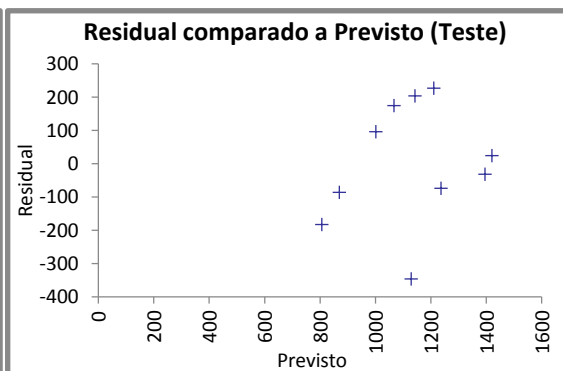


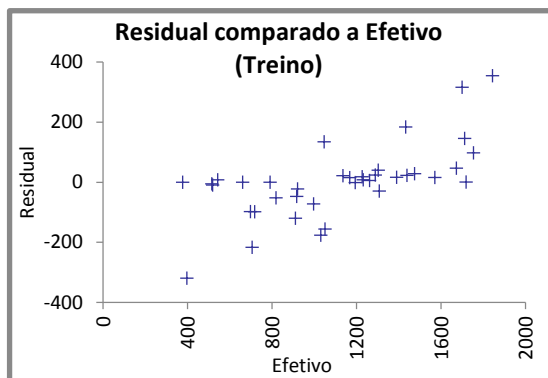

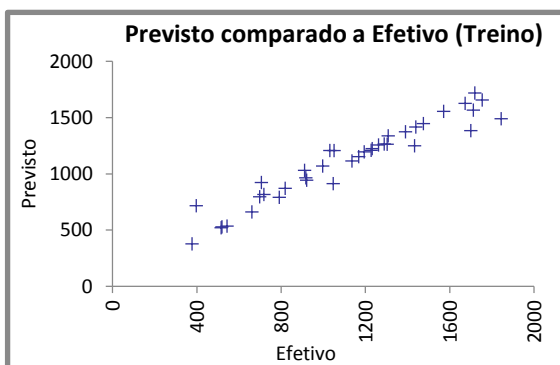


Anexo V.2 – Outros gráficos provenientes do Relatório da RNA 16.25

## ANEXO V.1 – RELATÓRIO DE TREINO/TESTE DA RNA 16.25 E IMPACTO DAS VARIÁVEIS

<b>Resumo</b>	
<i>Informações da rede</i>	
Nome	Rede treinada em Conjunto de dados núm. 1
Configuração	Previsor numérico de GRNN
Local	Esta pasta de trabalho
Variáveis categóricas independentes	0
Variáveis numéricas independentes	5 (SL4 pH, Caudal de Entrada, T (°C), SL5 MS (%), SL5 MV (%))
Variável dependente	Var. numérica (Biogás Consumido)
<i>Treinamento</i>	
Número de casos	38
Tempo de treinamento	00:00:00
Número de tentativas	122
Motivo da parada	Parada automática
% previsões inadequadas (15% tolerância)	13,1579%
Erro médio quadrático	121,92
Erro médio absoluto	77,01
Desvio padrão de erro absoluto	94,51
<i>Teste</i>	
Número de casos	10
% previsões inadequadas (15% tolerância)	40,0000%
Erro médio quadrático	173,44
Erro médio absoluto	144,71
Desvio padrão de erro absoluto	95,60
<i>Conjunto de dados</i>	
Nome	Conjunto de dados núm. 1
Número de linhas	50
Tags de casos manuais	NÃO
<i>Análise de impacto de variáveis</i>	
SL5 MV (%)	38,7865%
SL4 pH	23,6969%
Caudal de Entrada	19,1531%
T (°C)	15,0995%
SL5 MS (%)	3,2641%



