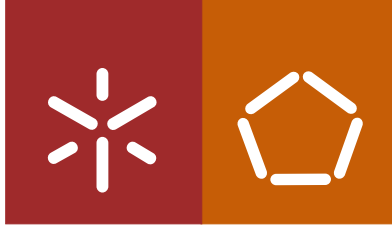


**Universidade do Minho**  
Escola de Engenharia

Ana Catarina Rodrigues Carreira

**Utilização de Redes Neurais Artificiais  
na gestão do processo de Digestão Anaeróbia**



**Universidade do Minho**  
Escola de Engenharia

Ana Catarina Rodrigues Carreira

## **Utilização de Redes Neurais Artificiais na gestão do processo de Digestão Anaeróbia**

Dissertação de Mestrado  
Mestrado Integrado em Engenharia Biológica  
Ramo de Tecnologia Ambiental

Trabalho efetuado sob a orientação da  
**Doutora Luciana José Ribeiro Pereira**  
e do  
**Engenheiro Adriano José Pereira de Magalhães**  
(representante da empresa Águas do Noroeste, S.A.)

outubro de 2014

## DECLARAÇÃO

**Nome:** Ana Catarina Rodrigues Carreira

**Endereço eletrónico:** catarinacarreira8@gmail.com

**Número do Bilhete de Identidade:**13898983

**Título da dissertação:** Utilização de Redes Neurais Artificiais na gestão do processo de Digestão Anaeróbia.

**Orientadores:** Dr.ª Luciana José Ribeiro Pereira e Eng.º Adriano José Pereira de Magalhães (representante da empresa Águas do Noroeste, S.A.)

**Ano de conclusão:** 2014

**Designação do Mestrado:** Mestrado Integrado em Engenharia Biológica, Ramo Tecnologia Ambiental

É AUTORIZADA A REPRODUÇÃO INTEGRAL DESTA DISSERTAÇÃO APENAS PARA EFEITOS DE INVESTIGAÇÃO, MEDIANTE DECLARAÇÃO ESCRITA DO INTERESSADO, QUE A TAL SE COMPROMETE

Universidade do Minho, \_\_\_\_ de \_\_\_\_\_ de 2014

Assinatura: \_\_\_\_\_



Universidade do Minho  
Escola de Engenharia

## Declaração RepositóriUM: Dissertação de Mestrado

Nome: Ana Catarina Rodrigues Carreira

N.º do Cartão de Cidadão/BI: 13898983 Telefone/Telemóvel: 912150557

Correio eletrónico: catarinacarreira8@gmail.com

Curso: Mestrado Integrado em Engenharia Biológica Ano de conclusão da dissertação: 2014

Área de Especialização: Tecnologia Ambiental

Escola de Engenharia, Departamento/Centro: Engenharia Biológica

### TÍTULO DA DISSERTAÇÃO/TRABALHO DE PROJETO

Título em PT: Utilização de Redes Neurais Artificiais na gestão do processo de Digestão Anaeróbia

Título em EN: Use of Artificial Neural Networks in the management of Anaerobic Digestion process

Orientador: Doutora Luciana José Ribeiro Pereira

Coorientador: \_\_\_\_\_

Número de Unidades ECTS da Dissertação: 30 Classificação em valores (0 a 20): 18

Classificação ECTS com base no percentil (A a F): \_\_\_\_\_

Declaro sob compromisso de honra que a dissertação agora entregue corresponde à que foi aprovada pelo júri constituído pela Universidade do Minho, UM.

Declaro que concedo à Universidade do Minho e aos seus agentes uma licença não-exclusiva para arquivar e tornar acessível, nomeadamente através do seu repositório institucional, nas condições abaixo indicadas, a minha dissertação, em suporte digital.

Concordo que a minha dissertação seja colocada no repositório da Universidade do Minho com o seguinte estatuto (assinale um):

- Disponibilização imediata do trabalho para acesso universal;
- Disponibilização do trabalho para acesso exclusivo na UM, durante o período de  
 1 ano,  2 anos ou  3 anos, sendo que após o tempo assinalado autorizo o acesso universal.
- Disponibilização do trabalho de acordo com o **Despacho RT-98/2010 c)** (embargo # anos)

Braga, \_\_\_\_ de \_\_\_\_\_ de 2014

Assinatura: \_\_\_\_\_



## **AGRADECIMENTOS**

A todos os que tornaram possível a concretização desta dissertação expresso aqui os meus sinceros agradecimentos:

À Doutora Luciana José Ribeiro Pereira, por todo o apoio e orientação prestados ao longo da realização deste trabalho.

Ao Engenheiro Adriano Magalhães, por todo o apoio, ensinamentos e disponibilidade prestados ao longo de todo o estágio curricular e realização deste trabalho.

Ao Engenheiro Vasco Braga, da EFACEC ENGENHARIA, pela sua disponibilidade, e aos restantes colaboradores da ETAR do Ave pelo apoio e pelo bom ambiente de trabalho criado.

Aos Engenheiros Nuno Brôco e José Gascão, da Direção de Engenharia das Águas de Portugal, pelo apoio prestado na interpretação dos resultados obtidos.

À colega Joana Brandão e Engenheiro Milton Fontes, da SIMRIA, pelo apoio prestado para a compreensão do *software* utilizado.

Aos restantes colaboradores das Águas do Noroeste, em particular da ETA de Areias de Vilar, pela forma cordial com que me receberam e pelo bom ambiente de trabalho criado pelo tempo que lá estive.

À família universitária, principalmente, aos meus amigos que me acompanharam diariamente nestes últimos cinco anos, a Gold Family. Obrigado pelo apoio, pelos momentos e histórias partilhadas.

Ao meu irmão e aos meus amigos pelo apoio e incentivo.

Por fim, um grande e especial agradecimento aos meus pais por tudo. Obrigada pelos incentivos e apoio incondicional ao longo dos anos, acompanhando sempre todo o meu percurso académico.



*“It is not the strongest of the species that survives, nor the most intelligent that survives. It is the one that is most adaptable to change.”*

Charles Darwin

**Aos meus pais.**





## RESUMO

A crescente escassez de combustíveis fósseis, a principal fonte de energia dos países desenvolvidos, e as preocupações ambientais, levam à busca de fontes de energia alternativas, tais como o biogás. Este gás, produzido durante o processo de digestão anaeróbia de lamas, é considerado um biocombustível pouco poluente e de baixo custo, podendo a sua potencialidade chegar até 60% do poder calorífico do gás natural. A Estação de Tratamento de Águas Residuais (ETAR) do Ave, possui elevada tecnologia para tratamento de águas residuais, destacando-se a unidade de tratamento terciário e a central de cogeração. A otimização de biogás torna-se essencial para a sua rentabilidade.

A presente dissertação apresenta um estudo de aplicação de Redes Neurais Artificiais (RNA) para previsão do biogás produzido na digestão anaeróbia da ETAR do Ave, visando a compreensão da complexidade do processo e avaliação do impacto das variáveis do processo na produção de biogás, de forma a otimizá-lo. As RNA, são modelos matemáticos computacionais capazes de entender relações complexas num determinado conjunto de dados. Funcionam de forma análoga ao cérebro humano, sendo capazes de prever valores quando novos casos lhes são apresentados. Para o desenvolvimento deste trabalho, recorreu-se ao programa NeuralTools™ da Palisade™, utilizando-se informação das variáveis do tratamento de lamas da ETAR do Ave: a *temperatura*, os *sólidos voláteis (SV)*, a *alcalinidade*, os *ácidos gordos voláteis (AGV)*, o *pH*, o *caudal de entrada (Q entrada)* e as *gorduras*. Foram treinadas e testadas várias redes de forma a escolher aquela que tem melhor desempenho na previsão. A quantidade e disponibilidade de alguns dados foram as grande limitações para o desenvolvimento do trabalho, no entanto, os modelos de RNA utilizados provaram a sua capacidade de generalização, no sentido em que previram valores que acompanham o comportamento real do processo de digestão anaeróbia. Verificou-se, ainda, que as variáveis que mais influenciam as RNA escolhidas, e por consequência, a produção de biogás no processo, são o *Q entrada* no digestor, a *Temperatura* e a *quantidade de SV*. A adição de gorduras em pequenas quantidades ao digestor revelou-se benéfica na produção do biogás.

Como resultado deste estudo, é possível concluir que os modelos RNA podem ser ferramentas poderosas para administrar o processo de digestão anaeróbica, permitindo a otimização da produção de biogás e portanto, essenciais para melhorar a rentabilidade das ETAR, nomeadamente a do Ave.



## ABSTRACT

The increasing scarcity of fossil fuels, the main source of energy in developed countries, associated with the increasing environmental concerns, is now leading to the search for new alternative and green sources of energy such as biogas. This gas, produced as a result of sludge anaerobic digestion process, is considered a low-polluting and cost-saving biofuel that can reach up to 60% of natural gas calorific value. Ave's Wastewater Treatment Plant, owns high technology for sewage treatment, with special highlight for the tertiary treatment facility and the cogeneration plant. The optimization of the biogas production process becomes essential for its profitability.

The present dissertation disclose a study of applying Artificial Neural Networks (ANN) for the prevision of biogas production by anaerobic digestion in Ave's WWTP, aiming at the understanding the process complexity and at the evaluation of the process variables impact on biogas production intending its optimization. ANN, are computational mathematical models able to understand complex connections between data in a particular dataset. They function in a similar way to the human brain, being able to predict values when new cases are presented to them.

NeuralTools™ software from Palisade™ was used for the development of this work, using information of the variables of Ave's WWTP sewage sludge treatment, namely: *temperature (T)*, *volatile solids (VS)*, *alkalinity*, *volatile fatty acids (VFA)*, *pH*, *sludge flow on the entrance (Qent)* and *fats*. Several networks were trained and tested, in order to select the one that showed the best overall performance for the predictions.

The reduced amount and the availability of certain data, were the major limitation for the development of this project; however, the ANN models utilized proved their capability of generalization, once they could predict values accompanying the real behavior of anaerobic digestion. It was also verified that the variables that had a major impact on the selected ANN and, on the biogas production in the process, were the *feed flow at the digester entrance*, the *temperature* and the *amount of volatile solids*. Moreover, the addition of small quantities of fat to the process of anaerobic digestion, revealed as benefit to the biogas production.

As a result of this study, it is possible to conclude that the ANN models can be powerful tools to manage the process of anaerobic digestion, enabling the optimization of biogas production and, hence, an essential tool to enhance the profitability of WWTP, including Ave's WWTP.



## **LISTA DE ABREVIATURAS**

AdP – Águas de Portugal

AGCL – Ácidos Gordos de Cadeia Longa

AGV – Ácidos Gordos Voláteis

CBO<sub>5</sub> – Carência Bioquímica de oxigénio

CH<sub>4</sub> – Metano

CO<sub>2</sub> – Dióxido de Carbono

EMQ – Erro médio Quadrático

ETA - Estação de Tratamento de Águas

ETAR - Estação de Tratamento de Águas Residuais

H<sub>2</sub>S – Ácido Sulfídrico

NH<sub>3</sub> – Amónia Livre

NH<sub>4</sub><sup>+</sup> - Ião Amónio

RNA – Redes Neurais Artificiais

SIMRIA - Saneamento Integrado dos Municípios da Ria

SV – Sólidos Voláteis

SST – Sólidos Suspensos Totais

ST – Sólidos Totais

TRH – Tempo de Retenção Hidráulica



# ÍNDICE

<b>1. INTRODUÇÃO</b> .....	1
1.1. Enquadramento Geral.....	1
1.2. Objetivos .....	3
1.3. Descrição Sumária do Estudo .....	4
<b>2. APRESENTAÇÃO DA EMPRESA E DO PROCESSO DA ETAR DO AVE</b> .....	7
2.1. Grupo Águas de Portugal .....	7
2.2. Grupo Águas do Noroeste .....	7
2.3. ETAR do Ave.....	10
<b>3. ESTADO DO CONHECIMENTO</b> .....	21
3.1. Tratamento de águas residuais .....	21
3.1.1. Tratamento da fase líquida.....	22
3.1.1.1. Tratamento Preliminar .....	22
3.1.1.2. Tratamento Primário .....	22
3.1.1.3. Tratamento Secundário .....	23
3.1.1.4. Tratamento terciário.....	24
3.1.2. Tratamento da fase sólida.....	25
3.1.2.1 Espessamento das lamas.....	26
3.1.2.2. Estabilização das lamas .....	26
3.1.2.3 Desidratação das lamas .....	27
3.2. Processo de Digestão Anaeróbia .....	28
3.2.1. Fases, Microbiologia e Bioquímica da digestão anaeróbia .....	28
3.2.2. Requisitos nutricionais .....	30
3.2.3. Fatores ambientais e parâmetros que influenciam a digestão anaeróbia .....	32
3.2.4. Influência dos Gorduras na digestão anaeróbia.....	36



3.2.5. Perturbações à operação em estado estacionário .....	37
3.2.6 Biogás .....	39
3.3. Redes Neurais Artificiais.....	42
3.3.1. Analogia com sistemas biológicos .....	43
3.3.2. Evolução Histórica .....	45
3.3.3. Princípios de funcionamento e descrição das RNA.....	46
3.3.4. Tipos de Redes Neurais Artificiais .....	50
3.3.5. Fases de desenvolvimento de uma RNA .....	52
3.3.6 Comparação entre RNA e Métodos Estatísticos.....	54
<b>4. APRESENTAÇÃO DO CASO DE ESTUDO .....</b>	<b>57</b>
4.1. Enquadramento do estudo.....	57
4.2. Metodologia Proposta .....	58
4.2.1 Apresentação do NeuralTools.....	58
4.2.2 Preparação de dados .....	58
4.2.3. Treino e Teste da Rede Neuronal .....	62
4.2.3.1. Configuração da rede .....	64
4.2.3.2. Tempo de execução .....	65
4.2.3.3. Processo de Treino .....	66
4.2.3.4. Relatório de Treino.....	67
4.2.4. Previsão .....	71
4.3. Desenvolvimento do Estudo .....	72
4.3.1. Introdução .....	72
4.3.2. Preparação dos dados .....	73
4.3.3. Treino e Teste.....	79
4.3.3.1. Primeiro conjunto de redes .....	80
4.3.3.2. Segundo conjunto de redes .....	82

4.3.4. Previsão e Validação .....	84
4.3.4.1. Previsão Instantânea .....	84
4.3.4.2. Previsão e validação com novos valores.....	90
<b>5. CONSIDERAÇÕES FINAIS .....</b>	<b>95</b>
5.1. Conclusões.....	95
5.2. Sugestões para desenvolvimentos futuros .....	97
<b>BIBLIOGRAFIA.....</b>	<b>99</b>
<b>ANEXOS .....</b>	<b>107</b>
Anexo I .....	109
Anexo II .....	117
Anexo III .....	123
Anexo IV .....	126
Anexo V .....	132
Anexo VI .....	139
Anexo VII .....	148
Anexo VIII .....	154
Anexo IX.....	157



## ÍNDICE DE FIGURAS

Figura 1. Empresas que colaboram com o Grupo AdP (retirado de <a href="http://www.adp.pt">http://www.adp.pt</a> ).....	7
Figura 2. Municípios que utilizam os serviços das Águas do Noroeste (Águas do noroeste, 2010). .....	8
Figura 3. Esquema da ETAR do Ave. Fase sólida: (1) Elevação Inicial; (2) Tratamento Preliminar; (3) Tratamento Primário; (4) Reator Biológico; (5) Decantação Secundária; (6) Tratamento Terciário; (7) Espessamento de lamas primárias; (8) Tratamento de Lamas; (9) Digestão Anaeróbia; (10) Gasómetro; (11) Desodorização. ....	11
Figura 4. Fotografia do primeiro estágio da elevação inicial – parafusos de Arquimedes – da ETAR do Ave.....	12
Figura 5. Fotografia do segundo estágio da elevação inicial – parafusos de Arquimedes – da ETAR do Ave.....	12
Figura 6. Fotografia da remoção de areias e gorduras da ETAR do Ave. ....	13
Figura 7. Fotografia dos Decantadores Primários da ETAR do vale do Ave.....	13
Figura 8. Fotografia do reator biológico da ETAR do Ave. ....	14
Figura 9. Fotografia da decantação secundária da ETAR do Ave. ....	14
Figura 10. Fotografia da microtamização da ETAR do Ave. ....	15
Figura 11. Fotografia dos Silos de lamas e do armazenamento de cal viva da ETAR do Ave.....	15
Figura 12. Fotografia de um dos digestores anaeróbios da ETAR do Ave.....	16
Figura 13. Fotografia do gasómetro da ETAR do Ave. ....	16
Figura 14. Fotografia dos ventiladores da desodorização da ETAR do Ave. ....	17
Figura 15. Sistema de Tratamento da ETAR do Ave (Águas do Noroeste, 2010).....	17
Figura 16. Constituintes de um neurónio ou célula neuronal. ....	43
Figura 17. Transmissão de um impulso nervoso através de uma sinapse química. ....	44
Figura 18. Modelo Estrutural de uma rede neuronal (Fonte: Ribeiro <i>et al.</i> , 2009).....	45
Figura 19. Modelo de um nó de uma RNA (Matos, 2008).....	47
Figura 20. Representação esquemática de um perceptrão (Matos, 2008).....	48

Figura 21. Esquema das ligações e elementos presentes num PMC de uma camada oculta (Silva, 2014).....	49
Figura 22. Exemplo de uma base de dados para utilizar com o NeuralTools. ....	59
Figura 23. Caixa de diálogo do gestor do conjunto de dados.....	60
Figura 24. Definição do tipo de variável.....	61
Figura 25. Conjunto de dados definido para ser utilizado.....	62
Figura 26. Caixa de diálogo Treinar.....	63
Figura 27. Caixa de diálogo Configuração da rede.....	64
Figura 28. Caixa de diálogo Tempo de Execução.....	65
Figura 29. Caixa de diálogo Visão Geral de Treino.....	66
Figura 30. Caixa de diálogo “Andamento do Treino”.....	67
Figura 31. Tabelas geradas no relatório de treino e teste automático do NeuralTools.....	68
Figura 32. Exemplos de gráficos gerados no relatório de treino e teste automático do NeuralTools – parte 1.....	69
Figura 33. Exemplos de gráficos gerados no relatório de treino e teste automático do NeuralTools – parte 2.....	70
Figura 34. Relatório detalhado de treino e teste da RNA do NeuralTools.....	71
Figura 35. Caixa de diálogo Previsão.....	72

## ÍNDICE DE TABELAS

Tabela 1. Constituição do Biogás (adaptado de Salomon, 2007).....	40
Tabela 2. Equivalências energéticas do biogás (adaptado de Pompermayer, 2000).....	41
Tabela 3. Variáveis disponíveis para treino das RNA referentes de Janeiro de 2012 a Julho de 2014. Dados diários, 31 variáveis com 942 casos cada uma; Dados Semanais, 84 variáveis com aproximadamente 145 casos cada uma.....	74
Tabela 4. Variáveis independentes ou de <i>input</i> escolhidas para as bases de dados.....	76
Tabela 5. Dados Diários Fornecidos pela EFACEC ENGENHARIA relativos aos vários caudais que intervêm no tratamento de lamas – Exemplo: Mês de Outubro de 2012. ....	110
Tabela 6. Dados Semanais Fornecidos pela EFACEC ENGENHARIA relativos aos parâmetros pH, ST, SV, %SV/ST,%matéria seca, AGV e Alcalinidade – Exemplo: Mês de Outubro de 2012.....	112
Tabela 7. Dados Fornecidos pela EFACEC ENGENHARIA relativos aos parâmetros de qualidade do biogás – Exemplo: Mês de Outubro de 2012. ....	114
Tabela 8. Dados Diários Fornecidos pela EFACEC ENGENHARIA relativos à temperatura dos digestores – Exemplo: Mês de Outubro de 2012. ....	115
Tabela 9. Dados Diários Fornecidos pela EFACEC ENGENHARIA relativos às gorduras adicionadas nos digestores – Exemplo: Mês de Maio de 2013.....	116
Tabela 10. Base de Dados sem gorduras. ....	118
Tabela 11. Base de dados com gorduras. ....	121
Tabela 12. Compilação do Primeiro Conjunto de Redes para a Base de dados sem gorduras. ....	124
Tabela 13. Compilação do Primeiro Conjunto de Redes para a Base de dados com gorduras. ....	125
Tabela 14. Base de dados sem gorduras. ....	127
Tabela 15. Base de dados com gorduras. ....	130
Tabela 16. Compilação do Segundo conjunto de redes para a base de dados sem gorduras. .	133
Tabela 17. Compilação do Segundo conjunto de redes para a base de dados com gorduras. .	136
Tabela 18. Previsão Instantânea a várias Temperaturas para a Base de dados sem gorduras. ....	140
Tabela 19. Previsão Instantânea a várias Temperaturas para a base de dados com gorduras. ....	145

Tabela 20. Dados relativos ao Biogás Real produzido na ETAR do Ave, ao biogás previsto pela rede “A2” e o respetivo desvio padrão. ....	149
Tabela 21. Dados relativos ao Biogás Real produzido na ETAR do Ave, ao biogás previsto pela rede “B15” e o respetivo desvio padrão .....	152
Tabela 22. Previsão Instantânea a várias Temperaturas para a base de dados com gorduras.	155
Tabela 23. Conjunto de dados a usar na previsão com a rede “A2” .....	158
Tabela 24. Conjunto de dados a usar na previsão com a rede “B15”. .....	158
Tabela 25. Valores de Biogás Real produzidos pela ETAR que o NeuralTools desconhece. ....	158

## ÍNDICE DE GRÁFICOS

Gráfico 1. Comparação do biogás total produzido com o biogás total previsto com a rede “A2”. (azul) valores de biogás real; (vermelho) valores de biogás previsto pela rede. ....	85
Gráfico 2. Comparação do comportamento da produção real de biogás total (azul) com a previsão da produção de biogás total à temperatura constante de 37 °C (vermelho). Previsão feita com a rede “A2”. Desvio Padrão médio resultante da média da diferença entre o biogás previsto à temperatura real com o biogás previsto com à temperatura testada foi de 10%. ....	86
Gráfico 3. Comparação do biogás total produzido (azul) com o biogás total previsto com a rede “B15” (vermelho). ....	87
Gráfico 4. Comparação do biogás total produzido pela ETAR (verde) com as previsões do biogás total usando a rede A2, base de dados sem gorduras (azul), e a rede B15, base de dados com gorduras (vermelho). A previsão dos valores de biogás total na base de dados com gorduras só iniciou a 22 de Abril de 2013. ....	88
Gráfico 5. Comparação do comportamento da produção real de biogás total (azul) com a previsão da produção de biogás total à temperatura constante de 38 °C (vermelho). Previsão feita com a rede “B15”. Desvio Padrão médio resultante da média da diferença entre o biogás previsto à temperatura real com o biogás previsto com à temperatura testada foi de aproximadamente 10%. ....	89
Gráfico 6. Comparação do comportamento da produção real de biogás total (azul) com a previsão da produção de biogás total a caudal constante de gorduras a 2 m <sup>3</sup> /dia (vermelho) e a 5 m <sup>3</sup> /dia (verde). Previsão feita com a rede “B15”. Desvio Padrão médio resultante da média da diferença entre o biogás previsto com a quantidade de gorduras real com o biogás previsto com a quantidade de gorduras testada foi de abaixo de 5%. ....	90
Gráfico 7. Comparação do biogás real produzido pela ETAR do Ave (azul) com o biogás previsto pela rede “A2” (vermelho) para o novo conjunto de dados. ....	91
Gráfico 8. Comparação do biogás real produzido pela ETAR do Ave (azul) com o biogás previsto pela rede “B15” (vermelho) para o novo conjunto de dados. ....	92
Gráfico 9. Comparação do biogás real produzido pela ETAR do Ave (vermelho) com o biogás previsto pela rede “B4” (azul) para o novo conjunto de dados. ....	93
Gráfico 10. Comparação entre o biogás real (cinzento) com o biogás previsto a 38 °C (cinzento claro) para a rede “A2” ....	144
Gráfico 11. Comparação entre o biogás real (cinzento) com o biogás previsto a 36 °C (cinzento claro) para a rede “A2” ....	144



Gráfico 12. Comparação entre o biogás real (cinzento) com o biogás previsto a 38 °C (cinzento claro) para a rede “A2” .....	147
Gráfico 13. Comparação entre o Biogás real da ETAR (cinzento) com o Biogás previsto pela rede “A2” (cinzento claro). .....	151
Gráfico 14. Comparação entre o Biogás real da ETAR (cinzento) com o Biogás previsto pela rede “B15” (cinzento claro). .....	153
Gráfico 15. Comparação da produção de biogás real (cinzento) com a respetiva quantidade de gordura (cinzento claro). .....	156

## ÍNDICE DE ESQUEMAS

Esquema 1. Sistema Multimunicipal de Abastecimento de água (Águas do Noroeste, 2010). ....	9
Esquema 2. Sistema Multimunicipal de Saneamento de águas residuais (Águas do noroeste, 2010).....	9
Esquema 3. Representação do sistema de tratamento de lamas. LS – Lamas Secundárias; LP – Lamas Primárias; LSE – Lamas Secundárias Espessadas; LPE – Lamas Primárias Espessadas; LM – Lamas Mistas; LD – Lamas Digeridas. ....	18
Esquema 4. Representação do Digestor Anaeróbio. LM – Lamas Mistas; LD – Lamas Digeridas; LA – Lamas em Aquecimento; AQ – Água Quente; G – Gorduras.....	19
Esquema 5. Fases e etapas de uma ETAR. ....	21
Esquema 6. Bioquímica e Microbiologia do processo de digestão anaeróbia (adaptado de Alves, 1998).....	28



# 1. INTRODUÇÃO

## 1.1. Enquadramento Geral

Com o 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. Cada vez mais a preservação do meio ambiente é uma preocupação. A escassez de água e o consumo excessivo de combustíveis fósseis, têm levado à procura de outras soluções para o consumo destes bens.

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 água 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. É importante que se possa aproveitar este tipo de processos ao máximo, tornando-os mais eficientes. 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 população e com todos os fatores a ele associados. Consequentemente, 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. Segundo Metcalf & Eddy (2004), 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. O ciclo de carbono deste gás tem uma duração menor comparativamente ao dos combustíveis fósseis, fazendo com que o carbono emitido seja rapidamente fixado com a produção de nova biomassa e não se concentre na atmosfera sob a forma de CO<sub>2</sub>, designando-se, por esta razão, por ciclo neutro de carbono (Silveira, 2009).

A digestão anaeróbia é descrita como um processo instável dado todos os fatores que o influenciam e a sua otimização reflete-se na produção de biogás (Speece, 1983). 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 (Ward *et al.*, 2008). 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 e distinguir padrões entre eles. 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. Pretende-se assim, através das RNA, encontrar alguma resposta para estas questões.

## **1.2. Objetivos**

Este projeto surgiu a partir do grupo Águas de Portugal, em que foi lançado o desafio às várias empresas pertencentes, que disponham de digestores anaeróbios de lamas. Visa pôr em prática a utilização de RNA na gestão de processos de digestão anaeróbia.

O objetivo principal deste projeto na empresa Águas do Noroeste S.A. é a análise e tratamento de dados de digestão anaeróbia da ETAR do Ave, com recurso a RNA, de forma a desenvolver um modelo capaz de prever os valores de biogás a produzir. Para tal, pretende-se:

- Relacionar algumas variáveis explicativas com a produção de biogás, definindo quais aquelas que têm maior impacto no processo de digestão anaeróbia;
- Auxiliar a tomada de decisões no processo de Digestão Anaeróbia, com vista à otimização da produção de biogás;
- Produzir um modelo de simulação da produção de biogás, com o fim de apoiar a gestão do processo de digestão.

O primeiro objetivo visa o estudo da influência das variáveis do processo sobre a produção de biogás. Até agora não se sabe ao certo qual o impacto que cada variável tem, talvez devido à falta de dados ou à falta de ferramentas adequadas para esse fim. Mas várias limitações se levantam com esta questão, pois são várias as variáveis existentes, o que torna importante ter um conhecimento prévio do sistema. Sabe-se que a temperatura e a quantidade de matéria orgânica são dois fatores a ter bastante em conta, pois um dita a produção de biogás e o outro, se não estiver no seu valor ótimo, pode destabilizar todo o processo. Espera-se, com

esta aplicação das RNA, conseguir estabelecer gamas de valores das variáveis para o melhor funcionamento do processo de digestão, fazendo uma comparação dos resultados obtidos, com a RNA, com os dados reais. Desta forma, tentar-se-á verificar até que ponto os modelos de simulação de produção de biogás podem ser fiáveis para que seja possível otimizar o processo da digestão anaeróbia e por consequência aumentar a produção de biogás, ajudando na gestão de toda a ETAR.

### **1.3. Descrição Sumária do Estudo**

A entidade Águas do Noroeste tem mostrado grande preocupação em otimizar os seus processos de funcionamento, nomeadamente, o processo de digestão anaeróbia. Surge assim a oportunidade de fazer um estudo, sugerido pelo grupo Águas de Portugal, através da análise e tratamento de dados para a gestão do processo de digestão anaeróbia, com recurso a RNA.

As RNA são ferramentas matemáticas computacionais que funcionam de forma semelhante ao cérebro humano. São capazes de entender relações complexas existentes em determinados conjuntos de dados, tomando-os como exemplos, para que perante novos dados sejam capazes de prever aquilo que se pretende. Neste caso, o objetivo passa por prever a produção de biogás, relacionando as variáveis explicativas do processo, de forma a otimizá-lo e ajudar na tomada de decisões de todo o processo de produção.

O objeto do estudo são os dois digestores anaeróbios presentes na linha de tratamento de lamas da ETAR do Ave, mas como não há medição parcial de biogás de cada digestor, considera-se os dois equipamentos como um digestor global. Outra particularidade do processo de digestão anaeróbia da ETAR do Ave é a adição de gorduras ao digestor, o que levou a testar duas hipóteses de modelação do processo através de RNA, em que numa se considera a quantificação de gorduras como variável de entrada e na outra não.

Para o desenvolvimento deste trabalho utilizaram-se os programas Microsoft Excel™ e NeuralTools™ do The Decision Tools Suite™ da Palisade™ e encontra-se dividido por várias fases. A primeira fase consistiu na preparação de dados, uma das fases mais cruciais para o desenvolvimento do restante estudo. A entidade exploradora da ETAR do Ave cedeu dados de todo o processo desde Janeiro de 2012 a Julho de 2014 para que fossem tratados e manipulados de forma a definir uma base de dados para o estudo. Como existem duas

hipóteses de estudo e a quantidade de dados disponível é diferente para cada uma delas, houve a necessidade de criar duas bases de dados. Seguidamente procedeu-se para as fases de treino, teste e previsão. Treinou-se e testou-se vários modelos de redes neuronais com diferentes conjuntos de dados, que variavam conforme as variáveis de entrada escolhidas. Pretendeu-se, assim, encontrar o modelo que melhor simulava o comportamento da digestão anaeróbia a fim de prever valores de produção de biogás futuros.







noroeste do país (Águas do Noroeste, 2010). São abrangidos pelos seus serviços cerca de 30 municípios, como é possível observar na figura 2.

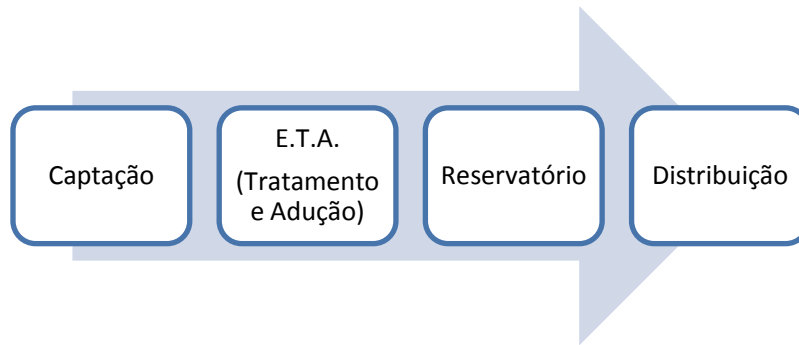


Figura 2. Municípios que utilizam os serviços das Águas do Noroeste (Águas do noroeste, 2010).

De forma a cumprir o seu objetivo a empresa está organizada em quatro centros operacionais, Minho, Lima, Ave e Cávado (Águas do Noroeste, 2010).

### **Abastecimento de água**

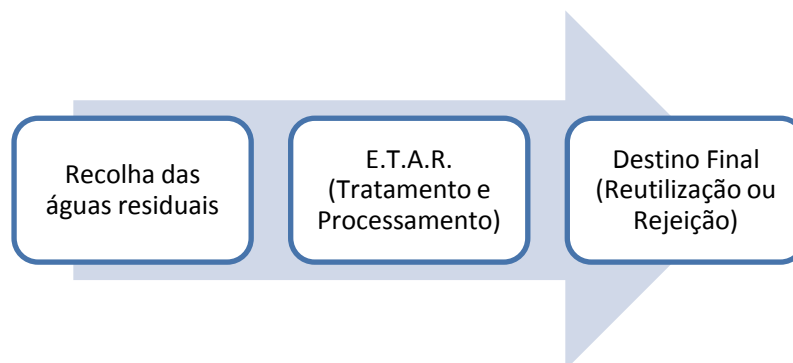
O sistema multimunicipal de abastecimento de água das Águas do Noroeste foi dimensionado de forma a satisfazer as necessidades de cerca de um milhão de habitantes dos seguintes municípios Arcos de Valdevez, Barcelos, Caminha, Esposende, Fafe, Maia (Norte), Melgaço, Monção, Mondim de Basto, Paredes de Coura, Ponte da Barca, Ponte de Lima, Póvoa de Lanhoso, Póvoa de Varzim, Santo Tirso, Trofa, Valença, Viana do Castelo, Vieira do Minho, Vila do Conde, Vila Nova de Cerveira e Vila Nova de Famalicão, que se estimam cerca de 67,1 milhões de m<sup>3</sup> de água potável por ano (Águas do Noroeste, 2010). A fim de cumprir aquilo a que se comprometem possuem várias infraestruturas: 14 captações, 13 estações de tratamento de água (ETA), 1,196 km de condutas adutoras, 104 estações elevatórias e 273 reservatórios de água para proceder à sua distribuição (Esquema 1) (Águas do Noroeste, 2014).



Esquema 1. Sistema Multimunicipal de Abastecimento de água (Águas do Noroeste, 2010).

### Saneamento de Águas Residuais

Este sistema multimunicipal abrange uma população maior quando comparado com o sistema anteriormente apresentado, como tal o número de infraestruturas é muito superior bem como os municípios que satisfaz. Os municípios de Amarante, Amares, Arcos de Valdevez, Cabeceiras de Basto, Caminha, Celorico de Basto, Esposende, Fafe, Felgueiras, Guimarães, Lousada, Mondim de Basto, Melgaço, Monção, Paredes de Coura, Ponte da Barca, Ponte de Lima, Póvoa de Lanhoso, Póvoa de Varzim, Santo Tirso, Terras de Bouro, Trofa, Valença, Viana do Castelo, Vieira do Minho, Vila do Conde, Vila Nova de Cerveira e Vila Nova de Famalicão, Vila Verde e Vizela usufruem deste sistema, existindo cerca de 267 estações elevatórias e 95 estações de tratamento de águas residuais (Esquema 2) (Águas do noroeste, 2010; Águas do noroeste, 2014).



Esquema 2. Sistema Multimunicipal de Saneamento de águas residuais (Águas do noroeste, 2010).

A Águas do Noroeste está aberta a novos desafios e projetos por forma a inovar os processos da própria empresa. O presente trabalho é mais um desafio a que a empresa se propôs cujo objetivo é avaliar a aplicabilidade da utilização de RNA na gestão de processos de

digestão anaeróbia, utilizando-se a ETAR do Ave, localizada em Vila do Conde, como exemplo de trabalho.

### **2.3. ETAR do Ave**

A ETAR do Ave, inaugurada a 31 de Agosto de 2010, está localizada na freguesia de Tougues, Vila do Conde. A infraestrutura está dimensionada para receber os efluentes provenientes de cerca de 258 mil habitantes-equivalentes, na época alta, e de 184 mil habitantes-equivalentes, na época baixa, dos Municípios de Vila do Conde e Póvoa de Varzim (Águas do Noroeste, 2010).

A ETAR do Ave possui sistemas da mais avançada tecnologia para o tratamento de águas residuais, por forma a garantir o cumprimento de todos os requisitos legais a que está obrigada a descarga do efluente tratado, cujo meio receptor é o rio Ave. É de salientar a existência de uma unidade de tratamento terciário, em que o efluente resultante do tratamento é sujeito a uma desinfecção por UV e a existência de uma central de cogeração (379kW x 2 unidades) em que é produzida um terço da energia consumida na instalação (Águas do noroeste, 2014).

Os vários processos de tratamento, agrupados em fase líquida, sólida e gasosa, implementados na ETAR do Ave, são apresentados na figura 3.




Figura 3. Esquema da ETAR do Ave. Fase sólida: (1) Elevação Inicial; (2) Tratamento Preliminar; (3) Tratamento Primário; (4) Reator Biológico; (5) Decantação Secundária; (6) Tratamento Terciário; (7) Espessamento de lamas primárias; (8) Tratamento de Lamas; (9) Digestão Anaeróbia; (10) Gasómetro; (11) Desodorização.

- |                                    |   |              |
|------------------------------------|---|--------------|
| 1) Elevação Inicial                | } | Fase Líquida |
| 2) Tratamento Preliminar           |   |              |
| 3) Tratamento Primário             |   |              |
| 4) Reator Biológico (3)            | } | Fase Sólida  |
| 5) Decantação Secundária (3)       |   |              |
| 7) Espessamento de Lamas Primárias |   |              |
| 8) Tratamento de Lamas             | } | Fase Gasosa  |
| 9) Digestão Anaeróbia              |   |              |
| 10) Gasómetro                      |   |              |
| 11) Desodorização                  |   |              |

## Fase Líquida

1) Elevação Inicial: As águas residuais brutas chegam graviticamente à ETAR, sendo a elevação inicial efetuada por parafusos de Arquimedes equipados com variação de velocidade, divididos em duas fases com dois (mais um) parafusos (figura 4 e 5).



Figura 4. Fotografia do primeiro estágio da elevação inicial – parafusos de Arquimedes – da ETAR do Ave.



Figura 5. Fotografia do segundo estágio da elevação inicial – parafusos de Arquimedes – da ETAR do Ave.

2) Tratamento Preliminar: O tratamento preliminar consiste numa primeira fase na gradagem mecânica grossa, espaçamento de barras de 30 mm, seguida da gradagem mecânica fina, em tamisadores rotativos com malha de 3 mm. A segunda fase do tratamento preliminar é a remoção de areias e gorduras, efetuada no desarenador/desengordurador. Neste equipamento as gorduras são flotadas por insuflação de ar e de areias, decantadas e removidas por uma bomba tipo por *air-lift* (figura 6). Todas as escorrências do processo são encaminhadas para esta fase.



Figura 6. Fotografia da remoção de areias e gorduras da ETAR do Ave.

3) Tratamento Primário: Este tratamento realiza-se em três decantadores lamelares quadrados (figura 7) e tem a importante função de separar e concentrar sólidos sedimentáveis. Trata-se de uma etapa sujeita a desodorização pelo que são protegidos por uma cobertura amovível. As lamelas existentes permitem aumentar a área de decantação. O caudal de efluente clarificado é medido, num medidor de caudal eletromagnético de DN 700, e encaminhado para o tratamento secundário. As lamas decantadas são encaminhadas para a linha de lamas.



Figura 7. Fotografia dos Decantadores Primários da ETAR do vale do Ave.

4) Reator Biológico: É nos reatores biológicos que se dá continuidade ao processo de tratamento de águas residuais (figura 8). Na ETAR do Ave existem três e têm a seguinte compartimentação:

- *Zona Anóxica/Seletor* – privilegia o desenvolvimento de bactérias floculantes em detrimento de bactérias filamentosas, prevenindo fenómenos de *bulking*.
- *Zona de pré-desnitrificação* – promove a conversão biológica dos nitratos em azoto atmosférico, essencial à redução dos compostos azotados.
- *Zona de Arejamento* – local do reator onde se privilegia a degradação da matéria orgânica e a nitrificação dos compostos de amónia.





Figura 8. Fotografia do reator biológico da ETAR do Ave.

5) Decantação Secundária: Após o tratamento das águas residuais nos reatores biológicos, estas são encaminhadas para os três decantadores secundários existentes (figura 9). Aqui promove-se a separação da fase líquida da fase sólida: a fase líquida segue para a etapa seguinte do processo, tratamento terciário, enquanto a fase sólida, sendo mais densa, vai decantar. Uma parte da biomassa vai retornar para o reator biológico de forma a manter a concentração de lamas ativadas adequada para o tratamento (recirculação de lamas), a restante parte, lamas em excesso, é encaminhada para a linha de lamas para proceder ao seu espessamento por via mecânica.



Figura 9. Fotografia da decantação secundária da ETAR do Ave.

6) Tratamento Terciário: Trata-se do último passo do tratamento da fase líquida em que se recebe água proveniente da decantação secundária. Aqui há remoção/redução dos sólidos suspensos ainda existentes através de filtração por dois microtamisadores, malha de 30  $\mu\text{m}$  (figura 10). Seguidamente o efluente é desinfetado por radiação ultravioleta de baixa pressão. É de salientar que uma parte do efluente desinfetado é reaproveitada na ETAR, sendo o resto descarregado no meio recetor, rio Ave.



Figura 10. Fotografia da microtamização da ETAR do Ave.

## Fase Sólida

7) Espessamento de Lamas Primárias: As lamas provenientes dos decantadores primários são espessadas em espessadores gravíticos, equipados com uma grade e raspador de fundo. As lamas espessadas nestes equipamentos são enviadas para os digestores anaeróbios, juntamente com as lamas em excesso espessadas.

8) Tratamento de Lamas: As várias etapas existentes no tratamento de lamas ocorrem dentro de um edifício para confinamento e tratamento de odores gerados. As lamas em excesso, extraídas a partir de poços de recirculação de lamas, do tratamento biológico, são espessadas mecanicamente em dois tambores de espessamento, equipados com floculador dinâmico. As lamas digeridas nos digestores anaeróbios são desidratadas em duas centrifugas de alto rendimento com adição de polímero em linha. As lamas desidratadas são recolhidas num parafuso transportador, misturadas com cal viva e bombeadas para dois silos de lamas equipados com medidor de nível (figura 11).



Figura 11. Fotografia dos Silos de lamas e do armazenamento de cal viva da ETAR do Ave.

9) Digestão Anaeróbia: As lamas mistas (primárias e secundárias) espessadas são estabilizadas por digestão anaeróbia em sistema de alta carga e regime mesofílico a 35 °C (figura 11). A fração volátil das lamas é parcialmente convertida em biogás. Aos digestores existentes são adicionadas gorduras provenientes do tanque de gorduras do tratamento preliminar.



Figura 12. Fotografia de um dos digestores anaeróbios da ETAR do Ave.

### **Fase Gasosa**

10) Gasómetro: O biogás produzido na digestão anaeróbia é armazenado num gasómetro de dupla membrana e de baixa pressão (figura 13).



Figura 13. Fotografia do gasómetro da ETAR do Ave.

11) Desodorização: A desodorização permite o tratamento de odores gerados no tratamento preliminar, primário e de lamas. O ar é aspirado através de ventiladores centrífugos, equipados com variador de velocidade, e encaminhado para uma lavagem química em três estágios no interior de torres, com circulação dos fluidos em contracorrente.



Figura 14. Fotografia dos ventiladores da desodorização da ETAR do Ave.

A forma como cada um dos processos de tratamento existentes na ETAR no Ave está ligado, apresenta-se na figura seguinte (figura 15).


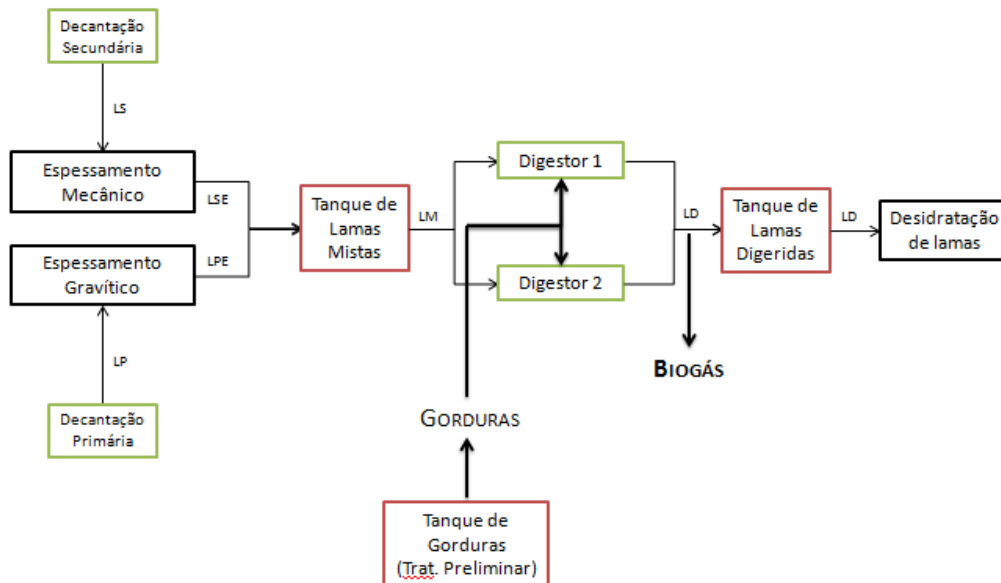


Figura 15. Sistema de Tratamento da ETAR do Ave (Águas do Noroeste, 2010).

Os esquemas abaixo apresentados permitem interpretar melhor o funcionamento do tratamento de lamas, podendo-se constatar a ligação existente entre as três fases: líquida, sólida e gasosa (esquema 3 e 4).

As lamas primárias espessadas e as lamas secundárias espessadas são reunidas no tanque de lamas mistas e daí são encaminhadas para cada um dos digestores (esquema 3). Como já foi referido anteriormente, em cada um dos digestores são adicionadas as gorduras provenientes do tratamento preliminar para serem codigeridas. Como resultado desta fase, é produzido biogás, sendo as lamas digeridas encaminhadas para o tanque de lamas digeridas e posteriormente para desidratação. É importante referir que no tanque de lamas digeridas

também há formação de biogás. As lamas provenientes do digestor, enquanto não arrefecem, continuam ativas e a produzir biogás, sendo também encaminhado para o gasómetro.

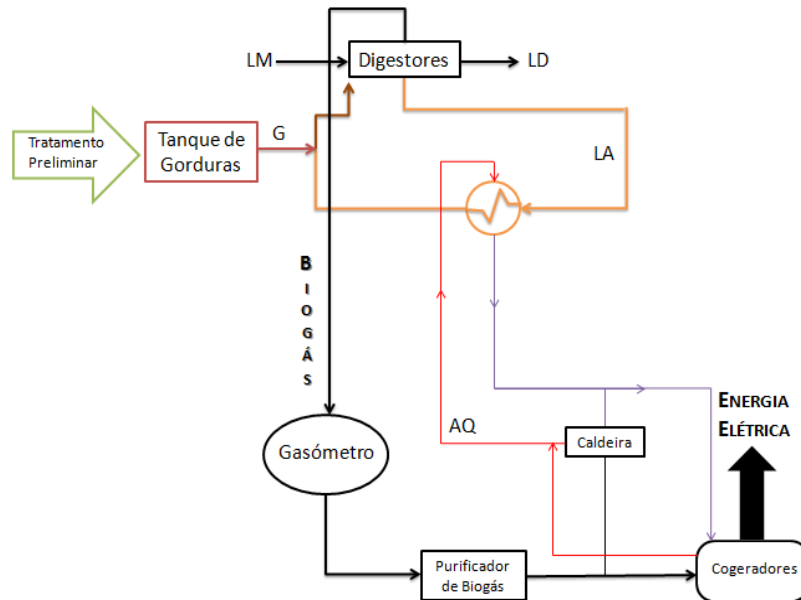


Esquema 3. Representação do sistema de tratamento de lamas. LS – Lamas Secundárias; LP – Lamas Primárias; LSE – Lamas Secundárias Espessadas; LPE – Lamas Primárias Espessadas; LM – Lamas Mistas; LD – Lamas Digeridas.

Aquando do tratamento secundário, fase líquida, pode formar-se *bulking* filamentoso que dificulta a sedimentação de lamas e que faz flotar o sobrenadante dos decantadores secundários. Este é removido e reintroduzido no processo no tratamento preliminar, antes da fase de separação de areias e gorduras. Devido a essa flotação, quando ocorre a remoção de gorduras do efluente, as escorrências provenientes do decantador secundário são separadas como gorduras e, por consequência, no tanque das gorduras poderá haver mistura de gorduras e dessas lamas que flotaram, as quais são posteriormente encaminhadas para os digestores anaeróbios.

O esquema 4 representa o processo de produção, tratamento e utilização de biogás. As lamas mistas entram no digestor e são digeridas juntamente com as gorduras, que são adicionadas na linha de circulação de aquecimento das lamas. O biogás produzido no digestor e tanque de lamas mistas é armazenado no gasómetro, sendo posteriormente utilizado quer na

cogeração, para produção de energia elétrica, quer na caldeira. Caso a qualidade do gás não seja adequada para valorização, este é destruído termicamente na tocha. A medição do biogás produzido é efetuada por somatório do biogás destruído termicamente com o biogás valorizado. A instalação não dispõe de medição parcial a cada digester.



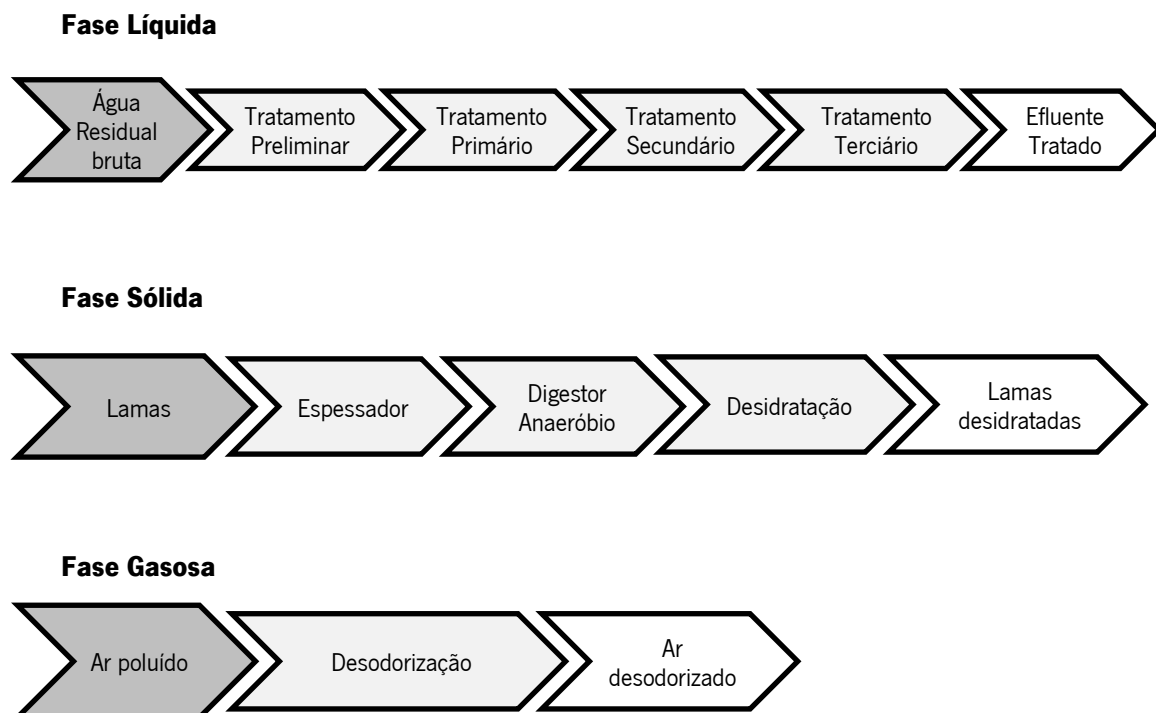
Esquema 4. Representação do Digestor Anaeróbio. LM – Lamas Mistas; LD – Lamas Digeridas; LA – Lamas em Aquecimento; AQ – Água Quente; G – Gorduras.



### 3. ESTADO DO CONHECIMENTO

#### 3.1. Tratamento de águas residuais

O tratamento de águas residuais é feito através de um conjunto de etapas normalmente divididas por níveis de tratamento: tratamento da fase líquida (preliminar, primário, secundário, terciário), tratamento da fase sólida e tratamento da fase gasosa (Pereira, 2011), correspondendo a um conjunto de processos físicos, químicos e biológicos. O controlo adequado dos parâmetros que definem as diferentes variáveis dos processos envolvidos permite atingir o objetivo da ETAR, receber e tratar águas residuais para que estas possam ser devolvidas ao meio ambiente com a menor matéria poluente possível e dentro dos parâmetros legislados. Seguidamente são analisadas as diversas fases bem como as etapas que decorrem numa ETAR (esquema 5).



Esquema 5. Fases e etapas de uma ETAR.



### **3.1.1. Tratamento da fase líquida**

#### **3.1.1.1. Tratamento Preliminar**

No tratamento preliminar ocorre a remoção de sólidos grosseiros, paus, pedras, areia, óleos e gorduras, que as águas residuais arrastam consigo até chegar à ETAR, de forma a proteger os equipamentos e as operações a jusante. Nesta etapa, a gradagem, o desarenamento e a remoção de gorduras são as operações que a definem (Pereira, 2011).

A gradagem é uma operação unitária em que a água passa através de um canal de uma grade (grossa, média ou fina), ou por uma combinação de grades de diferentes tamanhos, para que a remoção de material grosseiro indesejado seja mais eficiente. Esta é a primeira etapa do tratamento preliminar e onde é formado o primeiro subproduto do processo (Metcalf & Eddy, 2004).

Para que o tratamento primário seja mais eficaz tem de haver a remoção de areias e gorduras, pois a etapa da gradagem não é suficiente para tal. Surge, então, a etapa de desarenamento, em que há a sedimentação das areias num desarenador (Gomes, 2011). Seguidamente, estas areias são lavadas e é removida a matéria orgânica existente. Relativamente à remoção de gorduras e óleos, o seu processo é muito importante, pois caso não ocorra pode criar uma película à superfície da água ainda a tratar o que dificultará a atividade biológica das operações seguintes, bem como as trocas gasosas (Metcalf & Eddy, 2004).

#### **3.1.1.2. Tratamento Primário**

Nesta fase do tratamento, há remoção de uma parte do material flotante e sedimentável. Por outras palavras, existe a remoção dos sólidos orgânicos e inorgânicos bem como de escumas, materiais menos densos que a água (Metcalf & Eddy, 2004). Basicamente, há um acabamento daquilo que foi feito no tratamento preliminar.

No tratamento primário, existem etapas de cariz químico, em que há a adição de reagentes químicos e coagulantes, ou físico, através de processos de flotação, filtração e decantação (Metcalf & Eddy, 2004). A operação que melhor expõe este tratamento é a decantação, neste caso primária, em que há uma redução de 50 a 70% dos sólidos suspensos

sedimentáveis na água e uma diminuição de 25 a 40% da carência bioquímica em oxigênio ( $\text{CBO}_5$ ). Com a adição de químicos é possível que haja também a diminuição de azoto e fosforo orgânico bem como de metais pesados insolúveis (Metcalf & Eddy, 2004). As lamas primárias são um subproduto desta etapa, acumulando-se no fundo do decantador por serem mais densas que a água, bem como as escumas que formam uma camada à superfície que será enviada para o concentrador de gorduras já utilizado aquando do tratamento preliminar (Pereira, 2008).

### **3.1.1.3. Tratamento Secundário**

Apesar dos tratamentos já realizados nas etapas anteriores, as águas residuais continuam com carga elevada de  $\text{CBO}_5$  e de sólidos suspensos totais (SST). Os tratamentos secundários têm como objetivo respeitar as normas legisladas aquando da descarga da água tratada, havendo uma redução desses parâmetros,  $\text{CBO}_5$  e SST.

No tratamento secundário ocorre a maior parte da remoção da carga orgânica do efluente, desde que este chega à ETAR, através de meios químicos e/ou biológicos e através da combinação de operações e processos, sendo mais usuais os filtros percoladores, lamas ativadas e lagoas de oxidação (Gomes, 2011).

As águas residuais possuem uma elevada quantidade de substâncias biodegradáveis que podem ser tratadas em reatores biológicos. Com a utilização deste equipamento pretende-se oxidar as substâncias biodegradáveis em produtos finais, capturar e incorporar os sólidos suspensos e coloidais num floco biológico ou num biofilme, transformar ou remover nutrientes responsáveis pela eutrofização, azoto e fósforo, e remover compostos específicos e poluentes prioritários (Metcalf & Eddy, 2004).

No tratamento de águas residuais, os processos biológicos podem ser classificados segundo o tipo de biomassa existente, suspensa ou fixa. No primeiro caso, o processo mais utilizado é o tratamento por lamas ativadas. Habitualmente funciona a meia carga o que permite uma eficiência de remoção de 90% a 95% de carga poluente da água residual. Este processo é biológico e aeróbio e consiste numa mistura da água residual com a biomassa (microrganismos), formando uma lama biológica que é separada por decantação secundária (Gomes, 2011; Metcalf & Eddy, 2004).

É no reator aeróbio que se desenvolve e se faz a manutenção da cultura microbiana, na presença de matéria orgânica e oxigênio. Este último é obtido através de uma corrente de ar artificial que entra no reator, e só assim é possível manter as condições aeróbias necessários ao bom funcionamento. Este arejamento tem três funções importantes: manter uma boa homogeneização do reator, a síntese de novas células e uma respiração endógena (Metcalf & Eddy, 2004). Relativamente à concentração de biomassa no reator, recorre-se à recirculação de lamas biológicas para que esta seja constante. Para tal é essencial que se forme um bom floco biológico - massa biologicamente ativa resultante de processos de floculação de partículas coloidais orgânicas e inorgânicas e de células vivas - que seja fácil de sedimentar num decantador secundário (Metcalf & Eddy, 2004; Pereira 2008). Essas lamas recolhidas no decantador secundário sofrem o tratamento da fase sólida, que será descrita mais à frente.

Os biofiltros, os leitos percoladores e os biodiscos são exemplos de equipamento onde são aplicáveis processos por biomassa fixa, em que ocorre a adesão dos microrganismos a um meio de suporte (Pereira, 2008). Os materiais usados para esta adesão têm de ser resistentes às condições das águas residuais para que durem vários anos, sendo necessária uma grande área para promover o crescimento dos microrganismos, assim como espaço livre para a sua ventilação. Materiais sintéticos, pedra ou areia são exemplos de tipos de suporte a utilizar.

Os leitos percoladores são os mais utilizados quando se trata de processos por biomassa fixa para o tratamento de águas residuais, possuindo uma eficiência de remoção de carga orgânica de 85%. Tal como acontece nos tratamentos com biomassa suspensa, a matéria orgânica é removida por oxidação biológica e há síntese de novas células, a (Gomes, 2011; Metcalf & Eddy, 2004).

É de salientar que sempre que há formação de sólidos, aquando do tratamento secundário, é necessário a existência de um decantador, cuja função é a separação do efluente líquido dos sólidos, em semelhança ao decantador primário (Metcalf & Eddy, 2004).

#### **3.1.1.4. Tratamento terciário**

Esta fase do tratamento ocorre antes da descarga das águas residuais tratadas, por isso a sua finalidade é acertar todos os parâmetros da composição da água para que cumpra a legislação e certificar a qualidade. Estes parâmetros são importantes para que, posteriormente, a

água possa ser utilizada para diversos fins, como consumo humano, atividades agrícolas ou recreativas (Pereira, 2008). Pretende-se que haja uma remoção adicional do material dissolvido ou suspenso ainda existente na água residual após a série processos já aplicados, bem como a remoção ou inativação de microrganismos patogênicos nela presentes.

Dependendo daquilo que se quer remover, existem vários processos a ser utilizados. A precipitação química é usada para a remoção de nutrientes, como azoto e fósforo. De forma a pôr fim aos microrganismos patogênicos, a desinfecção é o método mais indicado. O cloro, ozono e a radiação ultravioleta estão entre os compostos mais usuais para a realização da desinfecção (Gomes, 2011; Metcalf & Eddy, 2004).

Além dos referidos, existem outros processos que contribuem para a melhoria do efluente para que este possa ter fins úteis, tais como: filtração, coagulação e decantação, osmose inversa, troca iônica, entre outros (Pereira, 2008).

### **3.1.2. Tratamento da fase sólida**

Há medida que ocorre o tratamento da fase líquida vão sendo produzidos vários subprodutos: gradados, areias, gorduras, lamas primárias e secundárias (biológicas) (Pereira, 2008).

**Gradados:** Este subproduto é proveniente da etapa gradagem, do tratamento primário. O seu destino final são os aterros sanitários, para tal são sujeitos a compactação e colocados em contentores.

**Areias:** Também pertencente ao tratamento primário, este subproduto resulta da etapa desarenamento. Tem o mesmo fim dos gradados, mas antes de ir para o aterro sanitário são lavadas para que se remova uma parte de matéria orgânica ainda existente, e seguidamente são depositadas em contentores.

**Gorduras:** As gorduras são recolhidas do decantador primário e são encaminhadas para um concentrador de gorduras onde grande parte da água é removida. Antes da sua eliminação, sofrem ainda um tratamento adequado para minimizar o impacte ambiental.

**Lamas primárias e lamas secundárias (biológicas):** Subproduto com maior concentração volúmica de todo o processo de tratamento de águas residuais. O principal objetivo do tratamento de lamas é retirar a máxima quantidade de água possível, para reduzir o volume das lamas, pois o custo de eliminação delas depende do seu volume. Além disto a redução do

volume permite a diminuição dos custos de transporte para encaminhar as lamas para o seu destino final, a sua compostagem e deposição num aterro, melhorar o seu transporte e o manuseamento, redução dos cheiros e pode levar ao aumento do poder calorífico quando incineradas devido à menor quantidade de água que possuem (Metcalf & Eddy, 2004; Pereira, 2008).

As lamas primárias provêm do tratamento preliminar e na sua constituição podem existir sólidos orgânicos, matéria orgânica de maiores dimensões bem como areias. As lamas secundárias ou biológicas provêm do tratamento secundário, em que as lamas são formadas devido à conversão da matéria orgânica solúvel em biomassa e de partículas de pequenas dimensões em que o tratamento primário não é capaz de as “tratar” (Metcalf & Eddy, 2004). Assim sendo, as lamas secundárias têm menos teor em matéria orgânica (Florindo, 2009).

O tratamento das lamas baseia-se em três etapas: espessamento, estabilização e desidratação, que será descrito seguidamente.

### **3.1.2.1 Espessamento das lamas**

É a primeira etapa do tratamento das lamas primárias e secundárias ou mistas, e é feito num equipamento muito semelhante ao decantador. A principal finalidade do espessamento é a redução do teor de água presente nas lamas, aumentando assim o teor de sólidos das lamas (Metcalf & Eddy, 2004).

Este tratamento pode ser feito através de vários processos, tais como: floculação química, adição de eletrólitos minerais, por tratamento térmico, congelação, electro-osmose entre outros. (Florindo, 2009)

### **3.1.2.2. Estabilização das lamas**

Os objetivos desta fase de tratamento visam reduzir o volume das lamas, eliminar os agentes de putrefação e os organismos existentes nas lamas (Metcalf & Eddy, 2004).

A estabilização pode ser feita por via química, tendo a título de exemplo a adição de cal, ou biológica, sendo a digestão aeróbia, a digestão anaeróbia, a compostagem ou a incineração os possíveis processos. A digestão anaeróbia é a mais utilizada, pois apenas uma pequena

percentagem da matéria orgânica se converte em novas células, devido à ausência de oxigénio, havendo assim uma menor produção de lamas (Pereira, 2008). Quanto à eficiência deste processo, cerca de 70 a 85% da matéria orgânica biodegradável presente nas águas residuais passa a metano, 5% a 15% são convertidos a biomassa microbiana, aumentando a quantidade de lamas, e cerca de 10% a 30% refere-se à quantidade de material que não é degradado (Carvalho, 1998). É importante salientar que o potencial de carga de um reator anaeróbio é determinado pela quantidade de lama que consegue ficar retida no reator (Carvalho, 1998).

Relativamente à mistura de resíduos, lamas residuais, em termos de N, P, K permanece praticamente inalterado à passagem pelo digestor, verificando-se fundamentalmente uma conversão dos nutrientes da sua forma orgânica original para uma forma mineralizada (Metcalf & Eddy, 2004).

Depois de proceder à estabilização das lamas, estas são encaminhadas para a etapa final deste tratamento e o sobrenadante retoma para o tratamento da fase líquida.

### **3.1.2.3 Desidratação das lamas**

A desidratação tem como objetivo remover a água ainda presente nas lamas que provêm do digestor, de forma a reduzir ao máximo o seu volume. De entre os vários métodos existentes para o procedimento desta última fase do tratamento, os mais utilizados são a filtração e a separação por centrífuga (Metcalf & Eddy, 2004). Estes meios são dispendiosos, mas optar por alternativas mais naturais obriga a ter uma maior área disponível; tem-se como exemplo os leitos de secagem. A concentração final das lamas vai depender em grande parte dos métodos escolhidos ao longo do seu tratamento, mas o valor médio é de 20% (Metcalf & Eddy, 2004).


Após todo o tratamento, as lamas têm três fins possíveis, dependendo da sua qualidade: valorização agrícola, aterro sanitário ou incineração. A valorização agrícola é a menos dispendiosa e tem outras vantagens associadas, tais como a melhoria da produtividade do solo e a reciclagem de nutrientes.

### 3.2. Processo de Digestão Anaeróbia

O processo microbiológico que ocorre na ausência de oxigênio, em que a matéria orgânica é convertida em metano e dióxido de carbono, é denominado por digestão anaeróbia. Ocorre em diversos meios naturais como sedimentos, fontes termais e sistemas gastrointestinais, mas também em ambientes controlados, dos quais se destacam os digestores anaeróbios.

#### 3.2.1. Fases, Microbiologia e Bioquímica da digestão anaeróbia

A digestão anaeróbia de compostos orgânicos pode ser dividida em quatro fases: hidrólise, acidogênese, acetogênese e metanogênese (Esquema 6).



Esquema 6. Bioquímica e Microbiologia do processo de digestão anaeróbia (adaptado de Alves, 1998).

Na primeira fase, hidrólise, há necessidade de hidrolisar a matéria orgânica (proteínas, lípidos, gorduras) transformando-a em materiais dissolvidos mais simples capazes de atravessar as paredes celulares das bactérias fermentativas hidrolíticas. Como se pode observar pelo

esquema 6 acima apresentado, os glícidos ou polissacáridos são hidrolisados em monossacáridos, as proteínas em aminoácidos e os lípidos ou gorduras a ácidos gordos e glicerol. A hidrólise ocorre porque as bactérias não têm capacidade para assimilar material orgânico na forma particulada. O tempo de hidrólise depende da superfície específica e do tipo de substrato, pelo que pode tornar-se uma etapa lenta, uma vez que os lípidos normalmente hidrolisam a uma velocidade menor quando comparados com outras macromoléculas (Henze e Harremões, 1983). Segundo Martinelle e Hult (1994), a velocidade do processo de hidrólise de gorduras depende fundamentalmente do comprimento das cadeias dos AGV, do estado do substrato (sólido ou líquido) e da área superficial específica. Relativamente às proteínas, a sua composição, solubilidade e área superficial são as grandes condicionantes da velocidade do processo nesta etapa (McInerney, 1988). É também importante salientar que durante a degradação das proteínas é libertado azoto sob a forma de amónia (Vavilin *et al.*, 2008).

Seguidamente ocorre a acidogénese, também denominada por fermentação, em que os compostos solúveis provenientes da hidrólise, por ação de bactérias fermentativas, são metabolizados em produtos mais simples, AGV, álcoois, hidrogénio, para serem excretados. Estas bactérias, na sua grande parte, são anaeróbias estritas o que implica a não tolerância à presença de oxigénio. Além disso, conseguem sobreviver em ambientes adversos devido à sua formação de esporos. É de salientar que a população fermentativa representa cerca de 90% da população bacteriana dos digestores anaeróbios (Alves, 1998). O hidrogénio tem um papel bastante importante no que toca à rentabilidade em termos energéticos, pois quando a pressão parcial é igual ou inferior a  $10^4$  atm há a formação de acetato e hidrogénio (Mosey e Fernandez, 1984), caso contrário há a formação de butirato e propionato. Quando comparados os dois percursos, o primeiro é o processo mais rentável, já o segundo, ocorre como consequência de choques orgânicos, hidráulicos ou até mesmo térmicos (Lau e Fang, 1997). Nesta etapa do processo de digestão, a maior parte das bactérias fermentativas são anaeróbias obrigatórias existindo apenas algumas anaeróbias facultativas que permitem manter o potencial redox do meio a um baixo nível. Adicionalmente, consomem o oxigénio que pode entrar no digestor, dissolvido no efluente (Alves, 1998).




Na terceira etapa ocorre a acetogénese, em que há uma oxidação dos compostos formados na acidogénese, AGV (como o propionato e butirato), álcoois e outros para que os compostos fiquem aptos para a última etapa da digestão anaeróbia. O hidrogénio, o acetato e o dióxido de carbono são os compostos formados pelas bactérias acetogénicas e levam a que haja



um decréscimo do pH do meio aquoso (Costa, 2007). De todos os produtos metabolizados pelas bactérias acidogénicas apenas o hidrogénio e o acetato podem ser utilizados pelas bactérias que intervêm na fase seguinte, a metanogénese.

Na última fase deste processo, metanogénese, há a formação de dióxido de carbono e de metano por ação das bactérias metanogénicas. Este tipo de bactérias pode dividir-se em dois grupos, acetoclásticas, havendo formação de metano a partir do ácido acético, e hidrogenotróficas, havendo produção de metano através do dióxido de carbono e hidrogénio (Alves, 1998). Com isto pode haver recuperação em termos energéticos (Florindo, 2009).

De seguida apresenta-se algumas das reações que ocorrem nesta fase da digestão anaeróbia:



Sabe-se que a maior parte do metano, cerca de 70%, provém do acetato. As bactérias responsáveis por esta degradação representam o elo mais fraco de toda a cadeia de digestão anaeróbia, pois são menos resistentes a condições adversas como choques hidráulicos ou orgânicos bem como há presença de substâncias tóxicas (Alves, 1998).

### 3.2.2. Requisitos nutricionais

Para certificar que todo o processo da digestão anaeróbia é eficiente e estável é necessário assegurar a presença de certos nutrientes, macro e micronutrientes, para que todas as bactérias intervenientes possam ter um crescimento dito normal, pois a limitação destes levaria a um crescimento deficiente. Em alguns casos, os nutrientes presentes no efluente a tratar podem ser suficientes para o crescimento das bactérias (Lema *et al.*, 1992). Por forma a haver uma maior remoção da matéria orgânica no processo de digestão anaeróbia, a adição de macro e micronutrientes a determinados efluentes, em quantidades corretas, é fundamental, pois pode minimizar os custos envolvidos no processo bem como evitar problemas de eutrofização à saída (Alves, 1998; Broderick e Sherrard, 1985).