## ANEXO V.2 – OUTROS GRÁFICOS PROVENIENTES DO RELATÓRIO DA RNA 16.25



# **ANEXO VI**


## **Informação resultante das fases Treino/Teste da melhor RNA para a ETAR de Ílhavo (Digestor 1)**

Anexo VI.1 – Relatório de Treino/Teste da RNA 11.1 e impacto das variáveis









Anexo VI.2 – Outros gráficos provenientes do Relatório da RNA 11.1

## ANEXO VI.1 – RELATÓRIO DE TREINO/TESTE DA RNA 11.1 E IMPACTO DAS VARIÁVEIS

Resumo	
<b>Informações da rede</b>	
Nome	Rede treinada em Digestor 1 todos os dados (3)
Configuração incluída na busca	GRNN, MLFN 2 a 6 nós
Melhor configuração	Previsor numérico de GRNN
Local	Esta pasta de trabalho
Variáveis categóricas independentes	0
Variáveis numéricas independentes	4 (SL4 %MV, SL5A FOS/TAC (AGV/ALC), Volume lamas digestor 1, T (°C) digestão 1)
Variável dependente	Var. numérica (Volume biogás 1)
<b>Treinamento</b>	
Número de casos	233
Tempo de treinamento	00:00:00
Número de tentativas	59
Motivo da parada	Parada automática
% previsões inadequadas (15% tolerância)	34,7639%
Erro médio quadrático	223,89
Erro médio absoluto	162,84
Desvio padrão de erro absoluto	153,65
<b>Teste</b>	
Número de casos	58
% previsões inadequadas (15% tolerância)	36,2069%
Erro médio quadrático	210,39
Erro médio absoluto	162,42
Desvio padrão de erro absoluto	133,74
<b>Conjunto de dados</b>	
Nome	Digestor 1 todos os dados
Número de linhas	400
Tags de casos manuais	NÃO
<b>Análise de impacto de variáveis</b>	
T (°C) digestão 1	37,1420%
SL4 %MV	27,1959%
SL5A FOS/TAC (AGV/ALC)	19,9064%
Volume lamas digestor 1	15,7556%



## ANEXO VI.2 – OUTROS GRÁFICOS PROVENIENTES DO RELATÓRIO DA RNA 11.1



# **ANEXO VII**


## **Informação resultante das fases Treino/Teste da melhor RNA para a ETAR de Ílhavo (Digestor 2)**

Anexo VII.1 – Relatório de Treino/Teste da RNA 17.0 e impacto das variáveis

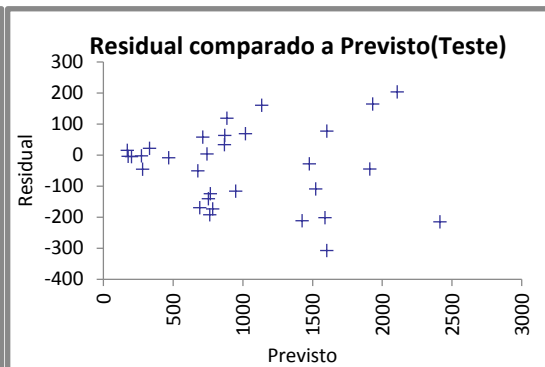







Anexo VII.2 – Outros gráficos provenientes do Relatório da RNA 17.0

## ANEXO VII.1 – RELATÓRIO DE TREINO/TESTE DA RNA 17.0 E IMPACTO DAS VARIÁVEIS

Resumo	
<b>Informações da rede</b>	
Nome	Rede treinada em Conjunto de dados núm. 1 (2)
Configuração incluída na busca	GRNN, MLFN 2 a 6 nós
Melhor configuração	Previsor numérico de GRNN
Local	Esta pasta de trabalho
Variáveis categóricas independentes	0
Variáveis numéricas independentes	5 (SL4 %MV, SL5B FOS/TAC (AGV/ALC), Volume lamas digestor 2, Temp digestão 2, CMV Dig 2)
Variável dependente	Var. numérica (Volume biogás 2)
<b>Treinamento</b>	
Número de casos	126
Tempo de treinamento	00:00:00
Número de tentativas	84
Motivo da parada	Parada automática
% previsões inadequadas (15% tolerância)	19,8413%
Erro médio quadrático	135,48
Erro médio absoluto	93,86
Desvio padrão de erro absoluto	97,71
<b>Teste</b>	
Número de casos	31
% previsões inadequadas (15% tolerância)	25,8065%
Erro médio quadrático	129,43
Erro médio absoluto	101,36
Desvio padrão de erro absoluto	80,49
<b>Conjunto de dados</b>	
Nome	Conjunto de dados núm. 1
Número de linhas	236
Tags de casos manuais	NÃO
<b>Análise de impacto de variáveis</b>	
Temp digestão 2	30,5621%
CMV Dig 2	27,3576%
Volume lamas digestor 2	19,1897%
SL5B FOS/TAC (AGV/ALC)	17,1121%
SL4 %MV	5,7785%