**Macronutrientes:** O azoto, o fósforo e o enxofre são os nutrientes que são precisos em maior quantidade durante o processo anaeróbio (Mara e Horan, 2003).

Segundo Silveira (2009), a razão carbono/azoto é bastante importante no processo de digestão anaeróbia, uma vez que um destes componentes pode tornar-se limitante. O azoto é por si só o nutriente que leva a que as bactérias tenham um crescimento adequado para o normal funcionamento de um digestor, já o carbono funciona como fonte de energia para os microrganismos existentes. Para que a atividade no digestor seja considerada ótima, a razão carbono/azoto deve ser de 30:1, pois as bactérias utilizam o carbono cerca de 30 vezes mais rápido do que o azoto (Igoni *et al.*, 2008).

A fonte de azoto mais pretendida pelos microrganismos metanogénicos é o ião amónio ( $\text{NH}_4^+$ ), pois a sua presença faz aumentar o crescimento das bactérias referidas (Alves 1998).

Relativamente à fonte de fósforo, quer o ácido fosfórico quer o sal de fosfato são bons nutrientes para adicionar ao digestor (Cavaleiro, 1999). Os precipitados inorgânicos de fosfato podem funcionar, nos digestores anaeróbios, como fonte interna de fósforo.

Outro macronutriente necessário é o enxofre, bastante importante nas reações metanogénicas. São utilizados sulfuretos que podem levar à precipitação de alguns metais necessários no meio, como o ferro, níquel e cobalto (Speece, 1983).

**Micronutrientes:** São vários os elementos necessários numa quantidade menor para o bom funcionamento deste processo, destacando-se três compostos o ferro, o cobalto e o níquel.

O ferro funciona como fonte de eletrões que intervêm no metabolismo e está presente em citocromos e ferredoxinas (Alves, 1998).

Relativamente ao cobalto, sabe-se que este é o nutriente que afeta a metanogénese a partir do metanol, pois estimula as bactérias intervenientes nesta fase que utilizam diretamente o metanol (Florêncio *et al.*, 1997).

Outro dos micronutrientes mais destacados é o níquel, trata-se de um constituinte do fator F430, que está envolvido nas reações metanogénicas. Além disto, nas membranas celulares existem elevados níveis de níquel, daí que também pode estar relacionado com a estabilidade estrutural (Alves, 1998).

### 3.2.3. Fatores ambientais e parâmetros que influenciam a digestão anaeróbia

Para o bom funcionamento do processo de digestão anaeróbia, existem várias condições ambientais que o afetam, tais como o pH, a alcalinidade e a temperatura.

Os microrganismos são muito sensíveis a variações de **pH**. Este tem um efeito muito importante na atividade enzimática de cada microrganismo, cada um deles possui um pH ótimo que se traduz numa máxima atividade (El-Mashad *et al.*, 2004). Os vários grupos bacterianos envolvidos no processo da digestão anaeróbia têm atividades máximas para pH entre 6 e 7,6 (Zehnder *et al.*, 1980). Sendo as bactérias metanogénicas, normalmente, as responsáveis pela cinética global do processo e até as mais sensíveis, considera-se que a gama de pH ótima para estes microrganismos é a apropriada para a digestão anaeróbia, isto é, pH com valores de 6,6 a 7,6 (Cavaleiro, 1999; Silveira, 2009). Sabe-se que o pH afeta a taxa de crescimento dos microrganismos bem como a sua morfologia e a sua estrutura, o que pode dificultar os fenómenos de adesão e floculação no digestor (Forage *et al.*, 1985). Além disto, alguns compostos podem tornar-se tóxicos devido a grandes mudanças de pH: para valores de pH baixos, os AGV livres podem causar inibição por ácidos fracos, enquanto para valores de pH elevados, a amónia livre pode causar inibição por bases fracas. Em ambos os casos geram-se formas não ionizadas que penetram a célula e aumenta a concentração intracelular de hidrogénio no meio, dadas as dissociações que provocam. Isto pode tornar-se um problema, pois existindo demasiados prótons existe a necessidade de os anular, o que provoca o gasto de ATP, havendo uma menor disponibilidade para o crescimento e metabolismo dos microrganismos (Fukuzaki *et al.*, 1990).

Outro fator importante no processo de digestão anaeróbia é a **alcalinidade**. Trata-se da medida representativa da capacidade tampão do meio, isto é, refere-se à resistência do meio a variações de pH. Os AGV são um produto intermediário da digestão anaeróbia que provocam uma elevada descida de pH do meio, caso a alcalinidade não seja suficiente. Quando o efluente a tratar tem um fraco poder tampão, é necessário corrigir o pH por adição de um reagente alcalino (Cavaleiro, 1999). Além dos AGV, a amónia ( $\text{NH}_4^+$ ,  $\text{NH}_3$ ), sulfuretos ( $\text{H}_2\text{S}$ ,  $\text{HS}^-$ ,  $\text{S}^{2-}$ ) e fosfatos ( $\text{H}_3\text{PO}_4$ ,  $\text{H}_2\text{PO}_4^-$ ,  $\text{HPO}_4^{2-}$ ,  $\text{PO}_4^{3-}$ ), também influenciam o balanço de pH (Silveira, 2009).

A **temperatura** é um parâmetro relevante na digestão anaeróbia, quer do ponto de vista cinético quer do ponto de vista termodinâmico. Em particular, a metanogénese é

fortemente influenciada por este parâmetro, as taxas de degradação e dos coeficientes de crescimento são dependentes da temperatura (Costa *et al.*, 2007). Na digestão anaeróbia existe uma variedade de gamas para o seu funcionamento: gama psicrófila (<20 °C), gama mesófila (20-45 °C) e termófila (>45 °C). As gamas termófila e mesófila, são aquelas em que há um crescimento máximo de microrganismos da fase metanogénica, sendo que as temperaturas preferenciais são entre 30 e 38 °C, na fase mesófila e de 49 a 57 °C, na fase termófila (Alves, 1998; Cavaleiro, 1999). A temperatura num digester deve ser constante o máximo possível para evitar efeitos negativos para o crescimento dos microrganismos presentes. O regime termófilo possui várias vantagens: aumenta a solubilidade dos compostos orgânicos, o que permite uma maior assimilação por parte dos microrganismos; permite aumentar as taxas de reações químicas e biológicas dentro do digester, acelerando o processo e fazendo com que seja possível a utilização de um digester de menor volume bem como um menor tempo de residência hidráulico; a taxa de destruição das bactérias patogénicas também pode aumentar (Van Lier, 1995). No entanto, a utilização de temperaturas elevadas acaba por tornar o processo instável, pois leva a um aumento da fração de amónia livre (NH<sub>3</sub>) que é inibitória para o processo, bem como de AGV, e necessita também de um maior consumo de energia para controlar a temperatura. Por outro lado, o processo mesófilo não exige um controlo tão grande, sendo mais estável e acabando por ser mais vantajoso.

Além dos fatores ambientais, outros parâmetros têm influência no processo, tais como o **tempo de retenção hidráulico (TRH) e agitação.**

O **TRH** refere-se ao tempo médio que um determinado volume de efluente permanece num digester. Este tempo deve ser o necessário de forma a garantir a degradação da matéria orgânica, ao passo que mantém o processo estável e minimiza a produção de lamas (Speece, 1983; Silveira, 2009).

A função da **agitação** é melhorar o contacto entre o substrato proveniente com a biomassa presente no digester, o que fará com que se evite a deposição de lama no fundo do digester bem como a formação de espuma à superfície (Ward *et al.*, 2008; Appels, 2008). Os métodos de agitação mais utilizados são a recirculação exterior de lama e agitação mecânica interna (Igoni *et al.*, 2008). Silveira (2009) cita vários estudos dos autores McMahon *et al.* (2001), Stroot *et al.* (2001) e Vavilin e Angelidaki (2005), que concluem que em digestores

completamente agitados, a intensidade de agitação do líquido em digestão influencia a inibição do processo bem como a sua recuperação em caso de um desequilíbrio orgânico.

Além destes parâmetros que influenciam o processo, existem outros fatores que podem afetá-lo, a **toxicidade e inibição**.

O processo de digestão anaeróbia contém diversos tipos de microrganismos que possuem diferentes respostas face aos compostos que fazem parte do substrato do afluyente ou face àqueles que são formados durante o processo, os subprodutos da digestão. Estes podem levar à diminuição da velocidade de processo (toxicidade) ou mesmo paragem do mesmo (inibição).

Os compostos inibitórios podem ser classificados como (Soto et al, 1992; Cavaleiro, 1999):

- inibidores metabólicos, os quais causam inibição reversível, após o seu desaparecimento do meio a atividade do digestor volta ao normal;
- inibidores fisiológicos, afetam os produtos formados ao longo da digestão, de forma que os seus efeitos continuam após o seu desaparecimento do meio;
- agentes bactericidas, conduzem à morte da flora bacteriana.

A **amónia** é um dos subprodutos da digestão anaeróbia, formado na primeira fase do processo. Dependendo dos níveis de pH pode formar-se o ião amónio ( $\text{NH}_4^+$ ) ou amónia livre ( $\text{NH}_3$ ). Este último é mais tóxico para o processo, pois é a forma não ionizada e formada a pH mais elevados (Cavaleiro, 1999), tem a capacidade de penetrar nas paredes das células levando a uma desregulação do balanço de protões bem como à deficiência de potássio (Chen *et al.*, 2008; Silveira, 2009). Já a sua forma ionizada tem um efeito contrário no processo, pois a sua presença leva à produção de hidróxido, que ao reagir com o dióxido de carbono forma bicarbonato, aumentando a capacidade tampão do processo (Silveira, 2009).

Quer o pH, a temperatura ou a concentração total de amónia ( $\text{NH}_4^+ + \text{NH}_3$ ), são fatores que interferem na concentração da amónia livre existente no digestor. Normalmente um aumento dos dois primeiros fatores referidos leva a um acréscimo da toxicidade, inibindo a atividade metanogénica, uma vez que aumenta a concentração da forma não ionizada comparativamente à forma ionizada (Borja *et al.*, 1996). Tal facto faz com que o processo se torne instável pois existe acumulação de AGV. Como consequência, há um decréscimo do valor

de pH, que leva a uma diminuição da amónia livre (Chen *et al.*, 2008; Vavilin *et al.*, 1995). Esta sucessão de reações leva a que o processo de digestão anaeróbia permaneça estável, mas com menor produção de metano.

Outros inibidores presentes no processo de digestão anaeróbia são os **sulfuretos**, estes são formados na presença de sulfatos e a baixos valores de pH (Cavaleiro, 2009). Nos digestores anaeróbios, este composto está presente em solução de diversas formas, tais como:  $S_2$ , HS e  $H_2S$  em solução;  $H_2S$  no biogás e ainda sulfuretos metálicos insolúveis (Silveira, 2009). Mas é a concentração de  $H_2S$  que mais inibe, pois este composto quando presente, e sendo uma partícula neutra, pode penetrar na membrana celular e provoca a inibição das bactérias metanogénicas. Esta inibição pode ser menor caso haja um período de adaptação destas bactérias com o  $H_2S$ , levando ao aumento da tolerância perante este inibidor (Chen *et al.*, 2008). O grau de inibição provocado pelos sulfuretos depende do pH, temperatura, concentração de iões metálicos e do tipo de digestor (Mara e Horan, 2003).

Os **metais pesados** estão normalmente presentes em efluentes industriais e domésticos e podem ter efeitos inibidores quando presentes na sua forma ionizada. Estes compostos não biodegradáveis, vão-se acumulando e podem atingir concentrações potencialmente tóxicas, inibindo diretamente a metanogénese, os microrganismos que nela intervêm e afetar a produção de metano (Chen *et al.*, 2008; Gonçalves, 1988). As principais causas deste nível de toxicidade recaem sobre o crómio, o níquel, o cobre, o cádmio, o ferro, o zinco e o chumbo (Jin *et al.*, 1998). Contudo quanto maior o teor em sólidos menor a suscetibilidade do sistema entrar em inibição e a presença de sulfuretos provoca a precipitação destes compostos (Silveira 2009).

Os **metais alcalinos e alcalino-terrosos** são utilizados, fundamentalmente a baixas concentrações para controlo do pH, sendo eles o sódio, o potássio, o cálcio e o magnésio (Cavaleiro, 1999). No entanto, quando a sua adição se torna excessiva têm um efeito inibitório para o processo anaeróbio.

Segundo estudos citados em Silveira (2009), o magnésio ou a combinação de cálcio e potássio reduzem a toxicidade provocada pelo sódio e por sua vez o efeito combinado de cálcio e sódio reduz a toxicidade provocada pelo potássio (Bashir e Matin, 2004a; Bashir e Matin, 2004b; Bashir e Matin, 2004c).

### 3.2.4. Influência dos Gorduras na digestão anaeróbia

Os lípidos são macromoléculas que intervêm no processo de digestão anaeróbia, sendo constituintes da matéria orgânica dos efluentes e que possuem um elevado potencial metanogénico (Alves e Cavaleiro, 2004). Têm uma importância acrescida em efluentes industriais dado que as gorduras estão presentes em concentrações mais elevadas quando comparado com os efluentes domésticos. Como já foi referido, na primeira etapa da digestão anaeróbia ocorre a hidrólise dos lípidos, sendo formados ácidos gordos de cadeia longa (AGCL) ou AGV e glicerol. Existem dois tipos de problemas associados à degradação anaeróbia de gorduras: problemas físicos e metabólicos. Os problemas físicos relacionam-se com a acumulação dos lípidos nos agregados da biomassa. Alves e Cavaleiro (2004) cita estudos de Hanaki *et al.* (1981), Rinzema *et al.* (1994) e Hwu *et al.* (1998), que provam que esta acumulação torna os agregados de biomassa leves e, por consequência, a sua flutuação e até saída do reator. Este tipo de problemas é mais evidente em processos de alta carga baseados em biomassa granular, uma vez que os AGCL desintegram os grânulos. Hwu *et al.* (1998) verificou que as lamas floculentas e em suspensão, que possuem maior área de superfície específica, eram muito mais suscetíveis à inibição comparativamente à lama granular. Relativamente aos problemas metabólicos, existem vários estudos que provam que os AGCL podem funcionar como bactericidas graças à sua adsorção à parede celular das bactérias, afetando as suas funções de proteção da célula e transporte (Alves *et al.*, 2004; Mechichi e Sayadi 2005; Rinzema *et al.*, 1994).

Alves *et al.* (2004) fizeram um estudo que permitiu obter novos dados acerca da acumulação e degradação de AGCL em condições anaeróbias. Foi utilizado o ácido oleico como AGCL a alimentar um reator de alta carga, pois é descrito como um dos mais abundantes na natureza e dos mais tóxicos para a biomassa. Verificou-se que havia um passo, mediado biologicamente, de conversão entre o ácido oleico e o ácido palmítico e que este último se acumulava associado à biomassa, sem ser posteriormente mineralizado nas condições operatórias prevalentes no reator. Contudo, ao retirar-se biomassa do reator e incubar-se num reator fechado sem a adição de qualquer outra fonte de carbono, ocorria uma eficiente mineralização a metano. Este estudo mostrou também que após a degradação dos ácidos gordos associados à biomassa, esta recupera significativamente a atividade metanogénica,

estando capaz de receber uma nova “carga” de ácidos gordos e de os degradar eficientemente. Os autores concluíram que os AGCL podem ser eficientemente mineralizados a metano, desde que se apliquem as condições apropriadas. Este estudo contraria assim as teorias estabelecidas de toxicidade permanente por parte dos AGCL, pois a sua inibição é reversível, provavelmente tratando-se somente de um efeito físico que afeta o transporte de substrato entre o líquido e a superfície das células. Do ponto de vista prático, esta investigação mostra que no tratamento de efluentes com elevados teores de lípidos, o processo contínuo de alta carga não é possível e só um processo descontínuo baseado na tecnologia dos reatores fechados sequenciais permite a mineralização deste tipo de compostos a metano.

### **3.2.5. Perturbações à operação em estado estacionário**

Dado todos os processos inibitórios e a lenta dinâmica do processo de digestão anaeróbia, é importante que se consiga atingir um certo nível de estabilidade no digestor para que não existam longos períodos de inatividade. Existem assim várias perturbações que podem ocorrer num digestor anaeróbio (Soto *et al.*, 1992):

- Sobrecargas do equipamento a nível hidráulico ou orgânico;
- Variações de temperatura – choque térmico;
- Alterações das condições físico-químicas do processo: pH, temperatura, potencial redox;
- Presença de substâncias tóxicas ou inibitórias;
- Modificações progressivas no equipamento.

#### **Choque Térmico**

Trata-se de qualquer mudança súbita no valor da temperatura do meio. Existem vários fatores que condicionam os efeitos que um choque térmico pode ter, sendo eles a temperatura que é aplicada, o tempo que essa temperatura permanece e qual a composição bacteriana da biomassa (Van Lier *et al.*, 1996). Esta perturbação pode ter consequências reversíveis ou irreversíveis dependendo se há um aumento ou uma diminuição da temperatura. No primeiro caso, pode haver uma deterioração irreversível do processo, dado que as bactérias são muito sensíveis a altas temperaturas. Já no segundo caso, a diminuição da temperatura faz com que o



crescimento seja mais lento, levando a uma redução da atividade por parte dos microrganismos presentes (Cavaleiro, 1999; Ribeiro, 1999).

### **Choque orgânico**

Os choques orgânicos ocorrem quando há um aumento da quantidade de matéria orgânica aplicada ao sistema. Resultam da concentração na alimentação de carga orgânica, com o caudal é constante, ou o contrário, do um aumento de caudal mantendo a carga orgânica. Estas alterações devem-se a picos de operação ao nível industrial ou em termos de consumos domésticos, mas podem surgir dado a acidentes de derrames nas linhas dos efluentes (Ribeiro, 1999).

Como resultado destes choques há alterações no funcionamento do digestor, nomeadamente ao nível da concentração de hidrogénio, devido à dificuldade dos microrganismos hidrogenofílicos metabolizarem o hidrogénio que é produzido em excesso pelas bactérias acidogénicas, originando um aumento da concentração deste componente no meio. Além disto, existe também uma acumulação de AGV, principalmente butirato e propionato, que leva à formação de outros compostos mais ramificados, como AGCL. Tal facto provoca uma diminuição do pH, gerada pelo esgotamento da alcalinidade que, por consequência, leva a um aumento da concentração de dióxido de carbono presente no biogás (Delorme e Kapuscinski, 1990; Soto *et al.*, 1992). Uma vez que este choque orgânico provoca inibição nas bactérias metanogénicas, embora possa existir um aumento na produção de biogás, não significa um aumento da produção de metano, mas sim de CO<sub>2</sub> e, por consequência, a produção de um biogás mais pobre em termos de potencial energético (Soto *et al.*, 1992).

De forma a resolver este problema, deve-se diminuir a carga orgânica através da diluição do afluente ou aumentar a atividade da biomassa, possível através da adição de lamas ao digestor ou através de aumentos da temperatura, caso não esteja a operar à temperatura ótima (Ribeiro, 1999).

### **Choque Hidráulico**

Este tipo de perturbação é originada quando há um aumento súbito de caudal alimentado ao digestor anaeróbio, resultante quer do aumento de produção de águas residuais, aliada a um período de maior consumo de água, quer devido à junção de águas pluviais à linha

de efluentes. Normalmente, um choque hidráulico vem acompanhado com uma sobrecarga orgânica (choque orgânico) caso a concentração da alimentação se mantenha constante.

Os problemas que surgem são semelhantes aos do choque orgânico, provocando além desses danos irreversíveis ao nível do funcionamento do digestor, nomeadamente ao nível da biomassa: desprendimento da biomassa do meio de suporte, fragmentação dos grânulos e por consequência pode haver “*washout*” da biomassa (Soto *et al.*, 1992).

### **Choque tóxico**

O choque tóxico é um tipo de problema que pode ou não ser acompanhado por um choque orgânico ou hidráulico e que corresponde ao aparecimento de substâncias tóxicas no processo. Tal pode acontecer por acidente ou devido a uma operação defeituosa do sistema (Cavaleiro, 1999). Existem dois tipos de inibição (Speece, 1996; Ribeiro, 1999):

- metabólica – inibição reversível, há recuperação da atividade original após a eliminação do composto ou que se tenha desenvolvido resistência;

- fisiológica ou bactericida – o efeito destes inibidores permanece durante algum tempo, pois afetam os componentes subcelulares das bactérias. Há uma inibição irreversível, devido à morte da flora bacteriana.

As etapas mais afetadas do processo são a acetogénese e metanogénese, e a diminuição da produção de metano e a acidificação do digestor são os maiores problemas causados. Além do tipo de composto que provoca a inibição, há outras condicionantes que influenciam o choque tóxico, como a concentração da substância tóxica, o tempo de exposição, o TRH e a temperatura da operação (Speece, 1996).

### **3.2.6 Biogás**

Em tempos passados, o biogás era simplesmente encarado como um subproduto da digestão anaeróbia, mas com o passar do tempo, a escassez de combustíveis fósseis existente e a crescente elevação dos preços dos combustíveis, surgiu a necessidade de recorrer a fontes de energia alternativas e economicamente atrativas para preservar recursos naturais. Assim, o biogás começou a ser estudado mais profundamente para ser utilizado como uma fonte de

energia alternativa, dada a redução dos impactos ambientais causados comparativamente à utilização de combustíveis fósseis.

Este composto é formado através da digestão anaeróbia de resíduos sólidos ou líquidos e a sua constituição é apresentada na tabela 1 com as respectivas percentagens de cada componente.

Tabela 1. Constituição do Biogás (adaptado de Salomon, 2007)

<b>Componentes</b>	<b>Percentagem (%)</b>
Metano (CH <sub>4</sub> )	40-75
Dioxido de Carbono (CO <sub>2</sub> )	25-40
Azoto (N)	0,5-2,5
Oxigénio (O)	0,1-1
Ácido Sulfídrico (H <sub>2</sub> S)	0,1-0,5
Amónia (NH <sub>3</sub> )	0,1-0,5
Monóxido de Carbono (CO)	0-0,1
Hidrogénio (H)	1-3

A percentagem de cada componente na composição deste gás vai depender da eficiência do processo, influenciada por fatores como a temperatura, pressão e carga orgânica aquando da acidogénese (Galbiatti *et al.*, 2010). Dado que o ácido sulfídrico é por norma um dos compostos mais presentes na concentração de biogás, seguido do metano e dióxido de carbono, respetivamente, torna o gás corrosivo, sendo necessário que haja adaptação dos equipamentos utilizados. Ao contrário do propano e butano, o metano é um gás leve, de fraca densidade, que ocupa um volume significativo dificultando a sua liquefação, o seu transporte e o seu armazenamento. A Tabela 2 mostra a equivalência energética de 1 m<sup>3</sup> de biogás com outras fontes.

Tabela 2. Equivalências energéticas do biogás (adaptado de Pompermayer, 2000)

<b>Fonte</b>	<b>Equivalência</b>
Gasolina (L)	0,61-0,70
Álcool (L)	0,80
Carvão mineral (kg)	0,74
Electricidade (kWh)	1,25-1,43

Tendo em conta que o poder calorífico do metano é  $35.800 \text{ kJ/m}^3$ , e que é o maior componente presente e, portanto, o mais influente, temos que o poder calorífico do biogás varia entre  $22.500$  a  $25.000 \text{ kJ/m}^3$ . Sabe-se então que há um aproveitamento de  $6,25$  a  $10 \text{ kWh/m}^3$ , sendo que a sua potencialidade pode chegar até  $60\%$  do poder calorífico do gás natural (Jordão *et al.*, 1995).

É importante ter conhecimento de como variam os componentes presentes na sua constituição para que haja um maior controlo da qualidade do biogás que se armazena (Galbiatti *et al.*, 2010). Tudo isto depende das características dos resíduos presentes no processo de digestão, uma vez que cada tipo de resíduo orgânico apresenta potenciais diferentes.

A produção de energia elétrica a partir do biogás apresenta vantagens aos mais variados níveis, tais como (Salomon, 2007):

- Redução das emissões de metano para a atmosfera, um dos principais gases pelo efeito de estufa;
- Diminuição do consumo de combustíveis fósseis
- Produção de energia elétrica a partir do biogás por processos de cogeração, quer para uso da própria entidade quer para venda, sendo mais favorável economicamente.

A utilização de biogás requer que sejam estabelecidas certas medidas de segurança para que não ocorram explosões. A formação do pessoal que opera no sistema de tratamento, a sinalização adequada nas áreas de maior perigo, a monitorização da composição do biogás, os critérios de segurança e execução impostas por empresas especializadas e o respeito dessas mesmas normas são medidas a ter em conta aquando da utilização deste biocombustível.

A utilização do biogás na geração termoelétrica requer especial atenção devido ao conteúdo de ácido sulfídrico ( $H_2S$ ) e à humidade presente no gás, sendo fundamental proceder à limpeza do biogás antes de qualquer utilização em máquinas térmicas.

### **3.3. Redes Neurais Artificiais**

As Redes Neurais Artificiais são modelos computacionais inspirados na biologia, que atuam de forma similar ao cérebro humano tendo a capacidade de entender relações complexas existentes num determinado conjunto de dados.

De acordo com Haykin (1999), citado em Matos (2008), e indo ao encontro do que já foi dito, as RNA podem ser definidas da seguinte forma: “Uma rede neuronal artificial é um processador massivamente distribuído em paralelo constituído por unidades de processamento simples, que tem a propensão natural para armazenar conhecimento experimental e torná-lo disponível para ser utilizado. Assemelha-se ao cérebro em dois aspetos: 1) O conhecimento é adquirido pela rede a partir do meio envolvente através de um processo de aprendizagem; 2) As intensidades das ligações entre neurónios, conhecidas como pesos sinápticos, são usadas para armazenar o conhecimento adquirido.”

Ao longo do tempo, a utilização de RNA é cada vez mais comum, vindo a ser desenvolvidas e aplicadas em várias áreas da ciência de forma a responder às necessidades impostas. O processamento de linguagem e imagem, o reconhecimento de padrões, a classificação de dados, a aproximação de funções, a otimização, a predição, o planeamento, a monitorização, o diagnóstico e o controlo são exemplos de campos onde podem ser aplicadas estas redes (Matos, 2008).

São vários os benefícios que se ganha com a utilização das RNA:

- Aprendizagem – uma RNA é treinada com um conjunto de dados que lhe é fornecido, e esta aprende a produzir resultados desejados para esse conjunto, através das intensidades das ligações entre os neurónios;
- Generalização – quando é adicionado um novo conjunto de dados, diferente dos exemplos conhecidos, a rede tem a capacidade de produzir resultados para esse conjunto, tendo em conta os exemplos usados anteriormente;

- Robustez – mesmo com a falha de alguns neurónios das redes, é possível estas ainda terem um bom desempenho e fornecer respostas adequadas por algum tempo;
- Paralelismo massivo potencial – no decurso do processamento da informação, os neurónios “disparam” simultaneamente.

### 3.3.1. Analogia com sistemas biológicos

O cérebro humano é o grande processador de informação em que todas as funções e movimentos do organismo estão a cargo dos cerca de 10 000 milhões de neurónios existentes no sistema nervoso. Todas as sensações, pensamentos e sentimentos são resultado de sinais que atravessam e são processadas pelos neurónios (Lingireddy e Brion, 2005). Cada um recebe impulsos de outros, através de um certo nº de dendrites.

Dependendo dos impulsos recebidos, um neurónio pode enviar um sinal para outros, através do seu único axónio que liga às dendrites de outros neurónios. Esta conexão é feita por sinapses que transmitem estímulos por todo o corpo através de diferentes concentrações de iões de sódio ( $\text{Na}^+$ ) e potássio ( $\text{K}^+$ ). A toda esta grande e complexa rede que permite processar e armazenar informações dá-se o nome de Rede Neuronal (Medeiros, 2006).

Cada constituinte de uma de uma célula neuronal, apresentada na figura 16, tem as suas funções nesta rede:

- Dendrites – recebem os estímulos transmitidos por outros neurónios
- Corpo celular do neurónio – constituinte cuja função é entender e combinar as informações de outras células neuronais
- Axónio – tem a finalidade de transmitir os estímulos para outras células.




Figura 16. Constituintes de um neurónio ou célula neuronal.

A comunicação entre os diferentes neurónios é feita de forma descontínua, através de impulsos, como já foi referido. Cada neurónio é envolvido por uma membrana que o isola dos restantes, daí a comunicação ser feita por via elétrica e por via química por intermédio de substâncias denominadas neurotransmissores. Assim sendo, o impulso é recebido, o neurónio processa e seguidamente dispara um segundo impulso que produz uma substância neurotransmissora que se desloca no corpo celular para o axónio. A comunicação entre neurónios (figura 17) é feita na região onde o sinal passa do axónio de um neurónio (pré-sináptico) para a dendrite de outro neurónio (pós-sináptico) sendo designada por sinapse, onde não existe qualquer ligação física (Matos, 2008). As redes neuronais naturais só emitem dois tipos de pulsos, positivos e contínuos, os pulsos negativos só são emitidos pelas redes neuronais artificiais (Matos, 2008).




Figura 17. Transmissão de um impulso nervoso através de uma sinapse química.

Em 1943, McCulloch e Pitts conceberam um modelo computacional muito semelhante ao funcionamento do cérebro humano, tratando-se de um modelo digital do neurónio biológico, e daí lançaram as fundações das RNA (Matos, 2008).

As RNA possuem muitas características semelhantes aos sistemas biológicos (Matos, 2008), pois são compostas por unidades conectadas, chamadas de nós ou neurónios, que vão receber vários valores de *input* e através de cálculos simples vão gerar um valor de *output* (Palisade, 2013). Por consequência, estes valores de *output* funcionam como valores de *input* para outro nó ou neurónio, ou podem ser a resposta final que se pretende com o uso das RNA.

Os neurónios presentes na RNA estão dispostos em camadas, conforme mostra a figura 18: a primeira, refere-se à camada de *inputs* ou de entrada, que recebe os dados necessários para o trabalho da rede, seguidamente surge a primeira camada oculta ou intermédia, que pode ser única, e por fim existe a camada de saída ou de *output* (Palisade, 2013). A camada escondida ou intermediária não tem qualquer ligação direta com o meio externo e faz a associação dos *inputs* e *outputs* do processo.




Figura 18. Modelo Estrutural de uma rede neuronal (Fonte: Ribeiro *et al.*, 2009).

A aprendizagem das redes ocorre de forma muito semelhante ao cérebro humano. Sendo este um órgão tão complexo, a sua aprendizagem é feita através da interligação de neurónios simples nas respetivas sinapses. Similarmente, as RNA aprendem através da interligação de nós simples, que representam os neurónios, sendo que as suas conexões representam as sinapses existentes nos neurónios biológicos. As funções simples, mas altamente interligadas, e os respetivos pesos das ligações permitem às RNA modelar diversos fenómenos complexos sem introduzir erros desnecessários (Lingireddy e Brion, 2005).

Apesar das comparações observadas e das semelhanças encontradas nem todos as RNA são tão “idênticas” às redes neuronais biológicas, existindo outros modelos. É importante salientar que a complexidade dos sistemas biológicos é muito maior do que no caso das RNA.

### 3.3.2. Evolução Histórica

Em 1943, pela mão de McColluch e Pitts, surge o primeiro modelo artificial de um neurónio biológico, sendo concebido como um modelo simplificado dos neurónios biológicos (Braga *et al.*, 2000). Mas só passado alguns anos, em 1949, é que as RNA começaram a ser mais estudadas. Donald Hebb lança um livro “A organização do comportamento” e mostra que



se um neurónio recebe uma entrada de outro neurónio e se ambos estão altamente ativos, a eficiência de uma sinapse variável entre eles é aumentada pela ativação repetida de um pelo outro através da sinapse (Lingireddy e Brion, 2005). Esta teoria é também conhecida por regra de Hebb.

Frank Rosenblatt cria, em 1958, um novo modelo, o Perceptrão, um filtro linear com capacidade de adaptação, tratando-se da forma mais simples de uma rede neuronal (Matos, 2008). Segundo o Teorema de convergência do Perceptrão, este modelo consegue encontrar sempre a solução desde que os dados correspondam a um conjunto linearmente separável.

Passados dois anos, Widrow e Hoff, desenvolveram um algoritmo de treino baseado no erro quadrático médio que implementaram na ADALINE (ADAPtative LINear ELEment) (Lingireddy e Brion, 2005; Braga *et al.*, 2000). Apesar de tudo parecer encaminhado, em 1969, Minsky e Papert mostraram que o perceptrão tem limites fundamentais, não sendo capaz de executar algumas operações e não dando nenhuma garantia que em perceptrões interligados em múltiplas camadas esses limites poderiam ser ultrapassados, pois não existiam algoritmos conhecidos para tal (Lingireddy e Brion, 2005). Assim, o estudo de RNA acabou por cair um pouco no abandono.

Na década de 80, renasce o estudo destas redes com Rumelhart, Hinton e Williams a publicarem o algoritmo de retro-propagação do erro que, aliado à utilização de redes neuronais de camadas múltiplas (perceptrões multicamada ou PMC), implementando funções de ativação não lineares, fizeram com que as limitações apresentadas por Minsky e Papert fossem ultrapassadas (Matos, 2008).

### **3.3.3. Princípios de funcionamento e descrição das RNA**

Uma rede neuronal trata-se de um sistema de elementos de processamento simples designados por nós ou neurónios que se ligam, armazenando informação de forma implícita na topologia e nos pesos das conexões ou ligações e têm capacidade de se ajustar (Matos, 2008). Portanto, os neurónios são a unidade base das RNA, estando interligados através de conexões ou canais de comunicação, permitindo a passagem de informação. Eles recebem informação de vários *inputs*, relacionando-os através do peso que estes têm no sistema, somando-os e por fim ditando um resultado que é o *output* da rede. Este valor é transmitido pela função de

transferência, que transforma o valor produzido através da soma ponderada dos *inputs* que a rede recebe (Matos, 2008; Silva, 2014). Na figura seguinte (figura 19) é apresentado o funcionamento de um nó genérico.




Figura 19. Modelo de um nó de uma RNA (Matos, 2008).

É possível observar as várias funções de transferência que intervêm no funcionamento de um neurónio, função de *input* ( $f_i$ ), de *ativação* ( $f_a$ ) e de *output* ( $f_o$ ). A primeira, corresponde ao somatório ou produto dos valores de *input* num único valor real; a segunda, faz a correspondência entre o resultado da função de *input* a um nível de ativação do nó, normalmente varia entre -1 e 1 ou 0 e 1; e a última função, que nem sempre é utilizada, destina-se a produzir um sinal a partir da ativação do nó.

Dos vários tipos de RNA existentes, a estrutura, o género de computações realizadas nos neurónios, e os algoritmos de treino utilizados, são os critérios que os diferem (Silva, 2014). São capazes de modelar funções de qualquer complexidade e o número de nós e camadas adequa-se à tal complexidade da função. As redes mais comuns são compostas por neurónios ordenados em camadas, que recebem *inputs* dos *outputs* de outros neurónios, de camadas anteriores, ou *inputs* externos.

Para determinar os valores dos pesos sinápticos é necessário um conjunto de dados que permitam entender a relação entre os valores de entrada e de saída da rede, sendo possível através de um processo de aprendizagem, o algoritmo de treino (Lingireddy e Brion, 2005).

Relativamente à arquitetura, existem dois modelos de redes neuronais artificiais mais usuais: o perceptrão e o perceptrão multicamada, sendo descritos seguidamente.

## Perceptrão

Este modelo de RNA trata-se do modelo mais simples e é utilizado para a classificação de padrões linearmente separáveis, ou seja, padrões que se encontrem em lados opostos de um hiperplano (Matos, 2008). Tal como se pode observar na figura 20, este modelo de RNA é constituído por um único nó com pesos sinápticos, ou ligações, e constantes ajustáveis. O esquema do nó utilizado por Rosenblatt foi proposto por McCulloch e Pitts (figura 20).