## ANEXO VII.2 – OUTROS GRÁFICOS PROVENIENTES DO RELATÓRIO DA RNA 17.0



# **ANEXO VIII**

**EXEMPLO DA PREVISÃO DE UMA RNA APÓS A FASE DE TREINO/TESTE**

## Anexo VIII - Exemplo da Previsão de uma RNA após a fase de Treino/Teste

Data	Dia	SL4 %MS	SL4 %MV	SL5B pH	SL5B %MS	SL5B %MV	SL5B REDOX	SL5B FOS/TAC (AGV/ALC)	Condutividade SL5B	SL5B NH4+	Volume lamas digestor 2	T (°C)	CMV Digestor 2	Volume biogás 2	Tag usada	Previsão	Adequada/Inadequada	Residual
20-Mai-2012	1	3,9	2,8	7,3	2,2	1,3		0,1019108			40	32,6	0,373333	179	treinar			
22-Mai-2012	2	3,7	2,8	7,3	1,7	1		0,1050725			39	33,2	0,364	175	treinar			
24-Mai-2012	3	4,3	3,3								36	34,4	0,396	181				
27-Mai-2012	4	3,8	2,9	7,3	1,7	1		0,0512821			35	34,9	0,338333	198	treinar			
29-Mai-2012	5	4,1	2,9	7,3	1,6	1		0,0425532			48	34,8	0,464	196	treinar			
31-Mai-2012	6	4,8	3,6								70	35	0,84	116				
03-Jun-2012	7	3,1	2,8	7,3	2,1	1,1		0,0855263			72	35,3	0,672	822,8	treinar			
05-Jun-2012	8	3,3		7,2				0,0699301			68	35,7		845,75				
07-Jun-2012	9										70	36,3		804,95				
10-Jun-2012	10	5	3,6	7,4		1,1		0,0642857			71	36,6	0,852	917	testar	941,66	Adequada	-24,66
12-Jun-2012	11	4,7	3,7	7,3	1,8	1,1		0,0875			78	36,8	0,962	834	treinar			
14-Jun-2012	12	3,4	2,6								54	36,9	0,468	635				
17-Jun-2012	13	3,3	2,5	7,3	1,9	1,2		0,0608108			70	36,6	0,583333	552	treinar			
19-Jun-2012	14	3,6	2,8	7,3	2	1,2		0,0641892			67	36,6	0,625333	739	treinar			
21-Jun-2012	15	3,6	2,6								71	36,3	0,615333	768				
24-Jun-2012	16	4,2	3	7,2	2	1,3		0,1280488			73	36,3	0,73	1032	treinar			
26-Jun-2012	17	3,8	2,8	7,3	2	1,3		0,0609756			81	36,4	0,756	935	testar	846,58	Adequada	88,42
28-Jun-2012	18	4,1	3								83	36,4	0,83	1032				
01-Jul-2012	19	3,6	2,6	7,3	2,1	1,3		0,0352564			72	35,8	0,624	929	treinar			
03-Jul-2012	20	3,4	2,5	7,3	2,4	1,5		0,0487805			79	36,1	0,658333	790	treinar			
05-Jul-2012	21	3,5	2,5								76	35,9	0,633333	942				
08-Jul-2012	22	4,5	3,1	7,3	2,6	1,6		0,1830508			79	35,8	0,816333	1089	treinar			
10-Jul-2012	23	4,3	3	7,4	2,2	1,3		0,0872093			61	35,7	0,61	889	testar	788,74	Adequada	100,26
12-Jul-2012	24	3,5	2,4								79	35,6	0,632	864				
15-Jul-2012	25	3,9	2,9	7,5	2,2	1,3		0,0615836			77	35,7	0,744333	1006	testar	865,18	Adequada	140,82

(...)