Figura 20. Representação esquemática de um perceptrão (Matos, 2008).

A computação do valor introduzido no nó de *output* é feita através do produto entre o valor de cada *input* ( $X_i$ ) e o peso da respetiva ligação ao nó de *input* ( $W_{i,1}^1$ ), resultando em  $y$ , que representa o número real que é transformado em  $X_i^1$ , derivado do somatório de todos os produtos (Matos, 2008).

Rosenblatt criou o Teorema de Convergência do Perceptrão, que diz que o algoritmo de treino converge e coloca a superfície de decisão na forma de um hiperplano entre duas classes, caso os padrões usados para treinar o perceptrão forem extraídos de duas classes linearmente separáveis. Assim, o perceptrão criado por Rosenblatt trata-se de um perceptrão de camada única que apenas consegue classificar padrões linearmente separáveis (Lingireddy e Brion, 2005).

## Perceptrão Multicamada (PMC)

Este modelo de RNA conhecido por *Feed-Forward Nets* ou *Perceptron Nets* ou Perceptrão Multicamada (PMC), caracteriza-se por possuir uma camada de *input*, uma camada de *output* e, pelo menos, uma camada intermédia ou oculta, em que cada nó está ligado a todos

os nós da camada seguinte (Lingireddy e Brion, 2005). Na figura 21, apresenta-se um exemplo de uma rede multicamada com uma camada intermédia.




Figura 21. Esquema das ligações e elementos presentes num PMC de uma camada oculta (Silva, 2014).

Segundo Lingireddy e Brion (2005), a fórmula matemática para determinar o valor de *output* numa rede PMC de três camadas é expressa pela seguinte equação (equação 1):

$$O_{Pk} = f_1\left(\sum_{j=1}^J w_{jk}^o \cdot f_2\left(\sum_{i=1}^I w_{ij}^h \cdot x_{pi} + b_j^1\right) + b_k^2\right) \quad [\text{equação 1}]$$

Em que  $O_{Pk}$  representa o valor de saída do  $k^{\circ}$  nó da camada de saída para o vetor  $p$ ;  $x_{pi}$  é o valor de entrada no  $i^{\circ}$  nó da camada de entrada do vetor  $p$ ;  $w_{jk}^o$  é o peso da conexão entre o nó  $j$  da camada oculta e o nó  $k$  da camada de saída;  $w_{ij}^h$  é o peso da conexão entre o nó  $i$  da camada de entrada e o nó  $j$  da camada oculta;  $b_j^1$  e  $b_k^2$  são termos constantes;  $f_1$  e  $f_2$  representam funções de ativação;  $I$  é o número de nós de entrada;  $J$ , o número de nós ocultos e  $K$ , os números de nós de saída.

É importante que a função de ativação para a camada oculta seja capaz de captar relações não lineares entre os valores de entrada e saída. Silva (2014), cita uma função de ativação de Jordan (1995) como sendo a função de ativação mais comum, a função logística sigmoidal (equação 2), que gera resultados compreendidos entre 0 e 1.

$$f(x) = \frac{1}{1 + e^{-x}} \quad [\text{equação 2}]$$

Estas redes neuronais são, por norma, treinadas através de um algoritmo de retro-propagação do erro (Matos, 2008).

Relativamente aos problemas que as RNA podem resolver, a Palisade (2013) apresenta dois tipos: problemas de classificação e problemas numéricos. Nos primeiros, tenta-se determinar a que tipo de categoria pertence um item desconhecido, como exemplo tem-se os diagnósticos médicos ou a previsão da capacidade de pagamento de créditos bancários. No segundo, procura-se responder à previsão de um resultado numérico específico, tendo como exemplo a previsão de preços de ações ou a previsão do nível de vendas num período futuro. Neste tipo de problema, deve optar-se por redes de *output* único, pois são mais fiáveis e adaptam-se a todos os problemas numéricos. Por exemplo, quando existem várias variáveis de *output* a prever, é recomendável fazer quantas redes de *output* único forem necessárias, para que cada uma delas faça a previsão para uma variável.

Uma RNA é muito mais complexa do que apenas encontrar relações entre a valores de entrada e saída. A modelação de RNA tem como função identificar essas relações implícitas entre os valores de entrada e de saída, mas com um fim. Para tal é necessário que os valores de entrada contenham informação que se adapte ao propósito da rede, para que através dos exemplos que lhe são fornecidos, ela aprenda e responda explicitamente com resultados para dados que até então não eram conhecidos, um novo conjunto de dados (Lingireddy e Brion, 2005).

#### **3.3.4. Tipos de Redes Neurais Artificiais**

As redes neuronais podem ser classificadas segundo a sua arquitetura, se se tratam de redes planares ou de camadas, o seu processo de aprendizagem, se o treino é feito com ou sem supervisão, ou a sua dinâmica, se existe transferência de informação sequencial ou simultânea.

Neste estudo será utilizado o NeuralTools™ da Palisade™, como tal é importante referir quais as redes neuronais que dispõe e quais aquelas que se adaptam ao trabalho. Esta ferramenta utiliza redes neuronais Multicamada *Feed-Foward* (MLF) ou Perceptrão Multicamada (MLP), redes de Regressão Generalizada (GRNN) e redes Probabilísticas (PNN). As redes MLF são utilizadas quer para previsões numéricas quer para previsões categóricas, já as outras duas dividem-se, as GRNN servem para fazer previsão numérica e as PNN para previsões categóricas.

Como neste estudo se pretende apenas uma previsão numérica, foram utilizadas redes MLF e GRNN.

### **Redes MLF e PNN/GRNN**

As RNA são bastante diversificadas e são diferenciadas pela sua estrutura, pelos cálculos efetuados nos nós ou neurónios da rede e pelos algoritmos de treino (Palisade, 2013).

As redes MLF são redes multicamadas, redes que possuem várias camadas de nós ou neurónios, sendo compostas, no mínimo, por três destas: camada de *input*, uma ou mais camadas ocultas ou intermédias e a camada de *output*. A primeira é aquela que dá conhecimento da informação de entrada, sendo que o número de nós nesta camada corresponde ao número de variáveis usadas e eles assumem o valor dos dados de entrada que será distribuído pelas seguintes camadas, as intermédias. Por fim, a camada de *output* ou de saída é aquela que apresenta a solução do problema. A comunicação feita entre os neurónios é unidirecional e apenas se ligam aos neurónios da camada seguinte, não havendo ligações entre neurónios da mesma camada.

O comportamento de uma rede MLF é determinado pela sua topologia, pelos pesos das conexões/ligações e termos constantes e pela função de ativação. O primeiro fator refere-se ao número de camadas ocultas e ao número de nós das camadas; o segundo, diz respeito aos parâmetros atribuídos às várias ligações entre os neurónios bem como o que é atribuído a cada nó; o terceiro fator refere-se à função que é utilizada para converter os *inputs* de cada nó no *output* correspondente (Palisade, 2013). O treino de uma rede MLF consiste, então, em encontrar um conjunto de pesos de conexões e de termos constantes que façam com que a rede forneça respostas corretas quando novos casos são apresentados.

Relativamente ao outro tipo de redes que o NeuralTools dispõe, as redes PN/GRNN, são redes muito semelhantes, variando no tipo de problemas que podem ser aplicáveis. Se o problema é de categoria, ou seja, se a rede possui uma variável de *output* categórica, a rede PN é a indicada a usar, mas caso se trate de uma variável numérica, as redes GRNN são as que se devem usar. Sendo o caso de estudo um problema numérico, destas duas redes será utilizada a rede GRNN.

A rede GRNN apresenta sempre quatro camadas: uma camada de *input*, duas camadas ocultas ou intermédias e uma camada de *output*. Na camada de *input*, tal como nas redes MLF,

cada nó representa uma variável de entrada. As duas camadas ocultas estão divididas em camada padrão e camada de soma. Na primeira, existe um nó para cada caso de treino, em que é calculada a distância do nó em relação ao caso apresentado. A função de distância é calculada através dos valores de fatores de suavização de cada nó de *input*, em que quanto maior o valor do fator, mais importante é esse caso de treino para a quando da previsão. A segunda, é constituída por nós de denominadores e numeradores, que recebem como *inputs* os valores relativos às funções de distância e do valor dependente e efetuam a sua soma. A última camada da rede, a camada de *output*, gera a previsão (Palisade, 2013).

### 3.3.5. Fases de desenvolvimento de uma RNA

Para trabalhar com uma RNA são necessárias estágios até ela estar apta a ser usada, sendo a preparação de dados, o treino, o teste e a previsão da rede as quatro fases que a constituem o seu desenvolvimento (Palisade, 2013). De seguida, prossegue-se à sua descrição e explicação.

#### 1º Estágio - Preparação dos dados

O grande objetivo desta fase é a preparação dos dados de *input*, definir qual o conjunto de dados a utilizar, optando por quais as variáveis de entrada que realmente interessam no processo e identificar quais as variáveis de saída, por outras palavras, aquelas com as quais se pretende fazer a previsão (Lingireddy e Brion, 2005). Uma boa compreensão do processo a modelar é o primeiro passo para que a preparação dos dados seja positiva para a implementação da RNA. Estes dois passos são fundamentais para evitar erros ou a utilização de dados menos fiáveis, que poderão resultar como um mau treino da rede.

Segundo Lingireddy e Brion (2005), esta é a etapa mais longa, devido à recolha extensa de dados e às decisões a tomar sobre as variáveis a escolher ou dados a rejeitar, tendo um grande peso na continuação do processo.

Existem dois fatores que são muito importantes no que diz respeito à base de dados, a quantidade e a qualidade. O primeiro fator, facilita a compreensão por parte da rede das relações existentes entre dados, pelo que um maior número de casos é favorável para o trabalho com as RNA, não só melhora o desempenho da rede como a capacidade de generalização

umenta. Relativamente ao segundo fator, é importante que se assegure qualidade nos dados para que os resultados obtidos sejam creíveis, aumentando a fiabilidade dos dados escolhidos.

Quando a base de dados está definida, esta vai dividir-se em três conjuntos: conjunto de treino, conjunto de teste e conjunto de validação. O conjunto de treino é aquele que alberga a maior quantidade de casos, casos esses que são conhecidos e que serão utilizados no processo de aprendizagem da rede. O conjunto de teste é utilizado para avaliar a capacidade de generalização da rede, isto é, o valor que se pretende prever é conhecido e será comparado com aquele que é obtido. E por último, mas não sendo de carácter “obrigatório”, existe o conjunto de validação, que serve para confirmar resultados considerados aceitáveis na fase de teste, certificando a capacidade de generalização da rede.

## 2º Estágio: Treino da RNA

Como já foi referido, nesta etapa todos os valores do conjunto de dados escolhidos para o treino são conhecidos e pretende-se que através dos dados de entrada, sejam obtidos resultados de *output* o mais próximo possível dos valores reais. É nesta fase que é feito o processo de aprendizagem de forma a ajustar os parâmetros de computação da rede (Palisade, 2013).

O processo é orientado pelos dados utilizados para o treino e pelo algoritmo de treino (Silva, 2014). O algoritmo de treino seleciona vários conjuntos de parâmetros e avalia-os aplicando a RNA a cada caso de treino, fazendo uma comparação com os valores de output reais conhecidos através das resposta que a rede fornece. Este algoritmo tem a capacidade de escolher novos conjuntos de parâmetros tendo em conta os resultados que foram obtidos nas tentativas anteriores.

Cada conjunto de parâmetros designa-se por *trial*, ou tentativa, e um caso de treino corresponde a uma linha de informação do conjunto de dados (Silva, 2014).

O treino de uma rede MLF consiste em encontrar um conjunto de pesos de conexão e de termos constantes que façam com que a rede forneça respostas corretas face a novos casos. Inicialmente o treino começa com a atribuição aleatória de um conjunto de conexões, o que pode diferir do valor real, existindo um valor de erro para cada caso. Assim, continua-se a fase de treino, em que as atribuições dos pesos das conexões deixam de ser aleatórias, sendo decididas pelo algoritmo de treino, baseando-se nas tentativas já feitas. O objetivo é minimizar esse valor de erro através dessas mudanças para que a diferença média quadrática entre a



resposta correta e a resposta dada pela rede seja mínima – minimização do erro médio quadrático (Palisade, 2014). Já o treino de uma rede GRNN consiste em otimizar os fatores de suavização para minimizar o erro do conjunto de treino.

### 3º Estágio: Teste da RNA

É nesta fase do processo que se verifica o desempenho da rede treinada. Por outras palavras, verifica-se a capacidade de prever valores de *output* conhecidos mas que não faziam parte do conjunto de treino (Palisade, 2013). É um processo mais rápido do que o treino da RNA e informa a qualidade da previsão de respostas conhecidas nos dados de teste, ajudando assim a saber se a rede fará boas previsões na fase seguinte. Para tal, a RNA é avaliada estatisticamente, oferecendo informação acerca das respostas que foram previstas incorretamente (percentagem) e calcula também o seu erro médio quadrático. Assim, a rede que tiver menor erro médio quadrático na fase de teste, bem como uma menor percentagem de previsões erradas, é considerada uma melhor rede para a previsão de valores de *output* novos, pois oferece maiores garantias de sucesso (Silva, 2014).

### 4º Estágio: Previsão

O objetivo principal da utilização de redes neuronais artificiais é fazer previsões (Palisade, 2013). Aqui é utilizada a rede que já foi treinada e testada para que agora possa ser utilizada com valores de *output* desconhecidos.

O processo de treino e teste é interativo e longo, comparativamente à previsão. O treino pode ser feito várias vezes, com configurações de rede diferentes, até ser apresentada uma rede que na fase de teste mostre melhores resultados. Para tal as redes têm de adquirir capacidade de generalização necessária para que seja assim possível escolher a melhor e efetuar previsões com um certo grau de confiança.

### **3.3.6 Comparação entre RNA e Métodos Estatísticos**

As RNA são uma alternativa aos métodos estatísticos e são usadas para aproximação de funções, tal como as regressões lineares, e para classificação, tal como as análises discriminantes e as regressões logísticas (Palisade, 2013).

As RNA começaram a surgir em meados do século XX, sendo que as técnicas de otimização de modelos lineares eram já bem conhecidas, mas a sua capacidade de modelar funções extremamente complexas era mínima. Para tal, começaram a desenvolver-se uma grande variedade de algoritmos sofisticados de treino de redes neuronais que fossem capazes de resolver aquilo que os métodos convencionais não eram capazes. Desta forma, as redes neuronais artificiais apresentam vantagem perante os métodos estatísticos.

Segundo Linigireddy e Brion (2005), as RNA apresentam uma vantagem singular dada a simplicidade com que certas alterações feitas na configuração da rede ajudam na compreensão das relações complexas existentes: a alteração de número de nós ou neurónios da camada escondida pode melhorar essa perceção.



## **4. APRESENTAÇÃO DO CASO DE ESTUDO**

### **4.1. Enquadramento do estudo**

Ao longo dos anos, as preocupações com o ambiente têm aumentado com vista a preservar aquilo que a natureza tem para nos oferecer. Neste contexto, as empresas preocupam-se cada vez mais em preservar os recursos naturais e tentam arranjar soluções aliadas à situação económica atual, de forma a garantir um desenvolvimento sustentável. Pretendem, portanto, otimizar os processos de tratamento e reduzir os custos de exploração.

A digestão anaeróbia e a consequente produção de biogás são vistas, muitas vezes, como processos complexos e até instáveis, o que torna difícil a sua otimização. Ao longo dos anos têm sido feitos estudos para tentar entender melhor o seu funcionamento de forma a encontrar a estabilidade dos digestores anaeróbios. O controlo destes processos tem como base somente os conceitos teóricos e a experiência acumulada, o que por vezes não é suficiente para entender o processo, pois certas alterações não têm resposta imediata.

A Águas do Noroeste, sendo uma empresa que procura a sustentabilidade económica, social e ambiental, tem demonstrado bastante preocupação em otimizar os seus processos de funcionamento, nomeadamente, o processo de Digestão Anaeróbia da ETAR do Ave. O recurso a RNA permite fazer o estudo do processo da digestão anaeróbia através da análise e tratamento dos seus dados com a finalidade de permitir uma melhor gestão desse mesmo processo. O objetivo do estudo passa por relacionar as variáveis do processo com a produção de biogás, de forma a otimizá-lo e ajudar na tomada de decisões no processo de produção. Espera-se assim, que estas ferramentas matemáticas sejam capazes de contribuir para a compreensão do processo, assumindo-se como um sistema de apoio da gestão da digestão anaeróbia.

Um estudo semelhante sobre a aplicação de redes neuronais artificiais para a gestão do processo de digestão anaeróbia, foi já realizado em 2013 por um colega na SIMRIA (Saneamento Integrado dos Municípios da Ria) e, dado a informação que se dispôs relativamente à gestão de biogás, o grupo Águas de Portugal optou por alargar este estudo a outras empresas para que todas possam beneficiar com ele.

## **4.2. Metodologia Proposta**

Para o desenvolvimento deste trabalho utilizaram-se os programas Microsoft Excel™ e NeuralTools™, do The Decision Tools Suite™, da Palisade™.

### **4.2.1 Apresentação do NeuralTools**

Na parte inicial do estágio foi realizado um *workshop*, na Águas de Portugal, com participação de vários técnicos pertencentes ao grupo, para introdução de conceitos acerca de redes neuronais e do *software* a utilizar, o NeuralTools.

O NeuralTools trata-se de uma ferramenta informática que é usada no Microsoft Excel, com vista a efetuar previsões através de recursos avançados de redes neuronais. Possui um gerenciador de dados avançado e algoritmos bem desenvolvidos deste tipo redes, sendo fácil de usar e bastante flexível, pois funciona exatamente como o Excel (Palisade, 2013). O facto de se trabalhar no Excel, permite a utilização dos dados lá contidos, inseridos manualmente ou utilizando as várias funcionalidades do próprio programa, e assim executar os procedimentos do NeuralTools – definição do conjunto de dados, treino e teste de redes neuronais e a previsão de valores usando as redes treinadas.

Este *software* pode resolver dois tipos de problemas, quer de classificação, quer numéricos e tal permite a utilização quer de variáveis categóricas ou variáveis numéricas, podendo estas ser dependentes ou independentes, criando relações lineares ou não-lineares.

De forma a poder passar pelas diversas fases das RNA, a base de dados utilizada deve ser suficientemente grande, possibilitando a utilização de diferentes dados para as fases de treino, teste e previsão. O desenvolvimento destas etapas no NeuralTools e os comandos associados serão descritos seguidamente.

### **4.2.2 Preparação de dados**

A preparação dos dados para criar e trabalhar na rede neuronal é um passo muito importante para a continuação do trabalho.

O *software* NeuralTools trabalha sobre as folhas de cálculo do Excel, em que as colunas representam as variáveis intervenientes e as linhas correspondem, uma a uma, a casos com diferentes valores para as variáveis escolhidas. Cada caso possui um conjunto de valores de variáveis independentes, **inputs**, e um valor para a variável dependente, **output**, este último podendo ser conhecido ou não. Na figura 22 é apresentada um exemplo de uma base de dados para ser utilizada no NeuralTools.

	A	B	C	D	E	F	G	H	I
1									
2									
3									
4									
5									
6									
7									
8									
9									
10									
11									
12									
13									

Figura 22. Exemplo de uma base de dados para utilizar com o NeuralTools.

O comando “Gerenciador de conjuntos de dados”, que aparece no canto superior direito, permite definir qual o conjunto de dados a utilizar. Para tal, é necessário seleccionar o campo de dados que pretendemos, clicar no comando “Gerenciador de conjunto de dados” e aparece a caixa de diálogo apresentada na figura abaixo (figura 23), que além de permitir definir o conjunto de dados também permite editar e excluir as variáveis que se pretende utilizar nas várias fases das redes neuronais artificiais.




Figura 23. Caixa de diálogo do gestor do conjunto de dados.

A caixa de diálogo apresenta várias opções, sendo elas:

- Novo e Excluir – adiciona um novo conjunto de dados ou exclui um conjunto já existente;
- Nome – permite especificar um nome para o conjunto de dados criado;
- Intervalo do Excel – especifica o intervalo do Excel correspondente ao conjunto de dados. Se forem selecionados vários intervalos de células no conjunto de dados, este item será antecedido pelo rótulo Múltiplos;
- Múltiplos – permite especificar intervalos de células individuais que formam o conjunto de dados, com múltiplos intervalos de células;
- Aplicar formatação de células – acrescenta uma grade e cores que identificam os conjuntos de dados;
- Importar – permite copiar, neste conjunto de dados, os tipos de variáveis de um outro conjunto de dados ou de uma rede neuronal.

Na secção de “Variáveis” da caixa de diálogo do gestor de conjunto de dados, figura 24, são apresentadas as variáveis disponíveis na base de dados para serem escolhidas como variáveis de entrada do conjunto de dados, havendo informação acerca do intervalo de dados do Excel a que corresponde essa variável, o nome e o tipo de variável.




Figura 24. Definição do tipo de variável.

Pode optar-se por seis tipos de variáveis, sendo elas:

- Categórica dependente - é uma variável dependente ou de *output* cujos valores possíveis são tomados de um conjunto de possíveis categorias;
- Categórica independente - é uma variável independente ou de *input* 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 ou de *input* cujos valores possíveis são numéricos;
- Tag - é uma variável que assume possíveis valores de “treino”, “teste” ou “previsão”. Esse tipo de variável é escolhido pelo utilizador para identificar casos a serem usados especificamente para treino, teste e previsão;
- Não usada - é uma variável da base de dados criada que não será usada na rede neuronal.

Após definir o conjunto de dados a utilizar e organizar as variáveis, a folha de cálculo do Excel fica formatada segundo a figura 25, apresentada em seguida.



	A	B	C	D	E	F	G	H	I
1									
2		<b>Dia</b>	<b>SV g/L (TLMistas)</b>	<b>Q entrada m3/dia (dig 1 + Dig 2)</b>	<b>pH (média)</b>	<b>Temperatura °C (média)</b>	<b>AGV Global mgCaCO3/L</b>	<b>Alcalinidade Global mgCaCO3/L</b>	<b>Biogás Total média m3/dia</b>
3		3-Jan-12	15,82	86	7,16	37,00	1107	1820	624,4
4		18-Jan-12	17,30	187	7,16	37,00	253	1425	1186,7
5		24-Jan-12	20,07	185	7,47	38,00	1867	2175	1171,7
6		31-Jan-12	15,90	148	7,02	34,00	258	1034	738,3
7		7-Fev-12	19,67	71	7,30	38,00	170	2163	807,3
8		22-Fev-12	14,02	172	7,18	34,00	198	1671	438,6
9		28-Fev-12	13,20	128	6,80	32,00	228	1017	244,7
10		6-Mar-12	16,60	36	6,94	34,00	348	2770	621,7
11		14-Mar-12	21,30	68	6,77	35,00	1619	2142	929,4
12		27-Mar-12	22,84	28	6,79	38,00	978	3488	813,9
13		3-Abr-12	27,10	30	7,20	36,00	1093	3355	538,6

Figura 25. Conjunto de dados definido para ser utilizado.

Com o conjunto de dados criado e bem definido, pode-se passar para as seguintes fases do processo da rede neuronal, treino e teste e previsão.

Sabe-se que o NeuralTools tem capacidade para processar até 256 conjuntos de dados contidos na mesma pasta de trabalho, bem como 16 384 variáveis para cada conjunto de dados. Relativamente ao número de casos de dados por variável e de casos por conjunto de dados, o limite é dado pela memória disponível no Excel, cerca de 16 277 216 casos, (Palisade, 2013).

#### 4.2.3. Treino e Teste da Rede Neuronal

Depois de definir qual o conjunto de dados a trabalhar na rede neuronal pode-se avançar para a etapa seguinte, treino e teste da rede. Na fase de treino, os valores de *output* são conhecidos, sendo assim treinada a rede neuronal. Já na fase de teste há a previsão de valores *output* através da rede neuronal treinada, medindo assim o seu desempenho. De salientar que neste caso os valores de *output* já são conhecidos. O NeuralTools permite que estas fases sejam feitas em simultâneo, ou seja, do conjunto de dados criado, parte é utilizada para o treino da rede neuronal e parte para o teste, sendo essa percentagem definida pelo utilizador. Além disso, este grupo permite também configurar o algoritmo de treino a usar bem como os critérios de tempo de execução desse mesmo algoritmo.

No separador NeuralTools do Excel existe o comando “treinar”, que quando selecionado, surge uma caixa de diálogo na qual se podem definir todas as condições para que ocorra o treino da rede, incluindo as configurações e o tempo de execução da mesma, figura 26.




Figura 26. Caixa de diálogo Treinar.

No separador “treinar” da caixa de diálogo, define-se qual o conjunto de dados que será utilizado no treino, bem como o local onde a rede será guardada no Excel. É aqui que também existe a opção de efetuar o teste seguido do treino, tornando as duas fases numa só, através da opção “Testar automaticamente em casos aleatoriamente selecionados”, em que é definida uma percentagem de casos que são “excluídos” do treino, para poderem ser utilizados apenas no teste da rede neuronal. Outra das opções também presentes é “Prever automaticamente valores dependentes ausentes”, em que esses dados são também usados para a fase da previsão. Quando é ativada esta opção, dispõe-se de mais duas escolhas, a “Previsão Instantânea”, em que é permitido alterar o valor das variáveis independentes o que altera instantaneamente o valor da previsão, e a “Colocação de valores previstos diretamente no conjunto de dados”. Ainda nesta caixa de diálogo, é possível escolher a opção “Calcular o impacto das variáveis” em que o NeuralTools calcula o impacto que cada variável independente ou de *input* teve no processo de treino, por outras palavras, mede a sensibilidade das previsões da rede a mudanças nas variáveis referidas.

### 4.2.3.1. Configuração da rede

No separador seguinte da caixa de diálogo do treino da rede, temos as condições relacionadas com a configuração da rede (figura 27). Aqui é escolhido o tipo de rede neuronal a ser utilizado, dispondo, além da escolha específica de uma rede, também da opção da procura da melhor rede.

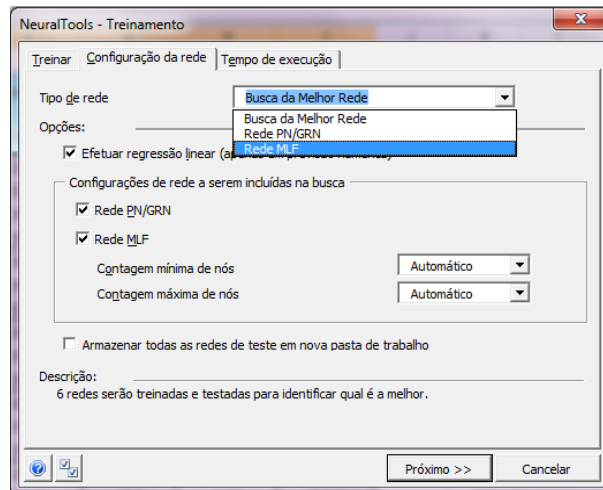


Figura 27. Caixa de diálogo Configuração da rede.

Aquando da escolha do tipo de rede a usar, tem de se ter em conta o tipo de problema em questão, numérico ou de classificação/categoria. Posto isto, existem dois tipos de rede disponíveis para a previsão de problemas de classificação: Redes Neurais Probabilísticas (PNN) e Redes *Multi-layer Feedforward* (MLF). Já quando se trata de um problema numérico, as redes disponíveis são as redes MLF e as Redes Neurais de Regressão Generalizada (GRNN), que são bastante semelhantes às redes PNN.

Como já foi referido anteriormente, existe ainda uma outra opção, “Busca da melhor rede”, em que são treinadas e testadas diversas redes neuronais dos tipos já descritos mas com várias configurações. Tal é possível devido à opção de estabelecer um número mínimo e máximo de nós nas redes MLF. É escolhida aquela que mostrar melhores resultados com base nos resultados do teste.

#### 4.2.3.2. Tempo de execução

Relativamente às condições de duração de treino da rede neuronal (figura 28) existem três critérios de paragem: duração, número de tentativas e andamento. A “Duração” especifica o tempo de limite que se pretende para o treino. É de notar que quando se opta por procurar a melhor rede, cada configuração de rede treinada durará o tempo que é aqui especificado. A opção “Tentativas” especifica o número de tentativas que o NeuralTools deve executar para cada rede. Por último o “Andamento” que trata-se da função da % mínima de mudança de erro em função do tempo, em que o NeuralTools parará se não puder melhorar a estatística de erros pelo menos na percentagem especificada dentro do intervalo de tempo definido.




Figura 28. Caixa de diálogo Tempo de Execução.

Não é possível saber ao certo qual o tempo necessário para treinar uma rede neuronal, por isso inicialmente é preferível aceitar as condições padrão.

Após definidas todas as condições do algoritmo de treino, passa-se para a última fase anterior ao treino. Na caixa de diálogo abaixo apresentada (figura 29) podemos observar a visão geral do treino, apresenta-se um resumo com a informação acerca das configurações de treino e do conjunto de dados, bem como as variáveis intervenientes.




Figura 29. Caixa de diálogo Visão Geral de Treino.

É importante verificar se existe alguma anomalia com os dados ou com alguma das opções escolhidas na configuração, pois o treino é o processo mais demorado na criação da rede neuronal. Quando tal acontece, o NeuralTools deteta e é transmitido na caixa de diálogo na secção “Erros e avisos”, para que assim seja possível corrigir o erro antes de dar início ao treino.

#### 4.2.3.3. Processo de Treino

Após iniciar o treino, é possível observá-lo em tempo real, isto é, na caixa de diálogo do andamento do treino (figura 30) surgem gráficos em que é possível observar os erros à medida que decorre o treino de cada configuração. É de notar que as mudanças nos erros observadas nos gráficos nada permite concluir acerca da qualidade das previsões que a rede fará com relação aos casos que não foram usados no treino. O treino é interrompido quando se atinge algum dos critérios de paragem definidos.




Figura 30. Caixa de diálogo “Andamento do Treino”.

#### 4.2.3.4. Relatório de Treino

No final do treino da rede são criados automaticamente relatórios detalhados (figuras 31 e 32) que permitem analisar a rede em termos de desempenho; fornecem informação acerca da rede em termos de configuração, treino e teste. Relativamente ao treino e teste, obtém-se conhecimento acerca do número de casos em causa, percentagem de previsões inadequadas, erro médio quadrático e absoluto e desvio padrão do erro absoluto. É também possível calcular o impacto das variáveis, desde que se tenha ativado essa função na caixa de diálogo do treino.

Seguidamente, será apresentado um exemplo de um relatório de Treino e Teste automático de uma rede neuronal, com a devida explicação dos principais parâmetros estatísticos.

**NeuralTools: Treinamento e Teste Automático de rede neural**

Executado por: Catarina

Data: segunda-feira, 13 de Outubro de 2014 13:09:22

Conjunto de dados: Conjunto de dados núm. 1

Rede: Rede treinada em Conjunto de dados núm. 1

Resumo	
<i>Informações da rede</i>	
Nome	Rede treinada em Conjunto de dados núm. 1
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	6 (SV g/L (TLMistas), Q entrada m <sup>3</sup> /dia (dig 1 + Dig 2), pH (média), Temperatura °C (média), AGV Global mgCaCO <sub>3</sub> /L, Alcalinidade Global mgCaCO <sub>3</sub> /L)
Variável dependente	Var. numérica (Biogás Total media m <sup>3</sup> /dia)
<i>Treinamento</i>	
Número de casos	87
Tempo de treinamento	00:00:00
Número de tentativas	116
Motivo da parada	Parada automática
% previsões inadequadas (30% tolerância)	2,2989%
Erro médio quadrático	103,35
Erro médio absoluto	62,49
Desvio padrão de erro absoluto	82,32
<i>Teste</i>	
Número de casos	22
% previsões inadequadas (30% tolerância)	50,0000%
Erro médio quadrático	453,11
Erro médio absoluto	370,75
Desvio padrão de erro absoluto	260,49
<i>Conjunto de dados</i>	
Nome	Conjunto de dados núm. 1
Número de linhas	109
Tags de casos manuais	NÃO
<i>Análise de impacto de variáveis</i>	
Q entrada m <sup>3</sup> /dia (dig 1 + Dig 2)	31,6452%
AGV Global mgCaCO <sub>3</sub> /L	19,8631%
Temperatura °C (média)	18,7642%
SV g/L (TLMistas)	18,5047%
pH (média)	9,9419%
Alcalinidade Global mgCaCO <sub>3</sub> /L	1,2809%

Busca da Melhor Rede			
	Erro de RMS	Tempo de treinamento	Motivo da parada do treinamento
Previsor linear	518,70	00:00:00	Parada automática
GRNN	453,11	00:00:00	Parada automática
MLFN 2 nós	639,61	00:00:32	Parada automática
MLFN 3 nós	963,07	00:00:41	Parada automática
MLFN 4 nós	628,54	00:00:50	Parada automática
MLFN 5 nós	888,28	00:01:01	Parada automática
MLFN 6 nós	472,49	00:01:07	Parada automática

Previsor linear comparado a rede neural		
	Previsor linear	Rede neural
R-quadrada (Treinamento)	0,6098	-
Erro médio quadrático (Treinamento)	498,70	103,35
Erro médio quadrático (Teste)	518,70	453,11

Figura 31. Tabelas geradas no relatório de treino e teste automático do NeuralTools.

- % 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 – exibe o impacto relativo das variáveis independentes ou de *input* nas respostas previstas.

No relatório gerado automaticamente após o treino, são também disponibilizados gráficos e histogramas, figuras 32 e 33. Esses gráficos de dispersão mostram as relações existentes entre os valores efetivos, previstos e residuais. Um valor residual é diferença entre o valor efetivo e o valor previsto.

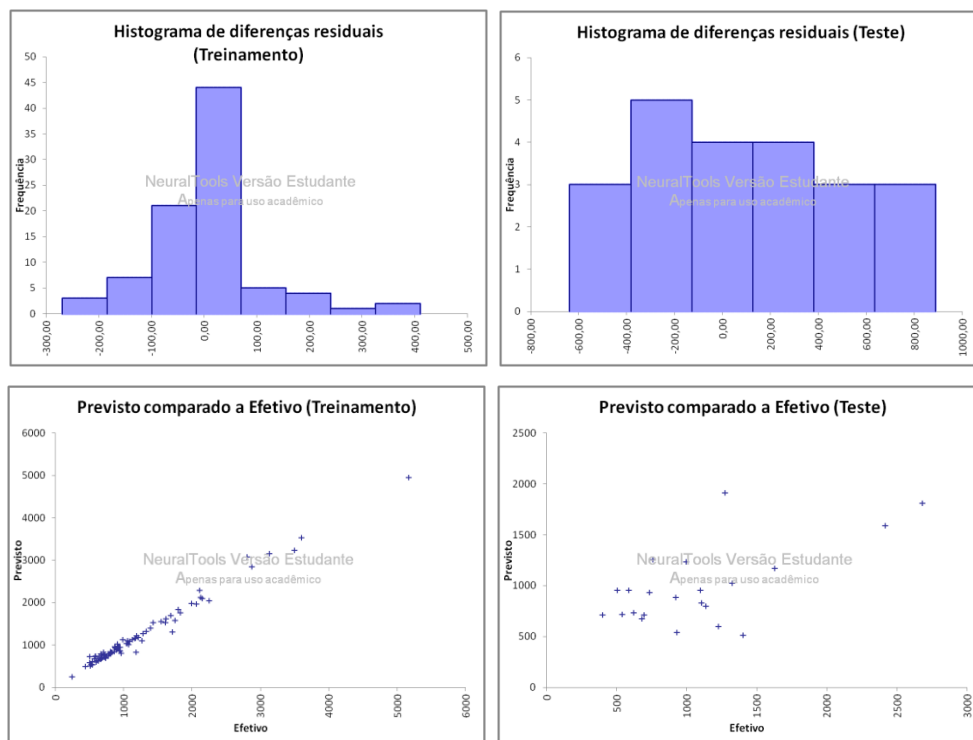


Figura 32. Exemplos de gráficos gerados no relatório de treino e teste automático do NeuralTools – parte 1.






Figura 33. Exemplos de gráficos gerados no relatório de treino e teste automático do NeuralTools – parte 2.

Um outro relatório surge ainda junto ao conjunto de dados e indica como se comportou a rede treinada na previsão de valores da variável dependente. De forma a entender, então, o seu desempenho, as previsões são marcadas como “Adequada” ou “Inadequada”, tal como mostra a figura 34.

Dia	SV g/l (TLMistas)	Q entrada m3/dia (dig 1 + Dig 2)	pH (média)	Temperatura °C (média)	AGV Global mgCaCO3/L	Alcalinidade Global mgCaCO3/L	Biogás Total média m3/dia	Tag usada	Previsão	Adequada/Inadequada	Residual
3-Jan-12	15,82	86	7,16	37,00	1107	1820	624,4	treinar			
18-Jan-12	17,30	187	7,16	37,00	253	1425	1186,7	treinar			
24-Jan-12	20,07	185	7,47	38,00	1867	2175	1171,7	treinar			
31-Jan-12	15,90	148	7,02	34,00	258	1054	738,3	treinar			
7-Feb-12	19,67	71	7,30	38,00	170	2163	807,3	treinar			
22-Feb-12	14,02	172	7,18	34,00	198	1671	438,6	treinar			
28-Feb-12	13,20	128	6,80	32,00	228	1017	244,7	treinar			
6-Mar-12	16,60	36	6,94	34,00	348	2770	621,7	testar	734,8	Adequada	-113,1
14-Mar-12	21,30	68	6,77	35,00	1619	2142	929,4	testar	538,6	Inadequada	390,9
27-Mar-12	22,84	28	6,79	38,00	978	3488	813,9	treinar			
3-Abr-12	27,10	30	7,20	36,00	1093	3355	536,6	treinar			
20-Abr-12	21,80	65	7,68	37,00	667	4154	949,3	treinar			
26-Abr-12	23,90	96	7,40	32,00	547	4047	731,6	treinar			
4-Mai-12	24,90	73	7,63	37,00	693	3781	570,3	treinar			
9-Mai-12	26,70	103	7,82	38,00	787	3728	719,0	treinar			
16-Mai-12	28,40	166	7,36	38,00	400	3728	803,7	treinar			
24-Mai-12	20,60	81	7,27	38,00	400	3594	1183,4	treinar			
29-Mai-12	16,70	156	7,51	37,00	387	3621	1096,7	testar	956,8	Adequada	139,9
5-Jun-12	14,10	124	7,38	37,00	427	3754	774,6	treinar			
14-Jun-12	28,20	153	7,38	36,00	507	3728	1322,7	testar	1027,0	Adequada	295,7

Figura 34. Relatório detalhado de treino e teste da RNA do NeuralTools.

#### 4.2.4. Previsão

Após o treino e teste de uma rede neuronal, esta está pronta para a sua grande finalidade, prever valores de *output* desconhecidos em novos casos. Existem dois métodos disponíveis pelo *software* para a previsão:

- 1) Método de previsão de valores desconhecidos da variável de *output* de um conjunto de dados, para tal basta utilizar o comando Prever existente no separador do NeuralTools;
- 2) Previsão Instantânea, em que os valores das variáveis de *input* de determinados casos podem ser alterados e a partir daí são previstos valores de *output* com as novas condições. Quando esta opção da previsão é ativada, surge automaticamente uma fórmula de Excel na célula que contém o valor previsto, para que se houver alteração direta nas células dos valores das variáveis independentes ou de *input*, o valor da variável dependente ou de *output* seja modificado automaticamente. Isto fará com que haja um recalculo com os novos valores impostos.

Tal como na etapa de treino e teste da rede neuronal, na previsão também aparece uma caixa de diálogo que permite especificar como se pretende que ocorra a previsão (figura 35).




Figura 35. Caixa de diálogo Previsão.

O conjunto de dados a utilizar pode ser escolhido, podendo existir vários conjuntos de dados na mesma folha de cálculo do Excel para proceder à previsão.

Sabe-se que só é possível prever valores para os casos em que os valores de *output* estão em falta, contudo, a “Previsão Instantânea” pode ser ativada e assim consegue ver-se como as mudanças nos dados podem afetar as previsões.

As previsões obtidas dos valores das variáveis independentes, com a utilização do *software*, são apresentadas numa tabela ao lado do conjunto de dados.

## 4.3. Desenvolvimento do Estudo

### 4.3.1. Introdução

Antes de iniciar o trabalho com as RNA, foi necessário adquirir o *software* necessário para a realização do estudo, o NeuralTools. Como a Universidade do Minho não dispunha do programa em nenhum dos seus departamentos, foi necessário a aquisição por parte da empresa Águas do Noroeste.

O início do estágio focou-se no conhecimento do funcionamento da digestão anaeróbia, e entender o procedimento adaptado na ETAR do Ave, conhecimento importante para a tomada de decisões aquando da realização do estudo das RNA. Houve também em paralelo, durante todo o período de estágio, o trabalho de acompanhamento da exploração da ETAR do Ave, cuja exploração é feita pela EFACEC ENGENHARIA. Este trabalho permitiu obter conhecimento do seu

funcionamento e organização da exploração, incluindo quais as funções de um operador e dos analistas do laboratório, acompanhando também os processos de amostragem e de controlo do processo.

Sendo o objetivo otimizar o processo de digestão anaeróbia, refletindo na otimização da produção de biogás, recorrendo a RNA, o conjunto de dados a tratar deve estar diretamente relacionado com os dois digestores anaeróbios existentes e a produção de biogás tem de ser, obrigatoriamente, uma variável presente. Contudo, a instalação não dispõe da medição parcial de biogás de cada digestor, optando-se por considerar os dois digestores como um digestor global, com uma entrada e saída única. Isto fez com que fosse necessário adaptar os dados fornecidos para que os resultados da digestão anaeróbia reflitam o funcionamento como sendo um só digestor.

Outra particularidade da ETAR é a adição de gorduras nos digestores anaeróbios, provenientes do tratamento preliminar, com o fim de aumentar a produção de biogás. Por forma a estudar o impacto das gorduras na rede, e por consequência na previsão do biogás, testaram-se duas hipóteses de trabalho. Na primeira, há a modelação do processo de digestão anaeróbia através de RNA sem considerar as gorduras adicionadas como uma variável disponível para variável de *input* do processo; na segunda, repete-se o procedimento mas as gorduras são consideradas uma variável de entrada.

#### **4.3.2. Preparação dos dados**

A ETAR do Ave cumpre um plano de amostragem para recolha, ao longo do processo, dos diversos dados para avaliação do seu funcionamento. Esses dados são armazenados numa plataforma, o NAVIA, facilitando o seu acesso. Este *software* foi implementado pelo Grupo Águas do Noroeste e encontra-se a uso da EFACEC ENGENHARIA, pelo que o acesso aos dados foi um pouco limitado, no sentido de preservar as fórmulas e métodos utilizados pela entidade exploradora.

Relativamente aos dados necessários para o desenvolvimento da RNA, parte-se do princípio que quanto maior for a base de dados, isto é, quanto maior o número de casos disponíveis, melhor serão os resultados obtidos pelo treino. Como consequência, será mais fácil compreender as várias relações entre as variáveis e os casos, o que fará com que a capacidade

de previsão da rede neuronal seja melhor. Contudo, e como já foi referido, não é só a quantidade que interfere no treino da RNA, a qualidade dos dados disponíveis também é um fator importante para o seu desempenho (Lingireddy e Brion, 2005).

Por norma, uma ETAR recolhe variadíssimos dados, em termos de recolha de lamas e de efluentes, em períodos diferentes e portanto, existem dados diários, semanais, quinzenais, mensais, trimestrais, etc., e essa recolha é feita pelos operadores. A sua periodicidade depende do processo implicado para a sua obtenção, pois existem dados que são recolhidos e obtidos diretamente no local de amostragem, enquanto outros necessitam de tratamento laboratorial, ficando dependentes não só do procedimento para a sua obtenção, como também da disponibilidade do laboratório.

Para este trabalho, foram dispensados dados diários e semanais relativos a todos os meses de 2012 e 2013, bem como até Julho do presente ano. No anexo I é apresentado as tabelas relativas aos dados de um só mês, dos trinta e um que estiveram disponíveis, pois há uma grande quantidade de informação mensal, com tabelas muito extensas, optando-se assim por apresentar uma amostra daquilo que esteve disponível. De seguida, na tabela 3, apresentam-se todas as variáveis que estiveram no leque de escolhas.

Tabela 3. Variáveis disponíveis para treino das RNA referentes de Janeiro de 2012 a Julho de 2014. Dados diários, 31 variáveis com 942 casos cada uma; Dados Semanais, 84 variáveis com aproximadamente 145 casos cada uma

<b>DADOS DIÁRIOS</b>	<b>DADOS SEMANAIS</b>
Temperatura (°C) do Digestor 1 e do Digestor 2	pH, ST (g/L), SV (g/L), %SV/ST e %matéria seca de lamas primárias – linha 1, 2 e 3
Caudal (m <sup>3</sup> /dia) de Gorduras introduzido no digestor 1 e 2	
Qualidade do Biogás no Gasómetro: Percentagem de CH <sub>4</sub>	pH, ST (g/L), SV (g/L), %SV/ST e %matéria seca de lamas primárias espessadas – linha 1 e 2
Qualidade do biogás no Gasómetro: Percentagem de CO <sub>2</sub>	
Qualidade do biogás no Gasómetro: Percentagem de H <sub>2</sub> S	pH, ST (g/L), SV (g/L), %SV/ST e %matéria seca de lamas secundárias recirculação/excesso – linha 1, 2 e 3
Caudal (m <sup>3</sup> /dia) de <i>By-pass</i> à ETAR	

Caudal (m <sup>3</sup> /dia) de efluente reutilizado	pH, ST (g/L), SV (g/L), %SV/ST e %matéria seca da entrada no tambor de espessamento
Caudal (m <sup>3</sup> /dia) de elevação de fossas sépticas	
Caudal (m <sup>3</sup> /dia) de escumas e escorrências	pH, ST (g/L), SV (g/L), %SV/ST e %matéria seca de lamas biológicas espessadas do tambor – linha 1 e 2
Caudal (m <sup>3</sup> /dia) de lamas primárias para espessador 1 e espessador 2	
Caudal (m <sup>3</sup> /dia) de lamas primárias espessadas para tanque de lamas mistas	pH, ST (g/L), SV (g/L), %SV/ST e %matéria seca de lamas mistas espessadas
Caudal (m <sup>3</sup> /dia) de recirculação de lamas – linha 1, 2 e 3	
Caudal (m <sup>3</sup> /dia) de lamas em excesso – linha 1, 2 e 3	pH, ST (g/L), SV (g/L), %SV/ST e %matéria seca de lamas digeridas
Caudal (m <sup>3</sup> /dia) de lamas para espessamento mecânico – linha 1 e 2	
Caudal (m <sup>3</sup> /dia) de polímero para espessamento mecânico – linha 1 e 2	pH, ST (g/L), SV (g/L), %SV/ST e %matéria seca de lamas desidratadas
Caudal (m <sup>3</sup> /dia) de lamas espessadas para digestor – linha 1 e 2	
Caudal (m <sup>3</sup> /dia) de lamas para desidratação – linha 1 e 2	pH, ST (g/L), SV (g/L), %SV/ST, %matéria seca, Alcalinidade (mgCaCO <sub>3</sub> /L) e Ácidos Gordos Voláteis (mgCaCO <sub>3</sub> /L) de lamas do digestor – linha 1 e 2
Caudal (m <sup>3</sup> /dia) de biogás para a tocha	
Caudal (m <sup>3</sup> /dia) de biogás para a caldeira	
Caudal (m <sup>3</sup> /dia) de biogás para os cogeneradores e caldeira	

Seguidamente, e após organizar todos os dados disponibilizados, foi necessário definir as variáveis e dados a utilizar. Esta escolha foi feita consoante a disponibilidade dos dados, considerando-se até que ponto seriam fiáveis, não sendo descartada a hipótese de haver erros nas anotações ou na recolha das amostras, e o conhecimento prévio de todo o processo, em que se conhece quais as variáveis que têm maior impacto na digestão anaeróbia.

Tendo em conta estes dois critérios, procedeu-se à escolha das variáveis de *input* a utilizar na modelação da rede neuronal de previsão da produção de biogás. As variáveis de *input*

escolhidas estão apresentadas na tabela 5 com o respetivo nome, tipo de variável e periodicidade de amostragem.

Outro dos critérios a ter em conta na escolha, é a relação direta entre as variáveis, por outras palavras, se as variáveis estão diretamente relacionadas, partilhando algum parâmetro que as definem. Aquando do treino da rede, é importante que não sejam assumidas relações com uma importância superior comparando com as restantes variáveis para não adulterar os resultados finais.

Tabela 4. Variáveis independentes ou de *input* escolhidas para as bases de dados

<b>Variável</b>	<b>Nomenclatura</b>	<b>Periodicidade de Amostragem</b>
Sólidos voláteis do tanque de lamas mistas - g/L	<i>SV</i>	Semanal
Caudal dos digestores (entrada) – m <sup>3</sup> /dia	<i>Q entrada</i>	Diário
pH dos digestores - escala Sörensen	<i>pH</i>	Semanal
Temperatura dos digestores - °C	<i>Temperatura</i>	Diário
Caudal de gorduras adicionada aos digestores - m <sup>3</sup> /dia	<i>Gorduras</i>	Diário
Ácidos Gordos Voláteis (Lamas dos Digestores) – mg/L de CaCO <sub>3</sub>	<i>AGV</i>	Semanal
Alcalinidade (Lamas dos digestores) – mg/L de CaCO <sub>3</sub>	<i>Alcalinidade</i>	Semanal
Caudal de Biogás Total produzido - m <sup>3</sup> /dia	<i>Biogás Total</i>	Diário

Os parâmetros escolhidos são descritos seguidamente:

- Sólidos Voláteis– representam o conteúdo de matéria orgânica da lama e são apresentados em g/L. No conjunto de sólidos que são introduzidos num digestor, estes são considerados a fração mais importante no que toca à produção de biogás, pois o seu conteúdo é um indicador primário do potencial de metano. Assim sendo, os *SV* são considerados a variável limitante, sendo este o ponto base para a escolha dos restantes casos dos parâmetros.
- Caudal de entrada – representa o volume de lamas por dia que entra nos digestores. A quantidade e as características estão dependentes do efluente que dá entrada na ETAR.

- Temperatura – refere-se à temperatura diária dentro do digestor e é medida em °C. É fundamental para o processo que a temperatura seja um parâmetro bastante controlado, pois como já foi referenciado, qualquer alteração, pontual ou frequente, pode alterar o bom funcionamento do digestor e provocar danos irreversíveis. Os digestores anaeróbios da ETAR do Ave operam em regime mesófilo, numa gama de temperaturas compreendida entre 35 e 38 °C.
- Caudal de Gorduras (Gorduras) – parâmetro referente à quantidade de gorduras que é adicionado aos digestores por dia. A adição de gorduras/lípidos aumenta a produção de biogás, conforme já estudado pela entidade exploradora. Pelo que foi encontrado na bibliografia, só operando em processo descontínuo baseado na tecnologia de reatores fechados sequenciais seria possível as gorduras, quando presentes com elevados teores, não serem inibidores da digestão anaeróbia (Alves *et al.*, 2004). Contudo, a ETAR do Ave opera em sistema contínuo e está provado em termos práticos que a produção de biogás é maior com esta adição. Assim irá ser estudado o impacto que as gorduras podem ter quando consideradas variável de entrada na rede neuronal artificial.
- Alcalinidade – resulta da presença de hidróxidos, carbonatos e bicarbonatos sendo expressa em miligrama de carbonato de cálcio por litro. Representa a resistência do meio a alterações de *pH*, causados pela acidificação do mesmo. Por outras palavras, este parâmetro é importante no processo, pois define a estabilidade do digestor.
- Ácidos Gordos Voláteis (AGV) – são formados durante o processo de digestão anaeróbia e têm uma grande influência no processo. Quando presentes em altas concentrações, levam a uma diminuição do *pH* pois provocam uma diminuição da alcalinidade. Se tal acontecer, o meio pode tornar-se impróprio/tóxico para alguns microrganismos existentes no processo.
- Caudal de biogás total (Biogás Total) – parâmetro definido como *output* do processo, dado que o principal objetivo deste estudo é otimizar não só o processo de digestão anaeróbia, mas também a produção de biogás, através da utilização de RNA. É apresentado em m<sup>3</sup>/dia e representa o volume de biogás produzido, através do somatório do biogás destruído termicamente com o biogás valorizado. A instalação não dispõe de medição parcial a cada digestor, daí ser necessário fazer o somatório do biogás encaminhado para destruição, queimado na tocha, e biogás valorizado, quer na caldeira de aquecimento, quer nos grupos de cogeração.



É importante referir que em algumas das variáveis apresentadas, todos os seus casos foram recalculados dado que neste estudo considera-se que a digestão anaeróbia ocorre num só digestor. Posto isto, o valor presente de caudal de entrada em cada caso corresponde à soma do valor desta variável, em cada digestor, para cada caso. O mesmo se aplica no caso do caudal de biogás total que corresponde à soma do caudal de biogás que é encaminhado para a tocha, caldeira e cogeneradores. Relativamente às restantes variáveis, excetuando os sólidos voláteis, todos os casos correspondem à média de valores entre os dois digestores presentes na ETAR, para cada caso.

Como a quantificação de gorduras na ETAR do Ave só é feita desde Abril de 2013, houve a necessidade de criar duas bases de dados de forma a testar as duas hipóteses de trabalho propostas, sendo:

1ª Hipótese - modelação de redes neuronais não assumindo a quantificação de gorduras como uma variável disponível para ser variável de entrada do sistema;

2ª Hipótese - modelação de redes neuronais assumindo a quantificação de gorduras como variável de entrada.

Depois de escolhidas as variáveis para as bases de dados, foi necessário fazer a seleção dos casos a escolher. Dos dados fornecidos, (consultar exemplo de um mês no anexo I), foram analisados os valores das variáveis, caso a caso, recorrendo não só à observação detalhada das tabelas mas também a tratamento gráfico para determinar quais os *outliers* presentes, resultantes quer de erros de medição quer da digitação de valores. Dado que o número de casos disponíveis era bastante extenso, houve necessidade de estabelecer uma variável como sendo limitante, fundamental para o processo de digestão anaeróbia, ditando quais os dias dos casos a escolher para as restantes variáveis. Assim, dada a grande influência que os SV possuem no processo, foi essa a estabelecida como a variável limitante do processo, pelo que os casos do processo teriam de ser escolhidos consoante a periodicidade deste parâmetro. Posto isto, surgem, então, as duas bases de dados para a modelação do processo de digestão através de redes neuronais correspondendo cada uma delas às duas hipóteses de trabalho, podendo ser consultados no anexo II. A primeira tabela do anexo II, tem-se a base de dados que não possui a quantificação de gorduras como uma variável disponível, com 109 casos, sendo apelidada por

**base de dados sem gorduras.** Na segunda tabela do mesmo anexo, a quantificação de gorduras já é assumida como uma variável de entrada do processo, e apresenta-se a base de dados relativa à segunda hipótese de trabalho, com 53 casos disponíveis, sendo apelidada nas etapas seguintes como **base de dados com gorduras.** Nenhuma das bases de dados possui uma grande quantidade de casos, dado que inicialmente existiam cerca 942 casos disponíveis, compreendidos entre Janeiro de 2012 a Julho de 2014, sendo reduzidos para valores próximos de 100.

De salientar que durante o processo de treino e teste houve necessidade de editar o conjunto de dados, passando do conjunto de dados presente no anexo II para o conjunto de dados apresentado no anexo III, que foi utilizado para levar até ao fim o presente estudo. Durante a descrição da próxima fase, isto será explicado com maior detalhe.

### **4.3.3. Treino e Teste**

Após uma boa preparação dos dados e boa definição do conjunto de dados, iniciou-se a fase de treino e teste da modelação de redes neuronais. É importante referir que apesar de na parte inicial deste trabalho estas etapas serem descritas separadamente, o NeuralTools permite que estas aconteçam em simultâneo do ponto de vista do utilizador, permitindo facilitar o seu trabalho. Contudo, o *software*, internamente, executa primeiro o treino e depois o teste sem que haja necessidade de uma intervenção por parte do utilizador. Tem a capacidade de dividir o conjunto de dados fornecido em conjunto de treino e conjunto de teste, mas dispõe a possibilidade de se poder definir a percentagem dos dados disponíveis que se pretende que intervenham na fase de teste. Assim, depois de serem definidas todas as configurações da rede, o NeuralTools escolhe aleatoriamente os casos pertencentes a cada fase.

São várias as redes que podem ser treinadas e testadas, mas no fim só uma é escolhida para a previsão dos resultados finais. Para tal, a escolha da melhor rede é feita de acordo com as previsões inadequadas na fase de teste e com o erro médio quadrático (EMQ) que possui. A melhor rede é aquela que apresenta um valor menor em cada um destes dois parâmetros. De forma a entender melhor o funcionamento de todo o programa, foram criados inicialmente conjuntos de dados aleatórios com o objetivo explorar e compreender todas as funcionalidades da fase de treino e teste de RNA.

Durante o processo de treino e teste foram apresentados dois conjuntos de redes, em que cada um deles tem redes referentes às duas bases de dados existentes. Em cada base de dados foram treinadas várias redes com conjuntos de dados diferentes, começando por modelar uma rede neuronal usando todas as variáveis de entrada possíveis. Com isto pretende-se ver qual o impacto que cada variável tem no processo, de forma a poder definir qual a sua importância. Assim é possível criar novos conjuntos de dados, com um menor número de variáveis de entrada, permitindo observar como o número de variáveis pode influenciar a modelação das redes na fase de teste. Não só o número de variáveis de entrada é importante, as variáveis escolhidas também têm o seu peso, pois podem ser treinadas e testadas várias redes em conjuntos de dados com o mesmo número de variáveis de *input*, sendo elas diferentes, apresentando depois resultados distintos nos relatórios gerados pela ferramenta.

Todas as redes foram treinadas no modo de “Busca da melhor rede”. Esta opção que o NeuralTools dispõe permite treinar e testar variadíssimas configurações de redes até encontrar aquela que possui melhor desempenho para o conjunto de dados existente. Como o que pretendemos trata-se de uma previsão numérica, o NeuralTools dispõe de dois tipos de rede: redes *Multi-Layer Feedforward* (MLF) ou Redes Neurais de Regressão Generalizada (GRNN). Além disso, por definição, em cada “Busca da melhor rede” são treinadas redes GRNN e MLF de 2 a 6 nós numa camada oculta, havendo uma comparação dos resultados com uma regressão linear. Contudo estas configurações podem ser alteradas pelo utilizador escolhendo se quer que seja feita regressão linear, quais dos dois tipos de redes devem ser incluídas na procura e, no caso das redes MLF, existe a opção de escolher o número mínimo e máximo de nós que a camada oculta pode possuir, variando entre 2 e 100. Nesta fase é importante ter em conta que as redes GRNN, por norma, caracterizam-se pela sua rapidez no processamento, enquanto as redes MLF são mais lentas, podendo demorar horas a concluir o treino e teste de cada rede.

Seguidamente, serão apresentados esses dois conjuntos de redes.

#### **4.3.3.1. Primeiro conjunto de redes**

Neste primeiro conjunto, foram treinadas e testadas redes neuronais a partir das bases de dados apresentadas no anexo III. Algumas redes foram treinadas e testadas com recurso à opção “Busca da melhor rede”, em que o número de nós variou entre 2 a 6 na camada oculta.

Após observar os relatórios gerados pelo *software* por cada rede treinada (exemplo apresentado no ponto 4.2.3.4 da presente dissertação), verificou-se que das várias redes treinadas na base de dados sem gorduras (ver compilação de redes no anexo IV), a melhor rede encontrada foi a rede “1.1\_RNA\_8”, configurada como uma rede GRNN tendo como variáveis de entrada, *Q entrada*, *AGV*, *Temperatura* e *SV*, e como variável de saída o *Biogás Total*, cujo EMQ é de 1184,89 e possuía cerca de 59% de previsões inadequadas. Todas as outras redes possuem EMQ superiores e na generalidade todas as previsões inadequadas estão acima dos 50%. Relativamente às redes treinadas na base de dados com gorduras (ver compilação de redes no anexo IV), a melhor rede treinada foi a rede “1.2\_RNA\_8” que tinha como variáveis de *input* o *Q entrada*, *AGV*, *Gorduras* e *SV*, configurada como uma rede MLF de 4 nós, cujo EMQ é de 481,2 e cerca de 65% de previsões inadequadas. Quase todas as redes treinadas e testadas nesta base de dados tinham EMQ exorbitantes, acima dos 1000, e a percentagem de previsões inadequadas rondava os 70%, na maioria dos casos apresentados.

Assim, houve a necessidade de mudar as bases de dados, pois com previsões de teste tão inadequadas mostrava que nenhum dos conjuntos de dados escolhidos transmitiam a realidade da produção de biogás e os EMQ tão elevados provavam haver uma grande incoerência. Tal facto advém da seleção dos casos aquando da formação das bases de dados. No processo da digestão anaeróbia da ETAR do Ave, a medição de biogás é feita somente no local que visa o seu destino, a sua contabilização é feita após a saída do biogás do gasómetro quando este é encaminhado para ser destruído ou valorizado, não havendo uma medição diária do biogás efetivamente produzido. A quantidade de biogás armazenado no gasómetro e o nível do tanque de lamas digeridas, e conseqüentemente o volume de biogás acumulado neste tanque, são variáveis do processo não disponíveis. Por forma a contornar esta limitação, chegou-se à conclusão que uma solução possível seria trabalhar com valores médios diários de produção de biogás calculados no período dos 7 dias mais próximos do dia em análise. Assim as duas bases de dados foram alteradas, os valores da variável referente ao biogás total produzido pela ETAR do Ave e podem ser consultadas no anexo III.

#### 4.3.3.2. Segundo conjunto de redes

Após a preparação das duas novas bases de dados, procedeu-se ao treino e teste de redes neuronais. Todas as redes presentes neste novo conjunto foram treinadas recorrendo à opção “Busca da melhor rede” que o *software* dispõe e, assim, para cada conjunto de dados somente a rede com melhor desempenho foi escolhida. Ao contrário do que aconteceu no primeiro conjunto de redes apresentado, aqui optou-se por alargar o número de nós na camada oculta, tanto que em todas as redes foram treinadas e testadas redes GRNN e MLF de 2 a 10 nós numa camada oculta, sendo que em algumas chegou-se mesmo aos 15 e 25 nós. Com isto, pretendeu-se ver qual a influência do aumento de nós no desempenho das redes.

Relativamente à base de dados sem gorduras presente no anexo III, não se notou melhorias no aumento do número de nós nas redes MLF treinadas, sendo que a maior parte das redes com melhor desempenho são redes GRNN ou MLF de 2, 3 ou 7 nós. No que diz respeito aos EMQ e às previsões inadequadas, em nenhuma das redes o erro foi inferior a 300, assumindo que o aceitável é na ordem dos 0-150, e as previsões inadequadas foram sempre acima do definido no programa como tolerável, os 30%. Entende-se que quanto menor o valor destes dois critérios, melhor é a rede neuronal. Assim, segundo os critérios de escolha de redes, nenhuma apresenta as características ditas ideais para proceder à previsão. Posto esta situação, a rede escolhida recaiu sobre aquela em que o conjunto de dados possui as variáveis que mais influenciam o processo da digestão anaeróbia, sendo esta análise feita através do conhecimento adquirido sobre o processo. A rede escolhida foi a rede “A2” que tem como variáveis de *input* o *Q entrada*, a *Temperatura*, os *SV* e os *AGV*, tratando-se de uma rede MLF de 3 nós. Esta rede apresenta também uma das percentagens de previsões inadequadas mais baixas, quando comparada com as restantes redes deste conjunto, relativas a esta hipótese de estudo, cerca de 36%, muito próximo do que foi estabelecido como tolerância (30%) e o seu EMQ é de 474,30. Todos os resultados das redes treinadas para esta base de dados estão disponíveis no anexo V.

Tal como no primeiro conjunto de redes, a melhor rede para a base de dados sem gorduras era constituída pelas mesmas variáveis independentes da melhor rede apresentada neste conjunto, simplesmente o erro e as previsões inadequadas são bastante mais pequenas do que no primeiro caso apresentado, dada a alteração feita nos casos da variável de *output*, o biogás total.

No que diz respeito à base de dados em que se pretende modelar redes neuronais tendo em conta a quantificação de gorduras (base de dados com gorduras presente no anexo III), a escolha da melhor rede dos conjuntos de dados estudados recaiu sobre o valor do EMQ, da percentagem de previsões inadequadas, das variáveis do conjunto de dados que têm maior influência no processo e que foram escolhidas também pela base de dados sem gorduras. Com isto, pretendeu-se fazer uma comparação entre as redes escolhidas que, apesar de terem bases de dados diferentes, têm variáveis de entrada iguais excetuando que no segundo caso existe a variável referente à quantificação de gorduras. Tal como sucedido na base de dados sem gorduras e observando os vários relatórios gerados pelo NeuralTools, os EMQ são todos superiores a 300, mas relativamente às previsões inadequadas na fase de teste a situação é melhor. As percentagens são na sua grande parte próximas de 50% mas, em alguns casos, ao contrário do que acontecia no primeiro caso, chegam a ser menores de 30%, estando dentro da tolerância estimada. A rede escolhida foi, portanto, a rede “B15”, tratando-se de uma rede GRNN, cujas variáveis de entrada são o *Q entrada*, a *Temperatura*, os *SV*, as *Gorduras* e os *AGV*, possuindo um valor de EMQ de 607,96 e a percentagem de previsões inadequadas que ronda os 45%. É de salientar que o impacto das variáveis, quer nesta rede quer na rede “A2”, referente à base de dados sem gorduras, é muito semelhante, pois o caudal de entrada, a temperatura dos digestores e os sólidos voláteis são os parâmetros que maior influência têm em ambas as redes. Já a quantificação de gorduras, conforme se pode constatar pela compilação de redes para a base de dados com gorduras presente no anexo V, não têm um impacto muito grande na rede, nem na maior parte das redes treinadas e testadas nesta base de dados.

Ao analisar todos os relatórios gerados ao fim de cada treino e teste das RNA deste conjunto, existe uma rede que possui um erro menor bem como a percentagem de previsões inadequadas dentro da tolerância estimada nas confirmações da rede. Esta é a rede “B4”, cujas variáveis de *input*, por ordem de impacto na rede, são a *Alcalinidade*, o *pH*, a *Temperatura*, as *Gorduras* e os *AGV*, com um valor de EMQ de cerca de 400 e a percentagem de previsões inadequadas a rondar os 27%, sendo das mais baixas encontradas na realização deste estudo. Nesta rede não estão presentes duas das variáveis que tiveram um elevado impacto nas outras redes já referidas (rede “A2” e rede “B15”), assim pretende-se ver qual é resultado da previsão com novos valores a fim de fazer uma comparação com a rede escolhida para a segunda hipótese do estudo, a rede “B15”.

#### 4.3.4. Previsão e Validação

Esta é a última etapa do todo o processo de modelação de RNA em que se pretende verificar a capacidade de generalização e o desempenho das melhores RNA escolhidas no passo anterior. Aqui, criou-se um novo conjunto de dados do qual as redes não tiveram conhecimento na fase de treino e teste, para assim efetuar previsões de biogás total produzido associado às variáveis de *input* das redes, sem conhecer os valores de *output*. Além disto, optou-se por fazer também uma previsão dos valores já conhecidos, relativos às bases de dados utilizadas no treino e teste de redes. Apesar dos valores das variáveis de *output* já serem conhecidos pretende-se ver qual a resposta da rede, com fim a comparar os resultados de biogás total reais com os previstos. Ao ser feita esta previsão, vai ser ativada a opção “Previsão Instantânea” para poder estudar o modo como as alterações feitas em algumas das variáveis de entrada se refletem na produção de biogás.

##### 4.3.4.1. Previsão Instantânea

De forma a avaliar o desempenho da rede e a alterações causadas por mudanças nos valores das variáveis de entrada foram feitas previsões nas duas bases de dados conhecidas (anexo III), utilizando as melhores redes: a rede “A2” para a primeira hipótese de estudo e a rede “B15” para a segunda hipótese. Analisou-se o comportamento da rede na previsão de valores de *output*, fazendo variar de forma constante o valor de Temperatura e a quantificação de gorduras que são adicionadas aos digestores. Para tal houve junção dos resultados em tabelas e posterior criação de gráficos de forma a facilitar a análise.

##### Base de dados sem gorduras

Na primeira hipótese a ser estudada, a melhor rede escolhida foi a rede “A2” cujas variáveis de *input* são o *Q entrada*, a *Temperatura*, os *SV* e os *AGV*. Segundo o gráfico abaixo apresentado (gráfico 1), pode verificar-se que as previsões assumem um comportamento muito semelhante à produção de biogás real, pois os valores previstos não diferem muito dos valores reais.




Gráfico 1. Comparação do biogás total produzido com o biogás total previsto com a rede "A2". (azul) valores de biogás real; (vermelho) valores de biogás previsto pela rede.

Esta semelhança entre os valores reais e previstos pode dever-se ao facto da rede já conhecer os valores da variável de *output*, apesar disso, as similaridades são visíveis.

A variável de entrada a ser estudada nesta hipótese foi a *Temperatura*. Os valores das variáveis foram dispostos em tabelas, apresentadas no anexo VI, e foram elaborados vários gráficos de forma a melhor entender como funcionam as respostas das variáveis de *output* face às alterações feitas nas outras variáveis. A previsão da produção de biogás foi testada para uma gama de temperaturas compreendida entre 35 e 40 °C e verificou-se que a temperatura que melhor se adapta ao processo de digestão anaeróbia no sentido de otimizar a produção de biogás, perante a RNA escolhida, é 37 °C (gráficos em Anexo 6). No gráfico 2, é possível verificar que o biogás previsto a uma temperatura constante de 37 °C é bastante parecido com o biogás produzido pela ETAR do Ave. É importante referir que no caso estudado com temperaturas constante de 36 e 38 °C, as previsões também eram aceitáveis, dada a proximidade com os valores reais.






Gráfico 2. Comparação do comportamento da produção real de biogás total (azul) com a previsão da produção de biogás total à temperatura constante de 37 °C (vermelho). Previsão feita com a rede “A2”. Desvio Padrão médio resultante da média da diferença entre o biogás previsto à temperatura real com o biogás previsto com à temperatura testada foi de 10%.

Nas restantes temperaturas estudadas, principalmente nos extremos da gama, os valores de biogás previstos não refletiam o comportamento da produção real de biogás, com muitos valores de *output* previstos iguais, aumentando o desvio padrão.

#### Base de dados com gorduras

Esta base de dados, como já foi referido, foi utilizada para a modelação de redes neuronais tendo a quantificação de gorduras como variável de entrada. A rede escolhida foi a rede “B15”, cujas variáveis de entrada são o *Q entrada*, a *Temperatura*, os *SV*, as *Gorduras* e os *AGV*. Nesta hipótese, os valores de biogás total previsto são bastante semelhantes aos valores de biogás total reais, sendo a maior parte dos valores previstos iguais aos valores de *output* reais, como é possível observar no gráfico 3. Tal como já foi dito anteriormente, o facto da rede utilizada já ter conhecimento dos valores de *output* reais pode influenciar a semelhança existente entre os valores reais e previstos.