01-Abr-2015	514	3,2	2,5								150	38,9	1,25	1572				
05-Abr-2015	515	3,7	2,8	6,9	1,8	1,2	-314,1	0,16	9,49	1100	150	38,4	1,4	1958	testar	1644,31	Inadequada	313,69
07-Abr-2015	516	3,6	2,7	7,2	1,9	1,2	-266	0,15	9,7	1160	135	38,2	1,215	1923	treinar			
08-Abr-2015	517	3,6	2,7								147	38	1,323	1796				
12-Abr-2015	518	3	2,2	7,4	1,9	1,2	-315,7	0,13	9,67	1060	151	37,8	1,107333	1757	treinar			
14-Abr-2015	519	3,4	2,6	7,4	1,5	1	-308,4	0,15	9,58	1090	146	38	1,265333	1897	treinar			
15-Abr-2015	520	3,5	2,7								144	37,7	1,296	1510				
19-Abr-2015	521	3,4	2,5	7,3	1,9	1,3		0,14		858	121	36,3	1,008333	1555	testar	1481,67	Adequada	73,33
21-Abr-2015	522	3,3	2,5	6,9	2	1,3	-277,1	0,15	9,79	996	120	36,8	1	1352	testar	1571,91	Inadequada	-219,91
22-Abr-2015	523	3,3	2,4								120	36,9	0,96	1408				
26-Abr-2015	524	3,2	2,4	7,3	2	1,2	-273,9	0,15	9,79	1210	120	37,2	0,96	1935	treinar			
28-Abr-2015	525	3,4	2,6	7,2	2,1	1,3	-291,6	0,15	8,33	1250	120	36,5	1,04	1602	treinar			
03-Mai-2015	526	3,1	2,4	7,2	2,1	1,4	-268,8	0,14	9,4	1210	125	37,1	1	1389	treinar			
05-Mai-2015	527	3	2,3	7	2	1,3	-285,9	0,13	9,3	786	129	37,5	0,989	1589	treinar			
06-Mai-2015	528	3,3	2,6								133	37,4	1,152667	1532				
10-Mai-2015	529	2,9	2,3	7			-311	0,14	9,8	1200	125	37,2	0,958333	1488	treinar			
12-Mai-2015	530	3,3	2,6	7,3	2	1,3	-299,3	0,14	9,54	1170	106	37,1	0,918667	1513	treinar			
13-Mai-2015	531	3,1	2,5								150	37,2	1,25	1412				
17-Mai-2015	532	3,1	2,4	7,4	2	1,3	-338,8	0,13	8,83	915	141	37,3	1,128	1482	treinar			
19-Mai-2015	533	3,1	2,4	7,1	2	1,3	-327,2	0,12	8,65	1060	140	37	1,12	1267	testar	1592,95	Inadequada	-325,95
20-Mai-2015	534	3	2,5								140	36,7	1,166667	2028				

# **ANEXO IX**



## **Anexo IX - Gráficos da fase de Previsão das melhores RNA**

Anexo IX.1 – Gráficos da fase de Previsão da RNA 16.25 para a ETAR de Espinho



Anexo IX.2– Gráficos da fase de Previsão da RNA 11.1 para a ETAR de Ílhavo (Digestor 1)

Anexo IX.3– Gráficos da fase de Previsão da RNA 17.0 para a ETAR de Ílhavo (Digestor 2)

### ANEXO IX.1 – GRÁFICOS DA FASE DE PREVISÃO DA RNA 16.25 PARA A ETAR DE ES



## ANEXO IX.2– GRÁFICOS DA FASE DE PREVISÃO DA RNA 11.1 PARA A ETAR DE ÍLHAVO



### ANEXO IX.3– GRÁFICOS DA FASE DE PREVISÃO DA RNA 17.0 PARA A ETAR DE ÍLHAVO