,

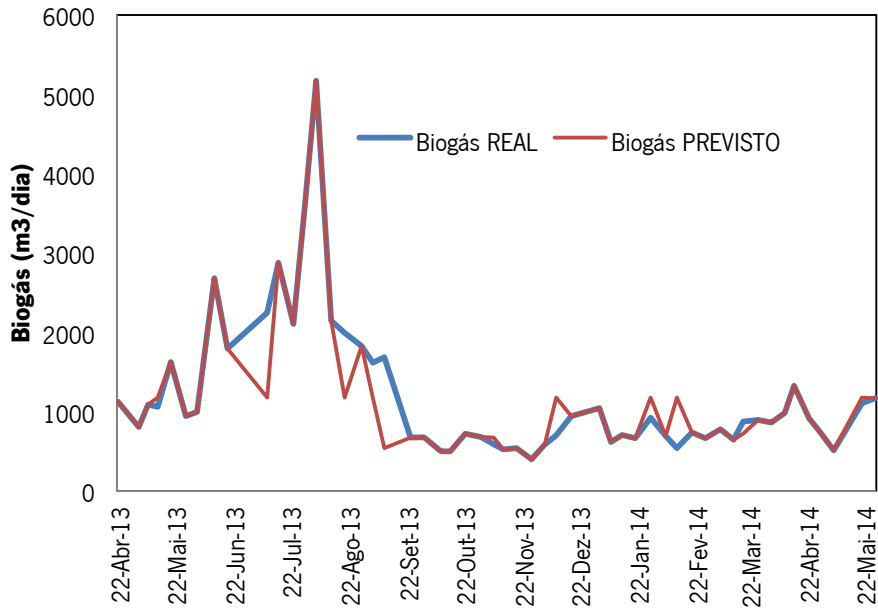


Gráfico 3. Comparação do biogás total produzido (azul) com o biogás total previsto com a rede “B15” (vermelho).

Assim, feita a análise das previsões nas duas hipóteses procedeu-se à comparação em simultâneo destas com o biogás total produzido pela ETAR. O gráfico 4 mostra o comportamento das duas previsões com o valor real. Consta-se que a previsão de valores feita com a rede “B15” assemelha-se mais à realidade de produção de biogás, enquanto os valores previstos com a rede “A2”, relativos à base de dados em que a quantificação de gorduras não é considerada uma variável, afastam-se mais dos valores reais e isso pode ser observado pelos valores de desvio padrão existentes (consultar anexo VII). Tal podem dever-se ao facto de a base de dados com gorduras possuir menos de metade dos valores da base de dados sem gorduras. Isto pode afetar a rede, pois não existem dados suficientes para serem divididos em conjuntos de treino e teste para estudar a modelação das redes neuronais bem como o funcionamento do processo, e assim podem prever-se dados pouco fiáveis, apesar de serem muito semelhantes com os valores de *output* reais. Isto é apoiado pela facto da rede já conhecer todos os dados envolvidos na base de dados, quer todos os casos das variáveis de *input* quer das variáveis de *output*, e segundo Lingireddy e Brion (2005), quanto maior o número de casos disponíveis na base de dados maior será a fiabilidade dos valores previstos com a melhor rede escolhida. Por outro lado, o facto de se considerar como variável de entrada a quantificação de gorduras pode ajudar a perceber melhor o processo de digestão anaeróbia e assim prever valores mais realistas,

independentemente do número de casos disponíveis na base de dados. O valor de biogás total real apresentado nas duas bases de dados é idêntico a partir do dia 22 de abril de 2013, bem como os casos de todas as variáveis de entrada, pois essa data/caso corresponde ao primeiro caso da segunda base de dados. Até lá a rede “B15” nada prevê pois não existem casos na base de dados correspondente.

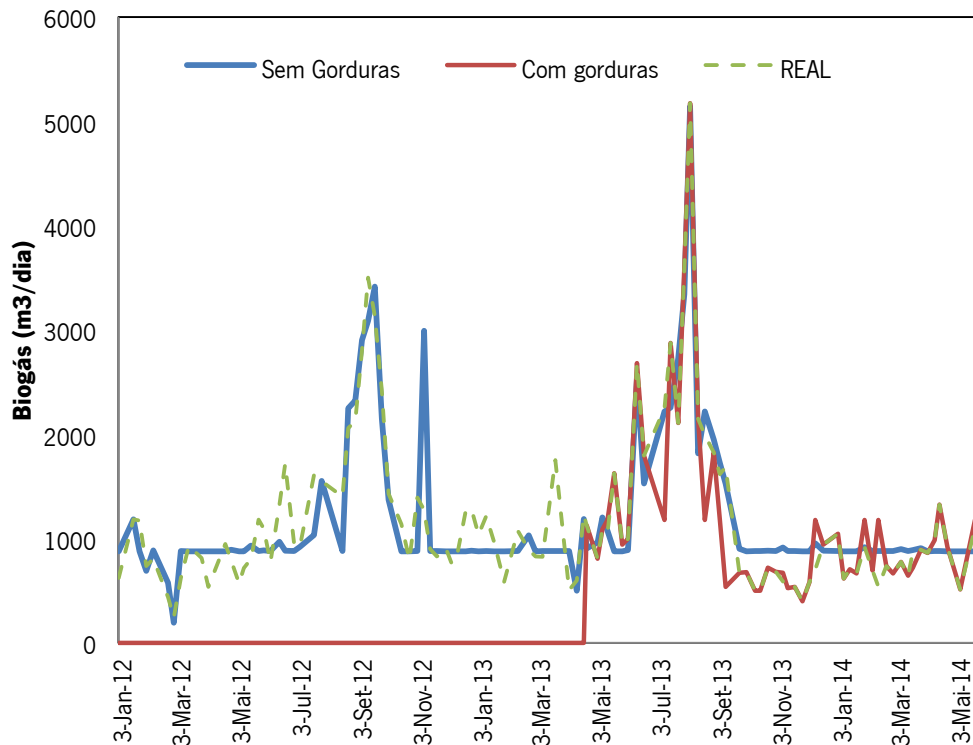


Gráfico 4. Comparação do biogás total produzido pela ETAR (verde) com as previsões do biogás total usando a rede A2, base de dados sem gorduras (azul), e a rede B15, base de dados com gorduras (vermelho). A previsão dos valores de biogás total na base de dados com gorduras só iniciou a 22 de Abril de 2013.

Seguidamente, tendo em conta somente a base de dados com gorduras, foram estudadas duas variáveis de entrada, a temperatura e a quantidade de gorduras adicionada por dia ao digestor.

Tal como sucedeu na base de dados anterior, os resultados foram compilados numa tabela de forma a facilitar a análise. Foi estudada uma gama de temperaturas compreendida entre 35 e 40 °C e, após a observação de cada um dos gráficos presentes no anexo VI, verifica-se que a temperatura que melhor se adapta à otimização da produção de biogás, perante a rede “B15”, é de 38 °C (gráfico 5).




Gráfico 5. Comparação do comportamento da produção real de biogás total (azul) com a previsão da produção de biogás total à temperatura constante de 38 °C (vermelho). Previsão feita com a rede “B15”. Desvio Padrão médio resultante da média da diferença entre o biogás previsto à temperatura real com o biogás previsto com à temperatura testada foi de aproximadamente 10%.

Neste caso, também se verificou que à temperatura constante de 37 °C, os valores das previsões de *output* também tinham comportamento muito semelhante aos valores da variável de *output* reais.

Outra das variáveis de entrada estudada foi o caudal diário de gorduras adicionado ao digestor. Aqui, a quantificação de gorduras foi definida por três valores constantes, 2, 5 e 8 m<sup>3</sup>/dia, de forma a analisar-se qual o limite máximo de gorduras que podem ser adicionadas diariamente ao digestor, mantendo os resultados fiáveis e assim tentar perceber o impacto que destas na digestão anaeróbia. A análise foi feita graficamente (disponível em anexo VIII) bem como analisando caso a caso através da observação direta dos casos na tabela (disponível em anexo VIII). Quando a variável de entrada relativa ao caudal de gorduras é de 8 m<sup>3</sup>/dia em todos os casos, os valores previstos de biogás total diferem bastante do comportamento do biogás total produzido na ETAR, havendo valores demasiado altos comparado com o histórico (tabelas de exemplo-mês disponibilizadas no anexo I) ou mais baixos.

Pela análise do gráfico 6, verifica-se que a quantidade de gorduras diárias que melhor se adequam à previsão de valores de biogás total, para a rede utilizada, varia entre 2 e 5 m<sup>3</sup>/dia.




Gráfico 6. Comparação do comportamento da produção real de biogás total (azul) com a previsão da produção de biogás total a caudal constante de gorduras a 2 m³/dia (vermelho) e a 5 m³/dia (verde). Previsão feita com a rede “B15”. Desvio Padrão médio resultante da média da diferença entre o biogás previsto com a quantidade de gorduras real com o biogás previsto com a quantidade de gorduras testada foi de abaixo de 5%.

É possível comprovar que a previsão de valores para os diferentes caudais utilizados é muito semelhante, não existindo quase variação e quando comparado com a produção de biogás total real, os valores são quase coincidentes. Assim torna-se quase impossível definir um caudal de gorduras constante como o certo a utilizar. Na ETAR do Ave, o caudal de gorduras médio é de 4,11 m³/dia, mas as gorduras não são adicionadas de igual forma, havendo dias que há e outros que não há adição.

#### 4.3.4.2. Previsão e validação com novos valores

Para avaliar a capacidade de generalização de cada uma das redes neuronais escolhidas foi criado um novo conjunto de dados para previsão e validação. Neste caso não há conhecimento por parte do *software* dos valores de *output*, por isso é possível observar como funcionam as redes perante novos dados e posteriormente é feita a comparação com os valores de *output*, que são conhecidos pelo utilizador. Este conjunto abrange os meses de Junho e Julho de 2014, e os critérios de escolha dos dados disponíveis foram feitos conforme explicado na preparação de dados, no ponto 2.3.2, em que como alguns parâmetros são semanais, apenas existem oito casos neste novo conjunto, disponível em anexo IX.

Primeiramente, foi feita a previsão para a rede “A2”, rede escolhida para estudar a primeira hipótese do estudo em que a base de dados não considera o caudal de gorduras adicionado ao digestor, uma variável disponível para variável de entrada na modelação de redes. Conforme se pode verificar pelo gráfico 7, a rede neuronal tem alguma dificuldade em aproximar o valor previsto do valor real do biogás que é produzido, contudo o comportamento é bastante semelhante, havendo uma certa tendência para os valores previstos acompanharem os valores reais.




Gráfico 7. Comparação do biogás real produzido pela ETAR do Ave (azul) com o biogás previsto pela rede “A2” (vermelho) para o novo conjunto de dados.

Relativamente à rede “B15”, rede escolhida para realizar a previsão dos valores *output* da base de dados que considera o caudal de gorduras, uma variável disponível para variável de entrada, os resultados comportaram-se da mesma forma. Por outras palavras, apesar dos valores previstos serem menores que os valores reais, há também uma certa tendência em acompanhar esses valores, sendo que neste caso é muito mais evidente comparado com o anterior, conforme pode ser observado no gráfico 8.




Gráfico 8. Comparação do biogás real produzido pela ETAR do Ave (azul) com o biogás previsto pela rede “B15” (vermelho) para o novo conjunto de dados.

Na fase de treino da segunda hipótese do estudo foi referida outra rede, a rede “B4”, que era considerada a melhor rede caso a rede fosse escolhida somente pelo EMQ e a percentagem de previsões inadequadas (consultar anexo V). Em relação a estes dois critérios, esta era a rede que menores valores apresentava e assim tudo indicava que seria a melhor rede a prever. Contudo, e conforme se pode observar no gráfico 9, o resultado não é o esperado, pois a previsão de valores feita por esta rede mostra um comportamento exatamente contrário àquele que acontece na realidade.

Perante estes resultados, prova-se que a escolha da melhor RNA de um conjunto de dados não deve recair somente no EMQ e na percentagem de previsões inadequadas. Apesar disto, o conjunto de dados para validação da rede é bastante pequeno, pelo que não se pode afirmar que esta constatação é completamente verdadeira. Seria necessário haver um maior número de casos neste novo conjunto para avaliar o comportamento da previsão de uma forma mais completa. É importante salientar, uma vez mais, que o facto do conjunto de treino não ser muito extenso também pode afetar a rede.




Gráfico 9. Comparação do biogás real produzido pela ETAR do Ave (vermelho) com o biogás previsto pela rede “B4” (azul) para o novo conjunto de dados.





## 5. CONSIDERAÇÕES FINAIS

### 5.1. Conclusões

Uma ETAR deve sempre tirar o maior partido possível da rentabilidade da exploração, devido aos elevados consumos energéticos que estão associados às várias operações de tratamento. A otimização do processo de digestão anaeróbia para a produção de biogás é, portanto, essencial. O biogás é uma fonte de energia pouco poluente e de baixo custo, pelo que as entidades que gerem as ETAR não devem ignorar as várias vantagens a nível económico e ambiental, que este biocombustível pode ter, apostando em estudos e projetos que façam compreender melhor todo o seu processo.

As RNA são uma ferramenta com um enorme potencial para a modelação do processo da digestão anaeróbia. Tratam-se de ferramentas matemáticas capazes de entender relações implícitas existentes num determinado conjunto de dados, funcionando de forma análoga ao cérebro humano. Estas redes são trabalhadas, fase de treino e teste, sobre um conjunto de dados que permite definir um padrão, ou seja, servem como exemplos, para que quando novos dados forem apresentados sejam capaz de fazer previsões. O *software* escolhido para fazer a modelação do processo de digestão anaeróbia através da aplicação de RNA foi o NeuralTools™ da Palisade™, que pode ser trabalhado no Microsoft Excel™.

Neste estudo foram definidas duas hipóteses de trabalho. Em ambas houve modelação do processo de digestão anaeróbia através das RNA, mas somente uma tinha em conta a quantificação de gorduras para o digestor como variável de entrada no sistema. Nas duas bases de dados foram desenvolvidas várias redes neuronais do tipo MLF e GRNN, que não apresentavam um bom desempenho, tendo como possíveis causas o facto de não haver medição do biogás produzido à saída do digestor, o facto do valor de biogás apresentado corresponder a uma média, e não ao valor efetivamente produzido, e devido aos valores dos casos existentes em algumas variáveis serem muito diferentes uns dos outros, o que tornou difícil encontrar uma relação entre as várias variáveis. Contudo, tendo em conta o funcionamento do processo da digestão anaeróbia e os critérios de escolha de redes neuronais, foi possível escolher as melhores redes e assim observar qual o impacto que esse conjunto de redes tem no processo.

Nas duas melhores redes escolhidas, cada uma pertencente a uma hipótese, o  $Q$  entrada, a *Temperatura* e os  $SV$  foram as três variáveis com maior impacto, sendo os  $AGV$  a variável que menos peso tem na rede neuronal. A variável *Gorduras*, presente apenas numa das redes, não teve um impacto muito significativo na rede. Posto isto, tentou-se avaliar o desempenho da rede com os dados utilizados na fase de treino e teste, através da previsão, mesmo já sendo valores conhecidos. Conclui-se que a rede prevê valores muito semelhantes aos valores reais, podendo dever-se ao conhecimento de todos esses valores por parte da rede.

As previsões apresentadas permitem perceber qual a gama de funcionamento ótimo para as diferentes variáveis, dependendo se estas podem ser controladas durante o processo, pois algumas dependem do próprio efluente. Assim, foram somente testadas duas variáveis, a *Temperatura* e as *Gorduras*, com o intuito de entender como funciona o digestor caso estas variáveis tenham valores constantes. No caso da *Temperatura*, conclui-se que a ótima para produção de biogás varia entre 37 e 38 °C, nas duas hipóteses, pois para valores mais altos ou mais baixos, os valores de produção de biogás previsto não descrevem a realidade da produção de biogás na ETAR. Relativamente às *Gorduras*, testada apenas na rede “B15”, não é possível definir um valor constante a ser utilizado, pois a adição de gorduras feita na ETAR é aquela que reflete melhores valores de produção de biogás. É importante salientar que quando foi testado o valor constante de 8 m<sup>3</sup>/dia de gorduras adicionadas ao digestor, aproximadamente o dobro do caudal médio diário real (4,11 m<sup>3</sup>/dia), a previsão da produção de biogás diminuiu numa grande parte dos casos. Isto vai de encontro aquilo que foi descrito anteriormente, segundo Alves *et al.* (2004), efluentes com elevados teores de lípidos não se mineralizam a metano em processos contínuos, tal só é possível em processo descontínuo, baseado na tecnologia dos reatores fechados sequenciais. Contudo, o *bulking* filamentoso que provoca a flotação do sobrenadante dos decantadores secundários, faz com que o tanque de gorduras do tratamento preliminar possua uma mistura de gorduras e de lamas secundárias, tal como explicado no ponto 2.3. Assim, pode-se considerar esse caudal elevado de entrada de gorduras no digestor como sendo o de uma mistura que contabiliza também essas lamas, na verdade não correspondendo a uma elevada percentagem de gorduras, o que poderá justificar os desvios obtidos com caudais elevados. Conclui-se, então, que as gorduras têm efeito benéfico na produção de biogás para caudais inferiores ou iguais a 5 m<sup>3</sup>/dia, em processo contínuo. Este resultado vai de encontro ao

processo real da ETAR do Ave, processo contínuo, em que a adição de gorduras, com um caudal médio diário entre 2 a 5 m<sup>3</sup>/dia, aumenta a produção de biogás.

Por fim, fez-se a validação das redes através de previsão de novos dados. Foi possível verificar a capacidade de generalização das redes. Nas duas hipóteses de trabalho, e perante as redes escolhidas, os valores previstos acompanham os valores reais, o que mostra que a rede é capaz de prever valores próximos da realidade e que pode ser utilizada na modelação do processo de digestão anaeróbia. Apesar do conjunto de dados de validação ser pequeno, a rede provou a sua capacidade de generalização.

Na segunda hipótese de trabalho, fez-se referência a outra rede, que apesar de não ter sido a escolhida como “a melhor rede”, foi aquela que apresentou melhores valores para critérios estabelecidos para a escolha de redes, mais concretamente, EMQ e previsões inadequadas no teste. Reparou-se que os valores previstos tinham um comportamento contrário, comparativamente aos valores reais relativos à produção de biogás. Conclui-se assim que um dos critérios que pode ter grande importância para a escolha da rede, além dos citados, são as variáveis de entrada que maior influência têm no processo da digestão anaeróbia, nomeadamente o caudal de entrada e sólidos voláteis do digestor.

Em suma, a utilização de RNA é um bom meio para a modelação do processo da digestão anaeróbia, pois ajuda a entender o seu funcionamento, na medida que permite o conhecimento das variáveis que mais influenciam o processo e a perceção das relações existentes entre elas, com a finalidade de dar apoio na gestão de todo o processo. Contudo, para o bom desenvolvimento da RNA e a obtenção de boas previsões, a quantidade e qualidade dos dados utilizados é crucial.

## **5.2. Sugestões para desenvolvimentos futuros**

Como foi referido ao longo do desenvolvimento do estudo, existem variáveis que possuem um alto impacto significativo no processo da modelação das RNA, nomeadamente o valor de biogás efetivamente produzido por cada digestor, contudo não há medição parcial de biogás à saída de cada um destes equipamentos, não existindo dados para este parâmetro. A implementação de dois medidores de caudal à saída de cada digestor, facilitaria a modelação das RNA e a informação obtida por estas.

Outra condicionante do processo, foi a periodicidade de medição de algumas variáveis. A maior parte dos parâmetros escolhidos nas melhores redes são medidos semanalmente, o que condicionou a base de dados de trabalho, limitando-a a um valor muito mais pequeno quando comparado com os dados que foram fornecidos inicialmente. Desde logo, isto pode influenciar o desempenho de uma RNA pois uma maior quantidade de casos leva à obtenção de melhores resultados.

Um tratamento estatístico dos dados das variáveis de entrada na primeira etapa do processo, tratamento de dados, antes de correr o NeuralTools, poderá ser uma solução para melhorar os resultados das redes. Desta forma, seria possível entender melhor quais as relações que as diferentes variáveis têm entre si e assim criar conjuntos de dados mais fiáveis, vista em obter redes melhores, com EMQ mínimos e com previsões inadequadas menores. A título de exemplo, destaca-se o programa SIMCA da UMETRICS NA MKS COMPANY, recorrendo à Análise de Componentes Principais (PCA) ou ao *Partial Least Square Regression* (PLS) para a análise dos dados.

Por fim, espera-se que este trabalho contribua para trabalhos futuros dentro do mesmo tema, ajudando na compreensão do processo de digestão anaeróbia, e que contribua para a otimização do processo de digestão anaeróbia não só na ETAR do Ave.

## **BIBLIOGRAFIA**

Águas do Noroeste, (2014) Águas do Noroeste – grupo Águas de Portugal. Acedido em: Maio de 2014 em <http://www.adnoroeste.pt/>.

Águas do Noroeste, (2010) Relatório de Sustentabilidade 2010 – Águas do Noroeste. Acedido em: Maio de 2014 em <http://www.adnoroeste.pt/>.

Alves, M. M. (1998) Estudo e caracterização de digestores anaeróbios de leite fixo. Universidade do Minho, Tese de Doutoramento, Braga

Alves, M., Cavaleiro, A. (2004) Operação Sequencial de um sistema batch para biosorção e mineralização anaeróbia de efluentes de lacticínios. Universidade do Minho.

Alves, M., Mota, M., Pereira, A. (2004) Digestão anaeróbia de gorduras: problemas e soluções. Universidade do Minho.

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

Bashir, B. H. and Matin, A. (2004a) Effect of calcium and potassium on sodium inhibition to methanogens in anaerobic treatment processes, *Electronic Journal of Environmental, Agricultural and Food Chemistry*, 3(6), pp. 769-776.

Bashir, B. H. and Matin, A. (2004b) Combined effect of potassium and magnesium on sodium toxicity in anaerobic treatment processes. *Electronic Journal of Environmental, Agricultural and Food Chemistry*, 4(1), pp. 827-834.

Bashir, B. H. and Matin, A. (2004c) Combined effect of calcium and sodium on potassium toxicity in anaerobic treatment processes. *Electronic Journal of Environmental, Agricultural and Food Chemistry*, 3(2), pp. 670-676

Borja, R., Sanchez, E. and Weiland, P. (1996) Influence of ammonia concentration on thermophilic anaerobic digestion of cattle manure in upflow anaerobic sludge blanket (UASB) reactors. *Process Biochemistry*, 31(5), pp. 477-483.

Braga, A., Carvalho, A. and Ludermir, T. (2000) *Redes Neurais Artificiais – Teoria e Aplicações*.

Broderick, T. A. E and Sherrard, J. H. (1985) Treatment of nutrient deficient wastewaters. *J. Water Pollut. Control Fed.*, 57(12), pp. 1178-1181.

Cavaleiro, A. J. (1999) Efeito de Sobrecargas de ácido oleico na actividade de consórcios microbianos anaeróbios desenvolvidos em processos de leito fixo. Universidade do Minho, Dissertação de Mestrado, Braga.

Carvalho, A. (1998) Modelagem de um reator anaeróbio de manta de lodo utilizando redes neurais artificiais. Escola de Engenharia, UFMG.

Chen Y., Cheng J. J. and Creamer K. S. (2008) Inhibition of anaerobic digestion process: a review. *Bioresource Technology*, 99, pp. 4044–4064.

Costa, T., Heneine, M., Ribeiro, P., Santana, D. (2007) “Operação, Monitoramento e Manutenção da Estação de Tratamento de Esgotos na Embrapa Milho e Sorgo”, Empresa Brasileira de Pesquisa Agropecuária, Centro Nacional de Pesquisa de Milho e Sorgo, Ministério da Agricultura, Pecuária e Abastecimento, Sete Lagoas.

Delorme, A. J. and Kapuscinski, R. B. (1990) On performing experimental studies on transient states of continuousflow methanogenic reactors. *Biotechnology and Bioengineering*, 35, pp. 746-750.

El-Mashad, H. M., Zeeman, G., van Loon, W. K. P., Bot, G. P. A. and Lettinga, G. (2004) Effect of temperature and temperature fluctuation on thermophilic anaerobic digestion of cattle manure. *Bioresource Technology*, 95(2), pp. 191–201.

Florindo, F. (2009) Caracterização das lamas geradas e a sua valorização nos subsistemas dos SMAS-Sintra, Universidade Técnica de Lisboa, Dissertação de Mestrado, Lisboa.

Forage, R. G., Harrison, D. E. F. and Pitt, D. E. (1985) Effect of environment on microbial activity. In: *Comprehensive Biotechnology: The Principles, Applications and Regulations of Biotechnology in Industry, Agriculture and Medicine*, M. Moo-Young. (Ed), Pergamon Press, Oxford, U.K., 1, pp. 251-280.

Fukuzaki, S., Nishio, N., Shobayashi, M. E and Nagai, S. (1990) Inhibition of the fermentation of propionate to methane by hydrogen, acetate and propionate. *Appl. Environ. Microbiol.*, 56, pp. 719-723.

Galbiatti, J. A., Caramelo, A. D., Silva, F. G., Gerardi, E., Chiconato, D. A., (2010) Estudo quali-quantitativo do biogás produzido por substratos em biodigestores tipo batelada, *Revista Brasileira de Engenharia Agrícola e Ambiental*, 14(4), p.432–437.

Gomes, S. (2011) Análise da Viabilidade Económica da reutilização de águas residuais tratadas – O caso da ETAR do Ave. Universidade do Minho.

Gonçalves, I. M. (1988) Tratamento anaeróbio de efluentes líquidos. Trabalho de síntese com vista a apresentação de provas de capacidade científica. Universidade da Beira Interior, Departamento de Química, Covilhã.

Henze, M. and Harremões, P. (1983) Anaerobic treatment of wastewater in fixed film reactors - a literature review. *Water Science and Technology.*, 15, pp. 1-101.

Hwu, C. (1997) Enhancing anaerobic treatment of wastewaters containing oleic acid. Wageningen Agricultural University, Wageningen, The Netherlands.



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

Jin, P., Bhattacharya, S. K., Williams, C. J. and Zhang, H. (1998) Effects of sulfide addition on copper inhibition in methanogenic systems. *Water Research*, 32(4), pp. 977-988.

Jordão, E. P. e Pessoa, C. A, (1995) Tratamento de esgotos domésticos, 3ª Edição, ABES – Associação Brasileira de Engenharia Sanitária e Ambiental

Lau, I. W. and Fang, H. (1997) Effect of temperature shocks to thermophilic granules. *Water Res.*, 31(10), pp. 2626-2632.

Lema, J. M., Mendez, R., Soto, M. (1992) Bases cinéticas y microbiológicas en el diseño de digestores anaerobios. *Ingeniería Química*, Enero, pp. 191-201.

Lingireddy S. and Brion G. M., (2005) *Artificial Neural Networks in Water Supply Engineering*. ASCE. Reston, Virginia.

Mara, D. and Horan, N. (2003) *The handbook of water and wastewater microbiology*, Academic Press, University of Leeds, Reino Unido.

Martinelle, M., Hult, K. (1994) Kinetics of triglyceride lipases. in Woolley, S. (Ed.), *Lipases*. Cambridge University Press, Cambridge.

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

McInerney, M. J. (1988) Anaerobic hydrolysis and fermentation of fats. in Zehnder, (Ed.), *Biology of Anaerobic Microorganisms*. Wiley, New York, pp. 872.

McMahon, K. D., Stroot, P. G., Mackie, R. I. and Raskin, L. (2001) Anaerobic codigestion of municipal solid waste and biosolids under various mixing conditions- II: Microbial population dynamics. *Water Research*, 35(7), pp. 1817-1827.

Mechichi, T. and Sayadi, S. (2005) Evaluating process imbalance of anaerobic digestion of olive mill wastewaters. *Process Biochemistry*, 40(1), pp. 139-145.

Medeiros, M. (2006) Avaliação da Operacionalidade de uma E.T.E. com reator UASB utilizando rede neural no processo de gestão ambiental. Universidade Federal de Santa Catarina.

Metcalf & Eddy (2004) *Wastewater Engineering – Treatment and Reuse*. New York, 4th Edition, McGraw Hill.

Mosey, F. E., Fernandez, X. A. (1984) Mathematical modelling of methanogenesis in sewage sludge digestion. In: *Microbiological Methods for Environmental Biotechnology*, J.M. Graincher e J.M. Lynch (Eds.), Academic Press, New York 159-168.

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

Pereira, M. (2008) “Contributo para Avaliar a possibilidade de reutilização das areias removidas nas ETAR”, Universidade Nova de Lisboa.

Pompermayer R. S., Paula JR D. R. (2000) Estimativa do potencial brasileiro de produção de biogás através da biodigestão da vinhaça e comparação com outros energéticos.

Ribeiro, N. J. M. S. (1999) *Estudos Dinâmicos do Processo de Digestão Anaeróbia com vista ao Desenvolvimento de um Sistema Inteligente de Supervisão Baseado em Conhecimento*, Universidade do Minho, Dissertação de Mestrado.

Ribeiro, J. e Selau, L. (2009) Methodology for the construction and choice of credit risk prediction models. Universidade Federal do Rio Grande do Sul.

Rinzema, A., Boone, M., Van Knippenberg, K., Lettinga, G. (1994) Bactericidal effect of long chain fatty acids in anaerobic digestion. *Water Environment Res.*, 66(1), pp. 40-49.

Salomon, K. R. (2007) Avaliação Técnico-Econômica e Ambiental da Utilização do Biogás Proveniente da Biodigestão da Vinhaça em Tecnologias para Geração de Electricidade, Universidade Federal de Itajubá, Tese de Doutorado.

Silva, G. (2014) Workshop: Redes Neurais Artificiais: Modelação de Processos não lineares”, Lisboa.

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”, Universidade Nova de Lisboa, Dissertação de Mestrado.

Soto, M., Méndez, R., Lema, J. M. (1992) Diseño y operacion de digestores anaerobios. II. Operacion y control. *Ingeniería Química*.

Speece, R.E. (1983) Anaerobic biotechnology for industrial wastewater treatment. *Environment. Science and Technology.*, 17(9), pp. 416-427.

Speece, R. E. (1996) Toxicity response. In: *Anaerobic Biotechnology For Industrial Wastewaters*, R.E. Speece (Ed.), Vanderbilt University, Archae Press, USA, pp. 245-286.

Stroot, P. G., McMahon, K. D., Mackie, R. I. e Raskin, L. (2001) Anaerobic codigestion of municipal solid waste and biosolids under various mixing conditions - I. digester performance. *Water Research*, 35(7), pp. 1804-1816.

Van Lier, J. B. (1995) Thermophilic anaerobic wastewater treatment; Temperature aspects and process stability. Tese de doutoramento, Wageningen Agricultural University, Wageningen, Holanda.

Van Lier, J.B., Martin, J.L.S. and Lettinga, G. (1996) Effect of temperature on the anaerobic thermophilic conversion of volatile fatty acids by dispersed and granular sludge. *Wat. Res.*, 30(1), 199-207.

Vavilin, V. A. and Angelidaki, I. (2005) Anaerobic degradation of solid material: Importance of initiation centers for methanogenesis, mixing intensity, and 2D distributed model. *Biotechnology and Bioengineering*, 89(1), pp. 113-122

Vavilin, V. A., Fernandez, B., Palatsi, J. and Flotats, X. (2008) Hydrolysis kinetics in anaerobic degradation of particulate organic material: An overview. *Waste Management*, 28(6), pp. 939–951

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

Ward, A. J., Hobbs, P. J., Hollimen, P. J. and Jones, D. L. (2008) Optimisation of the anaerobic digestion of agricultural resources. *Bioresource Technology*, 99(17), pp. 7928–7940.

Zehnder, A. J. B., Huser, B. A., Brock, T. D. E and Wuhrmann, K. (1980) Characterization of an acetate decarboxylating, non-hydrogen-oxidizing methane bacterium. *Arch. Microbiol.*, 124, 1-11



## **ANEXOS**

Anexo I – Dados Fornecidos pela EFACEC ENGENHARIA – Exemplos

Anexo II – Bases de dados do Primeiro Conjunto de Redes

Anexo III – Compilação do Primeiro Conjunto de Redes

Anexo IV – Bases de dados do Segundo Conjunto de Redes

Anexo V – Compilação do Segundo Conjunto de Redes

Anexo VI – Previsão Instantânea para diferentes valores de Temperatura

Anexo VII – Comparação do biogás real com o biogás previsto pelas redes “A2” e “B15”

Anexo VIII – Previsão Instantânea para diferentes valores de Gorduras

Anexo IX – Conjunto de dados relativo a junho e julho de 2014



## **Anexo I**

### Dados Fornecidos pela EFACEC ENGENHARIA

Exemplos



Tabela 5. Dados Diários Fornecidos pela EFACEC ENGENHARIA relativos aos vários caudais que intervêm no tratamento de lamas – Exemplo: Mês de Outubro de 2012.

Dia	By-Pass à ETAR (I-1153)	Efluente Reutilizado (I-5356)	Elevação de Fossas Sêpticas (I-1451)	Escumas e Escorrências (I-1157)	Lamas Primárias para Espessador 1 (I-6153)	Lamas Primárias para Espessador 2 (I-6154)	Lamas 1 <sup>a</sup> espessadas para tanques de lamas mistas (I-6155)	Recirculação de Lamas - Linha 1 (I-4254)	Recirculação de Lamas - Linha 2 (I-4255)	Recirculação de Lamas - Linha 3 (I-4256)	Lamas em excesso - Linha 1 (I-4257)	Lamas em excesso - Linha 2 (I-4258)	Lamas em excesso - Linha 3 (I-4259)	Caudal lamas para espessamento mecânico- Linha 1 (I-6151)
	Caudal Diário (m <sup>3</sup> /dia)	Caudal Diário (m <sup>3</sup> /dia)	Caudal Diário (m <sup>3</sup> /dia)	Caudal Diário (m <sup>3</sup> /dia)	Caudal Diário (m <sup>3</sup> /dia)	Caudal Diário (m <sup>3</sup> /dia)	Caudal Médio Diário (m <sup>3</sup> /dia)	Caudal Médio Diário (m <sup>3</sup> /dia)	Caudal Médio Diário (m <sup>3</sup> /dia)	Caudal Médio Diário (m <sup>3</sup> /dia)	Caudal Médio Diário (m <sup>3</sup> /dia)	Caudal Médio Diário (m <sup>3</sup> /dia)	Caudal Médio Diário (m <sup>3</sup> /dia)	Caudal Médio Diário (m <sup>3</sup> /dia)
01-Out	0	352	0	2.234	137	128	173	1.395	10.539	10.364	2	388	399	377
02-Out	0	281	0	2.086	137	129	161	4.285	5.553	5.369	2	255	270	265
03-Out	0	292	0	2.800	141	132	170	6.492	5.322	5.083	2	286	292	268
04-Out	0	326	20	3.141	138	131	168	7.759	5.069	4.907	3	260	276	264
05-Out	0	347	0	3.456	133	130	169	8.123	5.178	4.944	2	373	436	421
06-Out	0	382	0	3.508	61	134	170	7.192	5.206	5.045	1	322	286	381
07-Out	0	299	0	3.276	217	132	169	6.863	4.945	4.819	1	297	321	318
08-Out	0	357	0	2.931	136	128	168	0	8.891	1.684	2	390	260	307
09-Out	0	199	0	3.160	136	130	167	0	13.049	1.044	29	79	6	56
10-Out	0	166	0	2.904	144	133	169	0	8.407	0	1	5	3	1
11-Out	0	115	0	3.209	125	122	97	0	7.705	0	-19	5	12	11
12-Out	0	163	0	2.869	117	122	85	0	7.911	0	42	3	3	7
13-Out	0	135	0	2.984	115	139	88	0	16.226	6.874	2	2	1	1
14-Out	0	158	0	3.278	120	112	84	0	16.735	10.494	2	9	19	14
15-Out	0	102	0	3.110	120	122	85	0	5.294	308	48	29	8	47
16-Out	0	238	15	2.733	126	123	86	0	15.429	11.438	6	506	1	5
17-Out	0	155	0	2.653	113	120	75	0	29.577	5.569	176	34	0	174
18-Out	0	123	0	2.739	123	118	72	0	22.165	1.076	36	48	0	38
19-Out	0	75	0	2.521	119	118	66	0	14.098	992	2	1	1	1
20-Out	0	198	0	2.858	119	117	69	0	14.893	6	1	258	0	0
21-Out	0	154	0	2.583	121	131	72	0	17.650	1.891	2	196	0	1
22-Out	0	117	0	2.896	117	123	66	0	24.672	8.182	1	231	1	0
23-Out	0	145	0	2.656	119	120	68	0	10.659	0	2	224	0	0
24-Out	0	166	11	2.995	118	117	67	0	21.992	3.725	71	37	0	31
25-Out	0	113	12	2.710	114	123	68	0	24.852	9.952	2	2	0	1
26-Out	0	89	0	2.616	115	129	67	1.015	27.955	13.995	1	2	0	0
27-Out	0	164	0	3.143	123	141	72	0	28.350	3.431	2	295	1	2
28-Out	0	167	0	2.186	113	137	68	0	26.841	1.600	1	295	0	0
29-Out	0	119	0	2.626	118	135	68	0	14.877	6.922	1	39	0	0
30-Out	0	83	0	2.510	119	126	68	0	18.955	6.071	0	3	0	1
31-Out	0	123	0	2.681	119	126	68	308	10.339	0	254	3	0	225

Continuação da Tabela 5. Dados Diários Fornecidos pela EFACEC ENGENHARIA relativos aos vários caudais que intervêm no tratamento de lamas - Exemplo: Mês de Outubro de 2012.

Dia	Caudal lamas para espessamento mecânico- Linha 2 (I-6152)	Caudal poli para espessamento mecânico- Linha 1 (I-6260a)	Caudal poli para espessamento mecânico- Linha 2 (I-6260b)	Lamas espessadas para digestor 1 (I-6352)	Lamas espessadas para digestor 2 (I-6353)	Caudal lamas para desidratação - Linha 1 (I-8151)	Caudal lamas para desidratação - Linha 2 (I-8152)	Caudal poli para desidratação- Linha 1 (I-8158)	Caudal poli para desidratação- Linha 2 (I-8159)	Caudal de Biogás para a tocha (I-7564)	Caudal de Biogás para a caldeira (I-7565)	Caudal de Biogás para os co-geradores e caldeira (I-7651)
	Caudal Médio Diário (m <sup>3</sup> /dia)	Caudal Médio Diário (l/dia)	Caudal Médio Diário (l/dia)	Caudal Médio Diário (m <sup>3</sup> /dia)	Caudal Médio Diário (m <sup>3</sup> /dia)	Caudal Médio Diário (m <sup>3</sup> /dia)	Caudal Médio Diário (m <sup>3</sup> /dia)	Caudal Médio Diário (l/dia)	Caudal Médio Diário (l/dia)	Caudal Médio Diário (l/dia)	Caudal Médio Diário (l/dia)	Caudal Médio Diário (l/dia)
01-Out	363	5.280	5.556	106	108	150	0	17.299	0	0	0	1.417
02-Out	274	5.076	5.268	111	114	32	156	3.764	18.083	0	0	1.476
03-Out	290	4.701	5.023	134	137	178	76	19.643	8.555	0	0	1.481
04-Out	300	4.945	5.345	118	121	314	0	34.371	0	0	0	1.428
05-Out	306	6.907	5.862	128	124	96	145	10.625	23.209	0	0	1.551
06-Out	280	6.176	5.280	111	119	0	347	0	31.069	0	0	1.305
07-Out	313	4.777	5.059	109	112	0	236	0	26.319	0	0	1.304
08-Out	318	5.506	5.969	105	107	0	222	0	24.355	0	0	1.413
09-Out	59	985	1.119	84	86	53	0	5.690	0	0	0	1.225
10-Out	2	0	0	86	87	256	0	27.859	0	0	0	1.175
11-Out	12	157	179	50	50	201	0	22.119	0	0	0	1.130
12-Out	8	256	290	39	38	0	0	0	0	0	0	736
13-Out	1	0	0	41	42	0	0	0	0	0	0	699
14-Out	14	276	320	44	44	340	37	36.950	3.842	0	0	872
15-Out	34	0	622	54	55	0	0	0	1	0	0	1.040
16-Out	505	0	11.217	69	71	0	0	0	0	0	0	1.255
17-Out	32	0	509	124	130	0	233	0	24.285	136	486	519
18-Out	44	0	821	45	47	66	0	7.099	47	449	219	1.780
19-Out	1	0	0	33	34	0	0	0	0	0	0	1.216
20-Out	255	0	5.935	38	40	306	0	33.535	0	0	0	926
21-Out	194	0	4.774	32	31	0	0	0	0	0	0	828
22-Out	235	0	3.516	36	38	0	0	0	0	0	0	913
23-Out	212	0	3.928	41	42	108	0	11.829	0	0	0	909
24-Out	81	0	3.456	54	55	146	0	16.794	0	0	0	876
25-Out	1	0	0	30	32	115	0	14.182	0	0	32	524
26-Out	1	0	0	29	31	33	64	4.098	7.993	0	0	1.539
27-Out	292	0	5.205	1	0	0	0	0	0	0	0	0
28-Out	289	0	5.798	57	60	0	0	0	0	0	0	1.178
29-Out	43	0	881	43	44	19	0	3.373	0	0	220	2.200
30-Out	1	0	0	21	22	15	0	726	0	0	0	61
31-Out	28	0	830	90	94	0	133	0	16.247	0	0	1.668

Existem tabelas semelhantes a esta relativas aos meses de Janeiro de 2012 a Julho de 2014.

Tabela 6. Dados Semanais Fornecidos pela EFACEC ENGENHARIA relativos aos parâmetros pH, ST, SV, %SV/ST,%matéria seca, AGV e Alcalinidade – Exemplo: Mês de Outubro de 2012.

Data		03-Out	11-Out	16-Out	24-Out	
Lamas Primárias	Linha 1	pH (escala Sörensen)	6,79	6,90	6,61	6,66
		ST (g/L)	14,8	5,2	30,0	21,9
		SV (g/L)	11,3	3,4	21,7	16,7
		%SV/ST	76%	65%	72%	76%
		% Matéria Seca	1,5%	0,5%	3,0%	2,2%
Lamas Primárias	Linha 2	pH (escala Sörensen)	7,09	6,64	6,52	6,71
		ST (g/L)	4,7	20,4	25,6	18,5
		SV (g/L)	3,2	16,0	18,9	14,6
		%SV/ST	68%	78%	74%	79%
		% Matéria Seca	0,5%	2,0%	2,6%	1,9%
Lamas Primárias	Linha 3	pH (escala Sörensen)	6,75	6,61	6,48	6,74
		ST (g/L)	18,1	22,8	27,2	17,5
		SV (g/L)	14,2	18,0	20,3	13,8
		%SV/ST	78%	79%	75%	79%
		% Matéria Seca	1,8%	2,3%	2,7%	1,8%
Lamas Primárias Espessadas	Linha 1	pH (escala Sörensen)	6,57	6,47	6,12	5,37
		ST (g/L)	18,2	20,3	27,7	39,4
		SV (g/L)	14,3	15,9	21,8	30,2
		%SV/ST	79%	78%	79%	77%
		% Matéria Seca	1,8%	2,0%	2,8%	3,9%
Lamas Primárias Espessadas	Linha 2	pH (escala Sörensen)	6,55	6,46	6,13	5,44
		ST (g/L)	18,7	17,3	27,8	38,6
		SV (g/L)	14,9	13,7	21,6	29,7
		%SV/ST	80%	79%	78%	77%
		% Matéria Seca	1,9%	1,7%	2,8%	3,9%
Lamas Sec. Recirculação/Excesso	Linha 2	pH (escala Sörensen)	6,80	6,89	6,82	6,82
		ST (g/L)	6,5	5,5	3,9	3,7
		SV (g/L)	4,8	4,3	2,4	2,8
		%SV/ST	74%	78%	62%	76%
		% Matéria Seca	0,7%	0,6%	0,4%	0,4%
Lamas Sec. Recirculação/Excesso	Linha 3	pH (escala Sörensen)	6,82	-	-	-
		ST (g/L)	7,2	-	-	-
		SV (g/L)	5,5	-	-	-
		%SV/ST	76%	-	-	-
		% Matéria Seca	0,7%	-	-	-
Entrada do Tambor de Espessamento		pH (escala Sörensen)	6,81	-	6,72	6,66
		ST (g/L)	6,1	-	7,1	5,9
		SV (g/L)	4,6	-	5,3	4,6
		%SV/ST	75%	-	75%	78%
		% Matéria Seca	0,6%	-	0,7%	0,6%

Continuação da Tabela 6. Dados Semanais Fornecidos pela EFACEC ENGENHARIA relativos aos parâmetros pH, ST, SV, %SV/ST,%matéria seca, AGV e Alcalinidade – Exemplo: Mês de Outubro de 2012.

Data		03-Out	11-Out	16-Out	24-Out
<b>Lamas Biológicas Espessadas Tambor Linha 1</b>	pH (escala Sörensen)	6,65	-	-	-
	ST (g/L)	33,6	-	-	-
	SV (g/L)	23,1	-	-	-
	%SV/ST	69%	-	-	-
	% Matéria Seca	3,4%	-	-	-
<b>Lamas Biológicas Espessadas Tambor Linha 2</b>	pH (escala Sörensen)	6,61	-	6,46	6,51
	ST (g/L)	32,90	-	40,10	32,00
	SV (g/L)	21,90	-	26,80	22,80
	%SV/ST	67%	-	67%	71%
	% Matéria Seca	3,3%	-	4,0%	3,2%
<b>Lamas Mistas Espessadas</b>	pH (escala Sörensen)	5,74	-	5,53	5,27
	ST (g/L)	33,0	-	37,8	31,9
	SV (g/L)	24,3	-	28,1	23,9
	%SV/ST	74%	-	74%	75%
	% Matéria Seca	3,3%	-	3,8%	3,2%
<b>Lamas Digestor Linha 1</b>	pH (escala Sörensen)	7,15	7,33	7,15	7,13
	ST (g/L)	16,4	15,0	14,7	16,4
	SV (g/L)	11,5	10,7	10,4	11,4
	%SV/ST	70%	71%	71%	70%
	% Matéria Seca	1,6%	1,5%	1,5%	1,6%
	Alcalinidade (mgCaCO <sub>3</sub> /L)	3.089	3.062	3.009	3.035
	Ácidos Gordos Voláteis (mgCaCO <sub>3</sub> /L)	757	653	693	667
<b>Lamas Digestor Linha 2</b>	pH (escala Sörensen)	7,15	7,21	7,11	7,13
	ST (g/L)	16,5	15,2	14,7	16,4
	SV (g/L)	11,6	10,9	10,4	11,4
	%SV/ST	70%	72%	71%	70%
	% Matéria Seca	1,7%	1,5%	1,5%	1,6%
	Alcalinidade (mgCaCO <sub>3</sub> /L)	3.062	3.115	3.062	3.089
	Ácidos Gordos Voláteis (mgCaCO <sub>3</sub> /L)	980	973	987	960
<b>Lamas Digeridas</b>	pH (escala Sörensen)	7,25	7,16	7,25	7,14
	ST (g/L)	16,2	20,9	15,1	27,0
	SV (g/L)	10,8	14,7	10,4	19,4
	%SV/ST	67%	70%	69%	72%
	% Matéria Seca	1,6%	2,1%	1,5%	2,7%
<b>Lamas desidratadas</b>	pH (escala Sörensen)	8,01	7,96	7,95	7,68
	ST (g/L)	193	245	213	202
	SV (g/L)	143	182	150	148
	%SV/ST	74%	74%	70%	73%
	% Matéria Seca	19,3%	24,5%	21,3%	20,2%

Existem tabelas semelhantes a esta, relativas aos meses de Janeiro de 2012 a julho de 2014.

Tabela 7. Dados Fornecidos pela EFACEC ENGENHARIA relativos aos parâmetros de qualidade do biogás – Exemplo: Mês de Outubro de 2012.

	Biogás - digestor 1			Biogás - digestor 2		
	CH <sub>4</sub> (%)	CO <sub>2</sub> (%)	H <sub>2</sub> S (ppm)	CH <sub>4</sub> (%)	CO <sub>2</sub> (%)	H <sub>2</sub> S (ppm)
01-Out	69,2%	33,9%	2.989	69,4%	33,8%	2.345
02-Out	68,4%	35,6%	3.126	68,5%	35,3%	2.531
03-Out	68,3%	35,8%	4.831	68,2%	35,6%	2.851
04-Out	68,5%	35,5%	4.321	68,6%	35,3%	2.711
08-Out	69,3%	34,6%	3.903	69,0%	34,8%	2.411
09-Out	69,5%	35,1%	3.845	69,3%	35,5%	2.321
10-Out	68,6%	35,0%	1.924	67,8%	35,4%	2.031
11-Out	68,8%	35,2%	1.812	68,0%	35,9%	1.949
12-Out	69,2%	34,7%	1.536	68,9%	34,9%	1.821
15-Out	68,5%	36,1%	1.531	68,5%	35,6%	1.615
16-Out	68,4%	35,6%	1.671	68,6%	35,4%	1.734
22-Out	69,2%	34,6%	1.612	69,0%	34,7%	1.724
23-Out	69,3%	34,6%	1.524	69,1%	34,7%	1.631
26-Out	68,9%	33,7%	1.603	69,0%	33,7%	1.734
30-Out	69,1%	33,6%	1.456	69,2%	33,4%	1.563
31-Out	69,1%	33,0%	1.631	69,3%	32,9%	1.784

Tabela 8. Dados Diários Fornecidos pela EFACEC ENGENHARIA relativos à temperatura dos digestores – Exemplo: Mês de Outubro de 2012.

	Temperatura	
	Digestor 1	Digestor 2
01-Out	38,0	38,0
02-Out	38,0	38,0
03-Out	38,0	38,0
04-Out	38,0	38,0
05-Out	38,0	38,0
06-Out	38,0	38,0
07-Out	38,0	38,0
08-Out	38,0	38,0
09-Out	38,0	38,0
10-Out	38,0	38,0
11-Out	38,0	38,0
12-Out	38,0	38,0
13-Out	38,0	38,0
14-Out	38,0	38,0
15-Out	38,0	38,0
16-Out	38,0	38,0
17-Out	38,0	38,0
18-Out	38,0	38,0
19-Out	38,0	38,0
20-Out	38,0	38,0
21-Out	38,0	38,0
22-Out	38,0	38,0
23-Out	38,0	38,0
24-Out	38,0	38,0
25-Out	38,0	38,0
26-Out	38,0	38,0
27-Out	38,0	38,0
28-Out	38,0	38,0
29-Out	38,0	38,0
30-Out	38,0	38,0
31-Out	38,0	38,0

Tabela 9. Dados Diários Fornecidos pela EFACEC ENGENHARIA relativos às gorduras adicionadas nos digestores – Exemplo: Mês de Maio de 2013.

	Gorduras	
	Digestor 1	Digestor 2
1-Mai	0,00	0,00
2-Mai	0,00	15,18
3-Mai	0,00	15,18
4-Mai	0,00	15,18
5-Mai	0,00	15,18
6-Mai	0,00	15,18
7-Mai	1,00	3,50
8-Mai	0,00	0,00
9-Mai	0,00	0,00
10-Mai	0,00	0,00
11-Mai	0,00	0,00
12-Mai	0,00	0,00
13-Mai	0,00	0,00
14-Mai	0,00	0,00
15-Mai	0,00	0,00
16-Mai	3,80	0,00
17-Mai	0,50	0,00
18-Mai	0,00	2,40
19-Mai	0,00	0,00
20-Mai	0,00	0,00
21-Mai	2,70	0,00
22-Mai	0,00	0,60
23-Mai	0,00	0,00
24-Mai	0,50	0,00
25-Mai	0,00	0,40
26-Mai	0,00	0,00
27-Mai	0,50	0,00
28-Mai	0,60	0,50
29-Mai	0,00	0,00
30-Mai	0,00	0,60
31-Mai	0,00	0,90

## **Anexo II**

### Bases de Dados do Primeiro Conjunto de Redes



Tabela 10. Base de Dados sem gorduras.

Dia	SV - TLMistas	Q entrada (dig 1 + Dig 2)	pH (média)	Temperatura (média)	AGV Global	Alcalinidade Global	Biogás Total (m3/dia)
3-Jan-12	15,82	86	7,16	37,00	1107	1820	813
18-Jan-12	17,30	187	7,16	37,00	253	1425	1354
24-Jan-12	20,07	185	7,47	38,00	1867	2175	1478
31-Jan-12	15,90	148	7,02	34,00	258	1034	857
7-Fev-12	19,67	71	7,30	38,00	170	2163	376
22-Fev-12	14,02	172	7,18	34,00	198	1671	324
28-Fev-12	13,20	128	6,80	32,00	228	1017	86
6-Mar-12	16,60	36	6,94	34,00	348	2770	554
14-Mar-12	21,30	68	6,77	35,00	1619	2142	743
27-Mar-12	22,84	28	6,79	38,00	978	3488	911
3-Abr-12	27,10	30	7,20	36,00	1093	3355	494
20-Abr-12	21,80	65	7,68	37,00	667	4154	1171
26-Abr-12	23,90	96	7,40	32,00	547	4047	816
4-Mai-12	24,90	73	7,63	37,00	693	3781	995
9-Mai-12	26,70	103	7,82	38,00	787	3728	462
16-Mai-12	28,40	166	7,36	38,00	400	3728	861
24-Mai-12	20,60	81	7,27	38,00	400	3594	1099
29-Mai-12	16,70	156	7,51	37,00	387	3621	1447
5-Jun-12	14,10	124	7,38	37,00	427	3754	527
14-Jun-12	28,20	153	7,38	36,00	507	3728	1188
20-Jun-12	20,90	132	7,25	37,00	413	3594	1606
29-Jun-12	11,60	152	7,16	37,00	387	3674	339
5-Jul-12	20,30	148	7,33	36,00	413	3488	1099
19-Jul-12	18,60	162	7,34	37,00	233	3568	1717
27-Jul-12	14,70	383	7,48	37,00	213	3408	1879
17-Ago-12	18,20	162	6,84	35,00	824	2995,5	1376
23-Ago-12	23,40	304	7,02	38,00	769	2942,5	2564
30-Ago-12	16,50	343	7,09	38,00	772	2929	2201
6-Set-12	22,20	323	7,25	38,00	328	2995	3114
12-Set-12	20,50	315	7,32	38,00	301	2929	3103
19-Set-12	16,50	328	7,18	38,00	296,5	2928,5	1496
26-Set-12	21,00	294	7,23	38,00	872,5	3141,5	6251
3-Out-12	24,30	271	7,15	38,00	868,5	3075,5	1481
16-Out-12	28,10	140	7,13	38,00	840	3035,5	1255
24-Out-12	23,90	109	7,13	38,00	813,5	3062	876
1-Nov-12	22,30	211	7,15	37,00	886,5	3527,5	1841
8-Nov-12	22,80	377	7,09	38,00	860	3514,5	1876
14-Nov-12	16,90	98	7,15	38,00	800	3448	1050
21-Nov-12	44,70	97	7,19	38,00	773,5	3408	1146
30-Nov-12	36,50	60	7,22	38,00	813,5	3434,5	694
6-Dez-12	9,20	67	7,27	37,50	826,5	3514,5	855
12-Dez-12	36,70	79	7,39	37,50	866,5	3594,5	918
20-Dez-12	35,40	68	7,34	38,00	860	3581	1157
26-Dez-12	13,20	118	7,44	38,00	873,5	3554,5	1590

Continuação da Tabela 10. Base de dados sem gorduras.

<b>Dia</b>	<b>SV - TLMistas</b>	<b>Q entrada (dig 1 + Dig 2)</b>	<b>pH (média)</b>	<b>Temperatura (média)</b>	<b>AGV Global</b>	<b>Alcalinidade Global</b>	<b>Biogás Total (m3/dia)</b>
2-Jan-13	31,10	67	7,32	37,00	900	3634	995
10-Jan-13	7,30	159	7,36	37,00	416,5	4300	1618
18-Jan-13	17,90	54	7,39	37,00	386,5	4340	1028
28-Jan-13	15,70	56	7,32	37,00	393,5	4340	0
11-Fev-13	21,30	72	7,41	36,50	420	4406,5	1236
22-Fev-13	23,20	129	7,39	36,50	220	4699,5	2026
1-Mar-13	23,70	59	7,83	37,50	563	5032,5	1382
8-Mar-13	37,20	33	8,01	37,50	460	5405	771
21-Mar-13	28,00	103	7,60	38,00	493	5471,5	916
4-Abr-13	16,80	62	7,49	36,00	217	5219	683
12-Abr-13	45,50	44	7,54	36,00	286,5	5232	1191
19-Abr-13	53,20	138	7,31	36,00	246,5	5298,5	1062
22-Abr-13	2,80	180	7,53	36,00	266,5	5165,5	1324
3-Mai-13	38,00	85	7,52	36,75	306,5	5232	662
8-Mai-13	19,10	299	7,25	36,75	183	5285	1987
13-Mai-13	20,80	190	7,43	36,75	386,5	4606	967
20-Mai-13	30,70	135	7,43	36,75	1900	4712,5	1174
28-Mai-13	10,10	170	7,55	36,75	817	4766	937
3-Jun-13	14,00	208	7,22	37,30	473,5	4712,5	817
12-Jun-13	23,90	257	7,26	37,30	447	4739,5	5767
19-Jun-13	30,10	225	7,11	37,30	526,5	4619,5	2019
10-Jul-13	3,60	98	7,26	38,20	426,5	4686	1354
16-Jul-13	16,40	232	7,20	38,20	433	4686	3859
24-Jul-13	13,30	300	7,24	38,20	440	4712,5	2395
30-Jul-13	18,80	293	7,19	38,20	447	4712,5	4532
05-Ago-13	17,90	334	7,10	37,75	520	4606	6364
13-Ago-13	32,80	285	7,03	37,25	500	4566	2097
20-Ago-13	39,50	257	7,08	37,75	513,5	4619,5	2279
29-Ago-13	25,20	242	7,25	37,93	453	4340	3923
04-Set-13	39,00	185	7,33	37,93	433	4060,5	1422
10-Set-13	18,80	184	7,10	37,93	340	4406,5	1281
24-Set-13	19,80	145	7,37	37,93	412,5	3821	669
01-Out-13	24,40	115	7,14	37,93	680	4313,5	654
10-Out-13	10,60	37	7,25	37,93	432	4033,5	708
15-Out-13	22,40	109	7,29	37,93	401	3874	847
23-Out-13	25,90	139	7,25	37,93	430,5	4007,5	302
31-Out-13	19,90	102	7,46	37,93	515	4246,5	641
07-Nov-13	18,00	145	7,25	37,93	452	4073,5	387
12-Nov-13	20,10	112	7,65	37,93	424,5	4579,5	597
19-Nov-13	20,90	116	7,42	37,93	373	4353	497
27-Nov-13	23,80	38	7,26	37,93	433,5	4087	340
04-Dez-13	21,90	67	7,33	37,93	452	4047	623
10-Dez-13	7,40	76	7,25	37,93	439	4047	665
18-Dez-13	12,10	73	7,48	37,93	450	4473	730

Continuação da tabela 10. Base de dados sem gorduras.

Dia	SV - TLMistas	Q entrada (dig 1 + Dig 2)	pH (média)	Temperatura (média)	AGV Global	Alcalinidade Global	Biogás Total (m3/dia)
2-Jan-14	26,20	73	7,44	37,10	373,5	4353	873
8-Jan-14	5,80	71	7,51	37,10	443	4460	496
14-Jan-14	19,30	45	7,43	37,10	458,5	4073,5	746
21-Jan-14	19,10	53	7,45	37,10	443	4473	531
29-Jan-14	48,60	57	7,44	37,10	434,5	4420	764
6-Fev-14	16,10	56	7,36	37,93	438	4326,5	688
12-Fev-14	43,40	51	7,38	37,93	441,5	4379,5	572
20-Fev-14	38,60	43	7,44	37,93	445,5	4420	746
27-Fev-14	40,90	56	7,52	37,93	436,5	4499,5	989
7-Mar-14	43,90	53	7,36	37,94	307	4207	663
14-Mar-14	16,20	63	7,33	38,01	433,5	4167	442
19-Mar-14	28,20	145	7,46	37,93	433,5	4433	0
27-Mar-14	48,50	70	7,49	37,66	453	4473	1065
3-Abr-14	19,90	58	7,29	37,27	446,5	4167	798
10-Abr-14	20,05	120	7,33	37,00	420	4113,5	593
15-Abr-14	21,92	157	7,34	36,80	630	5059	1118
23-Abr-14	11,80	167	7,56	36,86	657,5	4925,5	493
29-Abr-14	3,25	91	7,33	35,93	1005,5	4366,5	786
6-Mai-14	16,55	147	7,35	35,75	1053	4433	359
21-Mai-14	47,40	86	7,33	37,60	1053,5	4420	1019
28-Mai-14	35,70	113	7,46	38,03	762	4553	855

Tabela 11. Base de dados com gorduras.

Dia	SV g/L (TLMistas)	Q entrada m <sup>3</sup> /dia (dig 1 + Dig 2)	pH (média)	Temperatura °C (média)	Gorduras m <sup>3</sup> /dia	AGV Global mgCaCO <sub>3</sub> /L	Alcalinidade Global mgCaCO <sub>3</sub> /L	Biogás Total m <sup>3</sup> /dia
22-Abr-13	2,8	180	7,53	36,0	0	266,5	5165,5	1324
3-Mai-13	38,0	85	7,52	36,8	15,18	306,5	5232	662
8-Mai-13	19,1	299	7,25	36,8	0	183	5285	1987
13-Mai-13	20,8	190	7,43	36,8	0	386,5	4606	967
20-Mai-13	30,7	135	7,43	36,8	0	1900	4712,5	1174
28-Mai-13	10,1	170	7,55	36,8	1,1	817	4766	937
3-Jun-13	14,0	208	7,22	37,3	1,2	473,5	4712,5	817
12-Jun-13	23,9	257	7,26	37,3	0,8	447	4739,5	5767
19-Jun-13	30,1	225	7,11	37,3	0	526,5	4619,5	2019
10-Jul-13	3,6	98	7,26	38,2	0	426,5	4686	1354
16-Jul-13	16,4	232	7,20	38,2	2,8	433	4686	3859
24-Jul-13	13,3	300	7,24	38,2	0	440	4712,5	2395
30-Jul-13	18,8	293	7,19	38,2	0,6	447	4712,5	4532
05-Ago-13	17,9	334	7,10	37,8	0,9	520	4606	6364
13-Ago-13	32,8	285	7,03	37,3	0,5	500	4566	2097
20-Ago-13	39,5	257	7,08	37,8	0	513,5	4619,5	2279
29-Ago-13	25,2	242	7,25	37,9	0,4	453	4340	3923
04-Set-13	39,0	185	7,33	37,9	0	433	4060,5	1422
10-Set-13	18,8	184	7,10	37,9	6	340	4406,5	1281
24-Set-13	19,8	145	7,37	37,9	0,8	412,5	3821	669
01-Out-13	24,4	115	7,14	37,9	3,9	680	4313,5	654
10-Out-13	10,6	37	7,25	37,9	10,7	432	4033,5	708
15-Out-13	22,4	109	7,29	37,9	9,8	401	3874	847
23-Out-13	25,9	139	7,25	37,9	2,3	430,5	4007,5	302
31-Out-13	19,9	102	7,46	37,9	2,1	515	4246,5	641
07-Nov-13	18,0	145	7,25	37,9	0	452	4073,5	387
12-Nov-13	20,1	112	7,65	37,9	23	424,5	4579,5	597
19-Nov-13	20,9	116	7,42	37,9	4,4	373	4353	497
27-Nov-13	23,8	38	7,26	37,9	0	433,5	4087	340
04-Dez-13	21,9	67	7,33	37,9	0	452	4047	623
10-Dez-13	7,4	76	7,25	37,9	20,95	439	4047	665
18-Dez-13	12,1	73	7,48	37,9	2,6	450	4473	730

Continuação da tabela 11. Base de dados com gorduras.

2-Jan-14	26,2	73	7,44	37,1	1,3	373,5	4353	873
8-Jan-14	5,8	71	7,51	37,1	0,9	443	4460	496
14-Jan-14	19,3	45	7,425	37,1	3,4	458,5	4073,5	746
21-Jan-14	19,1	53	7,45	37,1	6,5	443	4473	531
29-Jan-14	48,6	57	7,435	37,1	2,5	434,5	4420	764
6-Fev-14	16,1	56	7,355	37,9	8,03	438	4326,5	688
12-Fev-14	43,4	51	7,38	37,9	8,03	441,5	4379,5	572
20-Fev-14	38,6	43	7,435	37,9	1,9	445,5	4420	746
27-Fev-14	40,9	56	7,515	37,9	1,4	436,5	4499,5	989
7-Mar-14	43,9	53	7,36	37,9	0	307	4207	663
14-Mar-14	16,2	63	7,33	38,0	1	433,5	4167	442
19-Mar-14	28,2	145	7,455	37,9	2,4	433,5	4433	0
27-Mar-14	48,5	70	7,485	37,7	24	453	4473	1065
3-Abr-14	19,9	58	7,29	37,3	22,3	446,5	4167	798
10-Abr-14	20,05	120	7,33	37,0	24,02	420	4113,5	593
15-Abr-14	21,92	157	7,34	36,8	0	630	5059	1118
23-Abr-14	11,8	167	7,56	36,9	0	657,5	4925,5	493
29-Abr-14	3,25	91	7,33	35,9	0	1005,5	4366,5	786
6-Mai-14	16,55	147	7,35	35,8	0	1053	4433	359
21-Mai-14	47,4	86	7,33	37,6	0	1053,5	4420	1019
28-Mai-14	35,7	113	7,46	38,0	0	762	4553	855

## **Anexo III**

### Compilação do Primeiro Conjunto de Redes

Tabela 12. Compilação do Primeiro Conjunto de Redes para a Base de dados sem gorduras.

Nome da Rede		1.1_RNA_1	1.1_RNA_2	1.1_RNA_3	1.1_RNA_4	1.1_RNA_5	1.1_RNA_6	1.1_RNA_7	1.1_RNA_8	1.1_RNA_9	1.1_RNA_10	1.1_RNA_11	1.1_RNA_12	1.1_RNA_13	1.1_RNA_14	1.1_RNA_15	1.1_RNA_16	1.1_RNA_17	
Configuração		Previsor linear	Previsor número de QMNN	Previsor número de QMNN	Previsor número de MLPN (3 nós)	Previsor número de MLPN (3 nós)	Previsor número de MLPN (3 nós)	Previsor número de QMNN	Previsor número de QMNN	Previsor número de MLPN (2 nós)	Previsor número de MLPN (2 nós)	Previsor número de MLPN (3 nós)	Previsor número de QMNN	Previsor número de MLPN (2 nós)	Previsor número de MLPN (nós: 4,4)	Previsor número de MLPN (nós: 5,5)	Previsor número de MLPN (nós: 6,6)	Previsor número de QMNN	
Variáveis (Impacto)	Dependentes	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	
	Independentes	SV	Q.ent (57,14%)	Q.ent (57,14%)	Q.ent (55,55%)	Q.ent (55,55%)	Q.ent (55,51%)	Q.ent (55,26%)	Q.ent (42,65%)	Q.ent (54,24%)	Q.ent (54,24%)	Q.ent (55,54%)	SV (55,55%)	SV (41,70%)	Temp. (51,51%)	Q.ent (50,70%)	Q.ent (57,52%)	Q.ent (42,65%)	
		Q.ent	AVD (24,5%)	AVD (24,5%)	pH (15,25%)	Alcal. (15,25%)	Alcal. (24,92%)	AVD (22,05%)	AVD (25,19%)	AVD (20,47%)	AVD (20,47%)	SV (15,75%)	Alcal. (25,09%)	Alcal. (21,49%)	SV (25,70%)	SV (50,49%)	pH (25,29%)	AVD (25,19%)	
		pH	Temp. (15,55%)	Temp. (15,55%)	SV (15,07%)	AVD (17,05%)	AVD (15,55%)	SV (14,02%)	Temp. (19,09%)	SV (15,55%)	SV (15,55%)	Temp. (15,55%)	Temp. (22,10%)	Temp. (20,51%)	Alcal. (22,09%)	AVD (20,15%)	SV (25,72%)	Temp. (19,09%)	
		Temp.	SV (12,91%)	SV (12,91%)	AVD (12,45%)	pH (14,54%)	pH (15,55%)	Temp. (15,55%)	SV (15,07%)	Temp. (11,90%)	Temp. (11,90%)	AVD (12,25%)	AVD (15,57%)	AVD (15,55%)	AVD (15,55%)	Temp. (15,70%)	Temp. (20,57%)	SV (15,07%)	
		AVD	pH (7,05%)	pH (7,05%)	Alcal. (10,92%)	Temp. (14,25%)	SV (9,57%)	Alcal. (11,09%)	-	-	-	-	-	-	-	-	-	-	-
Alcal.	Alcal. (0,50%)	Alcal. (0,50%)	Temp. (5,52%)	SV (14,15%)	Temp. (7,75%)	-	-	-	-	-	-	-	-	-	-	-	-		
Treino	Número de Casos	57	57	57	57	57	57	57	57	57	57	57	57	57	57	57	57	57	
	Erro médio	Quadrático	676,01	194,76	194,76	495,07	420,55	351,45	115,54	147,57	450,55	450,55	344,45	0	575,02	419,21	99,04	257,45	147,57
		Absoluto	451,54	115,45	115,45	335,57	277,95	251,29	55,55	151,45	351,05	351,05	245,45	0	422,12	271,57	51,95	159,17	151,45
	Desvio Padrão do erro absoluto	477,19	154,59	154,59	357,05	317,52	245,75	95,04	157,44	352,95	352,95	241,54	0	390,45	319,1	54,55	192,45	157,44	
	Previsões Inadequadas	57,47%	15,79%	15,79%	44,55%	35,55%	35,55%	5,75%	20,59%	44,55%	44,55%	35,55%	0%	50,57%	37,95%	5,05%	19,54%	20,59%	
Teste	Número de Casos	22	22	22	22	22	22	22	22	22	22	22	22	22	22	22	22	22	
	Erro médio	Quadrático	1205,55	1215,52	1215,52	1225,91	1552,49	1479,09	1259,9	1154,99	1449,04	1449,04	1415,59	1492,7	3350,17	1552,55	1451,45	1519,57	1154,99
		Absoluto	559,515	555,17	555,17	550,91	555,75	505,15	709,55	551,55	711,55	711,55	772,05	750,71	1445,55	905,55	550,59	1055,45	551,55
	Desvio Padrão do erro absoluto	1005,55	1015,25	1015,25	1055,05	1255,11	1340,74	1041	955,09	1252,42	1252,42	1155,59	1290,19	3055,55	1271,22	1155,4	1244,52	955,09	
	Previsões Inadequadas	45,45%	55,15%	55,15%	54,55%	50,00%	72,75%	59,09%	59,09%	50,00%	50,00%	50,00%	59,09%	55,54%	55,15%	55,54%	77,27%	59,09%	

Tabela 13. Compilação do Primeiro Conjunto de Redes para a Base de dados com gorduras.

Nome da Rede		1.2_RNA_1	1.2_RNA_2	1.2_RNA_3	1.2_RNA_4	1.2_RNA_5	1.2_RNA_6	1.2_RNA_7	1.2_RNA_8	
Configuração		Previsor numérico de GRNN	Previsor numérico de MLFN (3 nós)	Previsor numérico de GRNN	Previsor numérico de MLFN (3 nós)	Previsor numérico de GRNN	Previsor numérico de MLFN (2 nós)	Previsor numérico de GRNN	Previsor numérico de MLFN (nós: 4;4)	
Variáveis (impacto)	Dependentes	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	
	Independentes	Q ent (56,90%)	Alcal. (25,62%)	Q ent (53,99%)	Alcal. (24,03%)	Q ent (56,39%)	Q ent (30,88%)	SV (35,25%)	Q ent (43,00%)	
		SV (27,59%)	Q ent (21,26%)	Alcal. (21,77%)	AVG (18,09%)	SV (28,85%)	SV (28,30%)	Q ent (33,38%)	SV (19,73%)	
		Alcal. (13,37%)	AVG (15,36%)	SV (18,30%)	Gord. (16,88%)	Temp. (10,77%)	Gord. (26,61%)	AVG (26,30%)	AVG (19,65%)	
		Temp. (1,38%)	Temp. (12,38%)	Temp. (3,48%)	SV (15,44%)	Gord. (3,98%)	Temp. (14,21%)	Gord. (5,07%)	Gord. (17,61%)	
		AVG (0,70%)	Gord. (11,89)	Gord. (2,25%)	Q ent (14,40%)	-	-	-	-	
		Gord. (0,04%)	pH (8,89%)	AVG (0,22%)	Temp. (11,16%)	-	-	-	-	
pH (0,03%)	SV (4,59%)	-	-	-	-	-	-			
Treino	Número de Casos		42	42	42	42	42	42	42	
	Erro médio	Quadrático	235,66	165,52	297,93	133,1	287,04	335,29	174,5	90,14
		Absoluto	141,29	109,25	159,49	97,81	153,33	265,05	88,55	49,31
	Desvio Padrão do erro absoluto		188,61	124,34	251,65	90,27	242,65	205,36	150,37	75,45
	Previsões inadequadas		14,29%	16,67%	11,90%	21,43%	14,29%	42,86%	7,14%	7,14%
Teste	Número de Casos		11	11	11	11	11	11	11	
	Erro médio	Quadrático	562,43	1975,09	713,12	2356,48	608,6	1063,2	667,46	481,2
		Absoluto	434,72	1097,09	486,53	1457,13	466,73	764,23	519,15	399,8
	Desvio Padrão do erro absoluto		356,87	1642,53	521,37	1851,97	390,6	739,16	419,52	267,79
	Previsões inadequadas		72,73%	72,73%	54,55%	72,73%	63,64%	72,73%	63,64%	63,64%



## **Anexo IV**

### Bases de dados do Segundo Conjunto de Redes

Tabela 14. Base de dados sem gorduras.

Dia	SV g/L (TLMistas)	Q entrada m <sup>3</sup> /dia (dig 1 + Dig 2)	pH (média)	Temperatura °C (média)	AGV Global mgCaCO <sub>3</sub> /L	Alcalinidade Global mgCaCO <sub>3</sub> /L	Biogás Total media m <sup>3</sup> /dia
3-Jan-12	15,82	86	7,16	37,00	1107	1820	624,4
18-Jan-12	17,30	187	7,16	37,00	253	1425	1186,7
24-Jan-12	20,07	185	7,47	38,00	1867	2175	1171,7
31-Jan-12	15,90	148	7,02	34,00	258	1034	738,3
7-Fev-12	19,67	71	7,30	38,00	170	2163	807,3
22-Fev-12	14,02	172	7,18	34,00	198	1671	438,6
28-Fev-12	13,20	128	6,80	32,00	228	1017	244,7
6-Mar-12	16,60	36	6,94	34,00	348	2770	621,7
14-Mar-12	21,30	68	6,77	35,00	1619	2142	929,4
27-Mar-12	22,84	28	6,79	38,00	978	3488	813,9
3-Abr-12	27,10	30	7,20	36,00	1093	3355	538,6
20-Abr-12	21,80	65	7,68	37,00	667	4154	949,3
26-Abr-12	23,90	96	7,40	32,00	547	4047	791,6
4-Mai-12	24,90	73	7,63	37,00	693	3781	570,3
9-Mai-12	26,70	103	7,82	38,00	787	3728	719,0
16-Mai-12	28,40	166	7,36	38,00	400	3728	803,7
24-Mai-12	20,60	81	7,27	38,00	400	3594	1183,4
29-Mai-12	16,70	156	7,51	37,00	387	3621	1096,7
5-Jun-12	14,10	124	7,38	37,00	427	3754	774,6
14-Jun-12	28,20	153	7,38	36,00	507	3728	1322,7
20-Jun-12	20,90	132	7,25	37,00	413	3594	1715,0
29-Jun-12	11,60	152	7,16	37,00	387	3674	950,0
5-Jul-12	20,30	148	7,33	36,00	413	3488	924,7
19-Jul-12	18,60	162	7,34	37,00	233	3568	1608,1
27-Jul-12	14,70	383	7,48	37,00	213	3408	1550,9
17-Ago-12	18,20	162	6,84	35,00	824	2995,5	1402,4
23-Ago-12	23,40	304	7,02	38,00	769	2942,5	2061,0
30-Ago-12	16,50	343	7,09	38,00	772	2929	2128,0
6-Set-12	22,20	323	7,25	38,00	328	2995	2805,3
12-Set-12	20,50	315	7,32	38,00	301	2929	3500,7
19-Set-12	16,50	328	7,18	38,00	296,5	2928,5	3132,6
26-Set-12	21,00	294	7,23	38,00	872,5	3141,5	2418,4
3-Out-12	24,30	271	7,15	38,00	868,5	3075,5	1430,0
16-Out-12	28,10	140	7,13	38,00	840	3035,5	1138,0
24-Out-12	23,90	109	7,13	38,00	813,5	3062	798,4
1-Nov-12	22,30	211	7,15	37,00	886,5	3527,5	1393,7
8-Nov-12	22,80	377	7,09	38,00	860	3514,5	1273,6
14-Nov-12	16,90	98	7,15	38,00	800	3448	901,3
21-Nov-12	44,70	97	7,19	38,00	773,5	3408	828,4
30-Nov-12	36,50	60	7,22	38,00	813,5	3434,5	908,0
6-Dez-12	9,20	67	7,27	37,50	826,5	3514,5	760,6
12-Dez-12	36,70	79	7,39	37,50	866,5	3594,5	873,2
20-Dez-12	35,40	68	7,34	38,00	860	3581	1265,3
26-Dez-12	13,20	118	7,44	38,00	873,5	3554,5	1282,6

Continuação da tabela 14. Base de dados sem gorduras.

Dia	SV g/L (TLMistas)	Q entrada m <sup>3</sup> /dia (dig 1 + Dig 2)	pH (média)	Temperatura °C (média)	AGV Global mgCaCO <sub>3</sub> /L	Alcalinidade Global mgCaCO <sub>3</sub> /L	Biogás Total media m <sup>3</sup> /dia
2-Jan-13	31,10	67	7,32	37,00	900	3634	1037,7
10-Jan-13	7,30	159	7,36	37,00	416,5	4300	1216,3
18-Jan-13	17,90	54	7,39	37,00	386,5	4340	965,9
28-Jan-13	15,70	56	7,32	37,00	393,5	4340	585,9
11-Fev-13	21,30	72	7,41	36,50	420	4406,5	1074,6
22-Fev-13	23,20	129	7,39	36,50	220	4699,5	893,3
1-Mar-13	23,70	59	7,83	37,50	563	5032,5	830,7
8-Mar-13	37,20	33	8,01	37,50	460	5405	826,0
21-Mar-13	28,00	103	7,60	38,00	493	5471,5	1751,6
4-Abr-13	16,80	62	7,49	36,00	217	5219	506,1
12-Abr-13	45,50	44	7,54	36,00	286,5	5232	598,9
19-Abr-13	53,20	138	7,31	36,00	246,5	5298,5	1228,4
22-Abr-13	2,80	180	7,53	36,00	266,5	5165,5	1125,4
3-Mai-13	38,00	85	7,52	36,75	306,5	5232	807,3
8-Mai-13	19,10	299	7,25	36,75	183	5285	1089,7
13-Mai-13	20,80	190	7,43	36,75	386,5	4606	1060,0
20-Mai-13	30,70	135	7,43	36,75	1900	4712,5	1627,1
28-Mai-13	10,10	170	7,55	36,75	817	4766	942,7
3-Jun-13	14,00	208	7,22	37,30	473,5	4712,5	998,1
12-Jun-13	23,90	257	7,26	37,30	447	4739,5	2682,4
19-Jun-13	30,10	225	7,11	37,30	526,5	4619,5	1795,4
10-Jul-13	3,60	98	7,26	38,20	426,5	4686	2249,6
16-Jul-13	16,40	232	7,20	38,20	433	4686	2876,6
24-Jul-13	13,30	300	7,24	38,20	440	4712,5	2107,7
30-Jul-13	18,80	293	7,19	38,20	447	4712,5	3603,4
05-Ago-13	17,90	334	7,10	37,75	520	4606	5173,3
13-Ago-13	32,80	285	7,03	37,25	500	4566	2148,0
20-Ago-13	39,50	257	7,08	37,75	513,5	4619,5	1992,4
29-Ago-13	25,20	242	7,25	37,93	453	4340	1826,4
04-Set-13	39,00	185	7,33	37,93	433	4060,5	1617,7
10-Set-13	18,80	184	7,10	37,93	340	4406,5	1686,4
24-Set-13	19,80	145	7,37	37,93	412,5	3821	672,9
01-Out-13	24,40	115	7,14	37,93	680	4313,5	679,4
10-Out-13	10,60	37	7,25	37,93	432	4033,5	501,7
15-Out-13	22,40	109	7,29	37,93	401	3874	501,1
23-Out-13	25,90	139	7,25	37,93	430,5	4007,5	722,1
31-Out-13	19,90	102	7,46	37,93	515	4246,5	680,9
07-Nov-13	18,00	145	7,25	37,93	452	4073,5	588,6
12-Nov-13	20,10	112	7,65	37,93	424,5	4579,5	526,3
19-Nov-13	20,90	116	7,42	37,93	373	4353	539,1
27-Nov-13	23,80	38	7,26	37,93	433,5	4087	400,3
04-Dez-13	21,90	67	7,33	37,93	452	4047	583,9
10-Dez-13	7,40	76	7,25	37,93	439	4047	703,6
18-Dez-13	12,10	73	7,48	37,93	450	4473	942,7

Continuação da tabela 14. Base de dados sem gorduras.

Dia	SV g/L (TLMistas)	Q entrada m <sup>3</sup> /dia (dig 1 + Dig 2)	pH (média)	Temperatura °C (média)	AGV Global mgCaCO <sub>3</sub> /L	Alcalinidade Global mgCaCO <sub>3</sub> /L	Biogás Total media m <sup>3</sup> /dia
2-Jan-14	26,20	73	7,44	37,10	373,5	4353	1046,3
8-Jan-14	5,80	71	7,51	37,10	443	4460	616,6
14-Jan-14	19,30	45	7,43	37,10	458,5	4073,5	706,9
21-Jan-14	19,10	53	7,45	37,10	443	4473	667,1
29-Jan-14	48,60	57	7,44	37,10	434,5	4420	922,9
6-Fev-14	16,10	56	7,36	37,93	438	4326,5	695,3
12-Fev-14	43,40	51	7,38	37,93	441,5	4379,5	541,3
20-Fev-14	38,60	43	7,44	37,93	445,5	4420	736,7
27-Fev-14	40,90	56	7,52	37,93	436,5	4499,5	665,4
7-Mar-14	43,90	53	7,36	37,94	307	4207	776,9
14-Mar-14	16,20	63	7,33	38,01	433,5	4167	646,4
19-Mar-14	28,20	145	7,46	37,93	433,5	4433	876,6
27-Mar-14	48,50	70	7,49	37,66	453	4473	893,7
3-Abr-14	19,90	58	7,29	37,27	446,5	4167	862,1
10-Abr-14	20,05	120	7,33	37,00	420	4113,5	984,4
15-Abr-14	21,92	157	7,34	36,80	630	5059	1327,1
23-Abr-14	11,80	167	7,56	36,86	657,5	4925,5	916,9
29-Abr-14	3,25	91	7,33	35,93	1005,5	4366,5	735,9
6-Mai-14	16,55	147	7,35	35,75	1053	4433	512,0
21-Mai-14	47,40	86	7,33	37,60	1053,5	4420	1104,4
28-Mai-14	35,70	113	7,46	38,03	762	4553	1168,1

Tabela 15. Base de dados com gorduras.

<b>Dia</b>	<b>SV g/L (TLMistas)</b>	<b>Q entrada m<sup>3</sup>/dia (dig 1 + Dig 2)</b>	<b>pH (média)</b>	<b>Temperatura °C (média)</b>	<b>Gorduras m<sup>3</sup>/dia</b>	<b>AGV Global mgCaCO<sub>3</sub>/L</b>	<b>Alcalinidade Global mgCaCO<sub>3</sub>/L</b>	<b>Biogás Total média m<sup>3</sup>/dia</b>
22-Abr-13	2,8	180	7,53	36,0	0	266,5	5165,5	1125,4
3-Mai-13	38,0	85	7,52	36,8	15,18	306,5	5232	807,3
8-Mai-13	19,1	299	7,25	36,8	0	183	5285	1089,7
13-Mai-13	20,8	190	7,43	36,8	0	386,5	4606	1060,0
20-Mai-13	30,7	135	7,43	36,8	0	1900	4712,5	1627,1
28-Mai-13	10,1	170	7,55	36,8	1,1	817	4766	942,7
3-Jun-13	14,0	208	7,22	37,3	1,2	473,5	4712,5	998,1
12-Jun-13	23,9	257	7,26	37,3	0,8	447	4739,5	2682,4
19-Jun-13	30,1	225	7,11	37,3	0	526,5	4619,5	1795,4
10-Jul-13	3,6	98	7,26	38,2	0	426,5	4686	2249,6
16-Jul-13	16,4	232	7,20	38,2	2,8	433	4686	2876,6
24-Jul-13	13,3	300	7,24	38,2	0	440	4712,5	2107,7
30-Jul-13	18,8	293	7,19	38,2	0,6	447	4712,5	3603,4
05-Ago-13	17,9	334	7,10	37,8	0,9	520	4606	5173,3
13-Ago-13	32,8	285	7,03	37,3	0,5	500	4566	2148,0
20-Ago-13	39,5	257	7,08	37,8	0	513,5	4619,5	1992,4
29-Ago-13	25,2	242	7,25	37,9	0,4	453	4340	1826,4
04-Set-13	39,0	185	7,33	37,9	0	433	4060,5	1617,7
10-Set-13	18,8	184	7,10	37,9	6	340	4406,5	1686,4
24-Set-13	19,8	145	7,37	37,9	0,8	412,5	3821	672,9
01-Out-13	24,4	115	7,14	37,9	3,9	680	4313,5	679,4
10-Out-13	10,6	37	7,25	37,9	10,7	432	4033,5	501,7
15-Out-13	22,4	109	7,29	37,9	9,8	401	3874	501,1
23-Out-13	25,9	139	7,25	37,9	2,3	430,5	4007,5	722,1
31-Out-13	19,9	102	7,46	37,9	2,1	515	4246,5	680,9
07-Nov-13	18,0	145	7,25	37,9	0	452	4073,5	588,6
12-Nov-13	20,1	112	7,65	37,9	23	424,5	4579,5	526,3
19-Nov-13	20,9	116	7,42	37,9	4,4	373	4353	539,1
27-Nov-13	23,8	38	7,26	37,9	0	433,5	4087	400,3
04-Dez-13	21,9	67	7,33	37,9	0	452	4047	583,9
10-Dez-13	7,4	76	7,25	37,9	20,95	439	4047	703,6
18-Dez-13	12,1	73	7,48	37,9	2,6	450	4473	942,7

Continuação da tabela 15. Base de dados com gorduras.

2-Jan-14	26,2	73	7,44	37,1	1,3	373,5	4353	1046,3
8-Jan-14	5,8	71	7,51	37,1	0,9	443	4460	616,6
14-Jan-14	19,3	45	7,425	37,1	3,4	458,5	4073,5	706,9
21-Jan-14	19,1	53	7,45	37,1	6,5	443	4473	667,1
29-Jan-14	48,6	57	7,435	37,1	2,5	434,5	4420	922,9
6-Fev-14	16,1	56	7,355	37,9	8,03	438	4326,5	695,3
12-Fev-14	43,4	51	7,38	37,9	8,03	441,5	4379,5	541,3
20-Fev-14	38,6	43	7,435	37,9	1,9	445,5	4420	736,7
27-Fev-14	40,9	56	7,515	37,9	1,4	436,5	4499,5	665,4
7-Mar-14	43,9	53	7,36	37,9	0	307	4207	776,9
14-Mar-14	16,2	63	7,33	38,0	1	433,5	4167	646,4
19-Mar-14	28,2	145	7,455	37,9	2,4	433,5	4433	876,6
27-Mar-14	48,5	70	7,485	37,7	24	453	4473	893,7
3-Abr-14	19,9	58	7,29	37,3	22,3	446,5	4167	862,1
10-Abr-14	20,05	120	7,33	37,0	24,02	420	4113,5	984,4
15-Abr-14	21,92	157	7,34	36,8	0	630	5059	1327,1
23-Abr-14	11,8	167	7,56	36,9	0	657,5	4925,5	916,9
29-Abr-14	3,25	91	7,33	35,9	0	1005,5	4366,5	735,9
6-Mai-14	16,55	147	7,35	35,8	0	1053	4433	512,0
21-Mai-14	47,4	86	7,33	37,6	0	1053,5	4420	1104,4
28-Mai-14	35,7	113	7,46	38,0	0	762	4553	1168,1

## **Anexo V**

### Compilação do Segundo Conjunto de Redes

Tabela 16. Compilação do Segundo conjunto de redes para a base de dados sem gorduras.

Nome da Rede		A1	A2	A3	A4	A5	A6	A7	
Configuração		Previsor numérico de MLFN (10,10 nós)	Previsor numérico de MLFN (3 nós)	Previsor numérico de MLFN (7 nós)	Previsor numérico de MLFN (3 nós)	Previsor numérico de MLFN (3 nós)	Previsor numérico de GRNN	Previsor numérico de MLFN (7 nós)	
Variáveis (impacto)	Dependentes (output)	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	
	Independentes (input)	SV (39,09%)	Q ent. (48,53%)	Q ent. (44,16%)	Q ent. (81,94%)	Q ent. (53,67%)	Alcal. (40,03%)	Alcal. (57,55%)	
		Temp. (30,88%)	Temp. (19,95%)	SV (33,78%)	SV (18,06%)	SV (32,18%)	Temp. (31,18 %)	AGV (42,45%)	
		Q ent. (30,03%)	SV (16,89%)	Temp. (22,06%)	-	Temp. (14,15%)	AGV (28,79%)	-	
		-	AGV (14,64%)	-	-	-	-	-	
		-	-	-	-	-	-	-	
		-	-	-	-	-	-	-	
-	-	-	-	-	-	-			
Treino	Número de Casos		87	87	87	87	87	87	
	Erro médio	Quadrático	41,08	269,67	185,48	368,04	261,47	3,476	313,71
		Absoluto	20,11	204,19	137,15	249,15	201,11	0,8337	233,76
	Desvio Padrão do erro absoluto		35,82	176,15	124,86	270,89	167,09	3,375	209,20
	Previsões inadequadas (toler. 30%)		0,00%	27,59%	14,94%	31,03%	24,14%	0,00%	28,74%
Teste	Número de Casos		22	22	22	22	22	22	
	Erro médio	Quadrático	1389,43	474,30	439,91	395,48	466,12	679,15	734,97
		Absoluto	899,15	321,64	366,48	299,64	330,15	515,64	520,52
	Desvio Padrão do erro absoluto		1059,28	348,58	243,34	258,12	329,04	442,01	518,88
	Previsões inadequadas (toler. 30%)		54,55%	36,36%	63,64%	40,91%	45,45%	50,00%	59,09%



Continuação da tabela 16. Compilação do Segundo Conjunto de redes para a base de dados sem gorduras.

Nome da Rede		A8	A9	A10	A11	A12	A13	A14	A15	
Configuração		Previsor numérico de MLFN (2 nós)	Previsor numérico de GRNN	Previsor numérico de GRNN	Previsor numérico de GRNN	Previsor numérico de MLFN (6 nós)	Previsor numérico de MLFN (3 nós)	Previsor numérico de GRNN	Previsor numérico de GRNN	
Variáveis (impacto)	Dependentes (output)	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	
	Independentes (input)	Alcal. (39,04%)	Q ent. (31,65%)	Alcal. (60,99%)	pH (44,85%)	Q ent. (37,45%)	pH (72,66%)	Temp. (82,55%)	Q ent. (56,22%)	
		pH (31,87%)	AVG (19,86%)	SV (39,01%)	AGV (28,97%)	Temp. (31,95%)	Temp. (27,34%)	SV (16,84%)	Temp. (43,78%)	
		Temp. (17,32%)	Temp. (18,76%)	-	Temp. (26,18%)	AGV (30,60%)	-	AGV (0,62%)	-	
		AGV (11,76%)	SV (18,50%)	-	-	-	-	-	-	
		-	pH (9,94%)	-	-	-	-	-	-	
-	Alcal. (1,28%)	-	-	-	-	-	-			
Treino	Número de Casos		87	87	87	87	87	87	87	
	Erro médio	Quadrático	464,25	103,35	76,06	613,29	235,02	483,63	461,96	317,38
		Absoluto	309,24	62,49	11,53	390,38	159,62	338,01	305,80	219,15
	Desvio Padrão do erro absoluto		346,26	82,32	75,18	472,99	172,50	345,90	346,25	229,58
	Previsões inadequadas (toler. 30%)		40,23%	2,30%	0,00%	41,38%	17,24%	44,83%	36,78%	22,99%
Teste	Número de Casos		22	22	22	22	22	22	22	
	Erro médio	Quadrático	581,37	453,11	775,58	569,00	357,79	560,40	511,55	484,13
		Absoluto	401,09	370,75	524,07	417,23	288,08	401,84	404,65	357,11
	Desvio Padrão do erro absoluto		420,85	260,49	571,73	386,88	212,19	390,60	312,96	326,89
	Previsões inadequadas (toler. 30%)		54,55%	50,00%	50,00%	50,00%	40,91%	59,09%	63,64%	36,36%

EMQ das várias redes deste segundo conjunto para as rede A – Base de dados sem gorduras.

2	ERRO	3	ERRO	4	ERRO	5	ERRO	6	ERRO	7	ERRO	8	ERRO
GRNN	479,76	GRNN	540,65	GRNN	438,48	Previsor lineaa	525,34	GRNN	679,15	GRNN	807,27	GRNN	658,19
MLFN 3 nós	474,30	MLFN 2 nós	1069,02	MLFN 2 nós	1025,51	GRNN	540,65	MLFN 2 nós	1235,58	MLFN 2 nós	767,25	MLFN 2 nós	581,37
MLFN 4 nós	843,42	MLFN 3 nós	469,16	MLFN 3 nós	395,48	MLFN 2 nós	1109,15	MLFN 3 nós	1981,43	MLFN 3 nós	768,67	MLFN 3 nós	2360,28
MLFN 5 nós	774,22	MLFN 4 nós	965,11	MLFN 4 nós	552,78	MLFN 3 nós	466,12	MLFN 4 nós	1403,15	MLFN 4 nós	944,30	MLFN 4 nós	1011,59
MLFN 6 nós	530,67	MLFN 5 nós	1389,12	MLFN 5 nós	1916,98	MLFN 4 nós	965,17	MLFN 5 nós	861,26	MLFN 5 nós	848,30	MLFN 5 nós	704,14
MLFN 7 nós	478,08	MLFN 6 nós	1088,35	MLFN 6 nós	1658,43	MLFN 5 nós	977,71	MLFN 6 nós	938,87	MLFN 6 nós	810,85	MLFN 6 nós	598,56
MLFN 8 nós	590,15	MLFN 7 nós	439,91	MLFN 7 nós	1382,21	MLFN 6 nós	1054,02	MLFN 7 nós	887,36	MLFN 7 nós	734,97	MLFN 7 nós	1259,12
MLFN 9 nós	982,56	MLFN 8 nós	780,85	MLFN 8 nós	1606,46	MLFN 7 nós	2293,22	MLFN 8 nós	1281,18	MLFN 8 nós	864,52	MLFN 8 nós	890,72
MLFN 10 nós	837,84	MLFN 9 nós	1500,94	MLFN 9 nós	41590,93	MLFN 8 nós	913,95	MLFN 9 nós	2211,24	MLFN 9 nós	3873,92	MLFN 9 nós	1377,09
		MLFN 10 nós	921,34	MLFN 10 nós	1162,31	MLFN 9 nós	941,59	MLFN 10 nós	1696,62	MLFN 10 nós	1048,11	MLFN 10 nós	834,7983194
		MLFN 11 nós	675,46	MLFN 11 nós	1060,20	MLFN 10 nós	1829,18	MLFN 11 nós	5717,33	MLFN 11 nós	942,85	MLFN 11 nós	2208,89
<b>9</b>	<b>ERRO</b>	MLFN 12 nós	1016,62	MLFN 12 nós	896,55	MLFN 11 nós	1818,08	MLFN 12 nós	5037,53	MLFN 12 nós	891,96	MLFN 12 nós	2613,08
GRNN	453,11	MLFN 13 nós	915,27	MLFN 13 nós	784,19	MLFN 12 nós	956,58			MLFN 13 nós	1675,31	MLFN 13 nós	2500,18
MLFN 2 nós	523,32	MLFN 14 nós	1015,77	MLFN 14 nós	999,73	MLFN 13 nós	1304,73			MLFN 14 nós	3063,95	MLFN 14 nós	1427,11
MLFN 3 nós	577,03	MLFN 15 nós	969,01	MLFN 15 nós	938,75	MLFN 14 nós	1190,75	<b>13</b>	<b>ERRO</b>	MLFN 15 nós	6004,55	MLFN 15 nós	686,81
MLFN 4 nós	650,31	MLFN 16 nós	1037,71	MLFN 16 nós	753,09	MLFN 15 nós	1388,41	GRNN	594,35				
MLFN 5 nós	716,42	MLFN 17 nós	1420,84	MLFN 17 nós	1505,08	MLFN 16 nós	1459,99	MLFN 2 nós	617,78				
MLFN 6 nós	1404,42	MLFN 18 nós	960,26	MLFN 18 nós	1239,26			MLFN 3 nós	560,40	<b>14</b>	<b>ERRO</b>	<b>15</b>	<b>ERRO</b>
MLFN 7 nós	652,30	MLFN 19 nós	1852,22	MLFN 19 nós	1790,77	<b>12</b>	<b>ERRO</b>	MLFN 4 nós	603,33	GRNN	511,55	GRNN	484,13
MLFN 8 nós	608,04	MLFN 20 nós	1342,57	MLFN 20 nós	1377,21	GRNN	468,31	MLFN 5 nós	608,17	MLFN 2 nós	1026,25	MLFN 2 nós	596,13
MLFN 9 nós	946,49			MLFN 21 nós	2769,33	MLFN 2 nós	666,71	MLFN 6 nós	1896,62	MLFN 3 nós	1045,32	MLFN 3 nós	1670,21
MLFN 10 nós	742,65	<b>11</b>	<b>ERRO</b>	MLFN 22 nós	1163,91	MLFN 3 nós	505,74	MLFN 7 nós	778,06	MLFN 4 nós	1224,27	MLFN 4 nós	1440,63
MLFN 11 nós	910,70	GRNN	569,00	MLFN 23 nós	1508,15	MLFN 4 nós	531,00	MLFN 8 nós	795,34	MLFN 5 nós	1120,08	MLFN 5 nós	503,15
MLFN 12 nós	1300,47	MLFN 2 nós	574,46	MLFN 24 nós	2192,90	MLFN 5 nós	552,05	MLFN 9 nós	819,87	MLFN 6 nós	699,11	MLFN 6 nós	1767,40
MLFN 13 nós	895,84	MLFN 3 nós	963,57	MLFN 25 nós	1383,48	MLFN 6 nós	357,79	MLFN 10 nós	3042,36	MLFN 7 nós	1488,18	MLFN 7 nós	1769,29
MLFN 14 nós	715,08	MLFN 4 nós	599,17			MLFN 7 nós	4524,13	MLFN 11 nós	1556,62	MLFN 8 nós	1559,93	MLFN 8 nós	1766,65
MLFN 15 nós	1254,92	MLFN 5 nós	657,42			MLFN 8 nós	2668,37	MLFN 12 nós	752,44	MLFN 9 nós	1481,94	MLFN 9 nós	1529,86
		MLFN 6 nós	859,43			MLFN 9 nós	1138,08			MLFN 10 nós	1012,52	MLFN 10 nós	1061,79
<b>10</b>	<b>ERRO</b>	MLFN 7 nós	1187,03			MLFN 10 nós	458,62			MLFN 11 nós	1036,60	MLFN 11 nós	1448,97
GRNN	775,58	MLFN 8 nós	680,23			MLFN 11 nós	1525,32			MLFN 12 nós	2112,75	MLFN 12 nós	2494,47
MLFN 2 nós	17360,93	MLFN 9 nós	1498,77			MLFN 12 nós	2564,79			MLFN 13 nós	3294,35	MLFN 13 nós	2023,69
MLFN 3 nós	10445,46	MLFN 10 nós	1255,08							MLFN 14 nós	2153,30	MLFN 14 nós	986,43
MLFN 4 nós	9798,68	MLFN 11 nós	1006,83							MLFN 15 nós	1391,07	MLFN 15 nós	569,71
MLFN 5 nós	11431,67												

Tabela 17. Compilação do Segundo conjunto de redes para a base de dados com gorduras.

Nome da Rede		B1	B2	B3	B4	B5	B6	B7	
Configuração		Previsor numérico de MLFN (10 nós)	Previsor numérico de GRNN	Previsor numérico de GRNN	Previsor numérico de GRNN	Previsor numérico de GRNN	Previsor numérico de MLFN (4 nós)	Previsor numérico de MLFN (2 nós)	
Variáveis (impacto)	Dependentes (output)	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	
	Independentes (input)	Alcal. (17,81%)	Q ent. (67,59%)	Q ent. (67,59%)	Alcal. (46,88%)	pH (63,71%)	Q ent. (35,55%)	Q ent. (72,77%)	
		Q ent. (18,85%)	Gord. (32,41%)	Gord. (32,41%)	pH (30,23%)	Gord. (31,44%)	SV (25,92%)	Gord. (24,50%)	
		AGV (15,29%)	SV (0,00%)	SV (0,00%)	Temp. (18,36%)	Temp. (4,85%)	Temp. (23,40%)	Temp. (2,73%)	
		Temp. (14,65%)	-	-	Gord. (4,40%)	-	Gord. (15,14%)	-	
		Gord. (12,81%)	-	-	AGV (0,12%)	-	-	-	
		pH (11,77%)	-	-	-	-	-	-	
		SV (10,82%)	-	-	-	-	-	-	
Treino	Número de Casos	42	42	42	42	42	42	42	
	Erro médio	Quadrático	0,7666	247,14	247,14	513,21	709,02	121,27	241,30
		Absoluto	0,4883	151,88	151,88	287,07	448,96	86,34	174,74
	Desvio Padrão do erro absoluto	0,5910	194,97	194,97	425,41	548,76	85,15	166,42	
	Previsões inadequadas (toler. 30%)	0,00%	9,52%	9,52%	26,19%	45,24%	4,76%	23,81%	
Teste	Número de Casos	11	11	11	11	11	11	11	
	Erro médio	Quadrático	535,62	562,89	562,89	393,95	406,32	606,43	536,23
		Absoluto	428,87	403,40	403,40	242,00	280,36	438,33	359,25
	Desvio Padrão do erro absoluto	320,87	392,57	392,57	310,87	294,10	419,08	398,11	
	Previsões inadequadas (toler. 30%)	54,55%	27,27%	27,27%	27,27%	27,27%	45,45%	45,45%	

Continuação da Tabela 17. Compilação do Segundo Conjunto de redes para a base de dados com gorduras.

Nome da Rede		B8	B9	B10	B11	B12	B13	B14	B15	
Configuração		Previsor numérico de GRNN	Previsor numérico de GRNN	Previsor numérico de MLFN (3 nós)	Previsor numérico de GRNN	Previsor numérico de MLFN (5 nós)	Previsor numérico de MLFN (2 nós)	Previsor numérico de GRNN	Previsor numérico de GRNN	
Variáveis (impacto)	Dependentes (output)	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	Biogás Tot.	
	Independentes (input)	pH (40,89%)	Q ent. (56,61%)	pH	Temp. (51,17%)	Q ent. (22,21%)	Gord. (56,81%)	Q ent. (56,60%)	Q ent. (36,91%)	
		SV (23,90%)	Alcal. (25,81%)	AGV	SV (28,16%)	pH (22,10%)	SV (43,19%)	Alcal. (25,81%)	Temp. (18,03%)	
		Temp. (18,72%)	Gord. (16,87%)	Alcal.	Gord. (20,67%)	Temp. (21,55%)	-	Gord. (16,87%)	SV (17,96%)	
		Gord. (16,76%)	pH (0,72%)	SV	-	SV (19,27%)	-	pH (0,72%)	Gord. (13,62%)	
		AGV (0,14%)	-	Temp.	-	Gord. (14,87%)	-	-	AGV (13,47%)	
-	-	Gorduras	-	-	-	-	-	-		
-	-	-	-	-	-	-	-	-		
Treino	Número de Casos		42	42	42	42	42	42	42	
	Erro médio	Quadrático	131,67	425,42	172,21	9,408	71,20	492,24	425,42	0,00
		Absoluto	37,94	247,80	116,39	2,856	45,46	342,51	247,80	0,00
	Desvio Padrão do erro absoluto		126,09	345,80	126,92	8,964	54,80	353,53	345,80	0,00
	Previsões inadequadas (toler. 30%)		4,76%	19,05%	9,52%	0,00%	4,76%	57,14%	19,05%	0,00%
Teste	Número de Casos		11	11	11	11	11	11	11	
	Erro médio	Quadrático	656,69	536,85	1018,31	616,85	691,78	900,26	536,85	607,96
		Absoluto	418,46	412,07	773,83	433,92	487,40	658,60	412,07	479,21
	Desvio Padrão do erro absoluto		506,10	344,10	661,93	438,42	490,91	613,77	344,10	374,13
	Previsões inadequadas (toler. 30%)		36,36%	45,45%	63,63%	27,27%	36,36%	72,73%	45,45%	45,45%

EMQ das várias redes deste segundo conjunto para as rede B – Base de dados com gorduras.

<b>1</b>	<b>ERRO</b>	<b>2</b>	<b>ERRO</b>	<b>3</b>	<b>ERRO</b>	<b>4</b>	<b>ERRO</b>	<b>5</b>	<b>ERRO</b>	<b>6</b>	<b>ERRO</b>	<b>7</b>	<b>ERRO</b>
GRNN	637,15	GRNN	562,89	GRNN	562,89	GRNN	393,95	GRNN	406,32	GRNN	620,43	GRNN	539,22
MLFN 2 nós	1673,40	MLFN 2 nós	1607,27	MLFN 2 nós	1094,52	MLFN 2 nós	1247,78	MLFN 2 nós	1233,77	MLFN 2 nós	1791,14	MLFN 2 nós	536,23
MLFN 3 nós	760,57	MLFN 3 nós	582,85	MLFN 3 nós	651,75	MLFN 3 nós	1108,42	MLFN 3 nós	1434,17	MLFN 3 nós	1302,44	MLFN 3 nós	818,32
MLFN 4 nós	2031,09	MLFN 4 nós	986,05	MLFN 4 nós	668,93	MLFN 4 nós	1314,29	MLFN 4 nós	3180,56	MLFN 4 nós	606,43	MLFN 4 nós	1878,17
MLFN 5 nós	3443,23	MLFN 5 nós	987,79	MLFN 5 nós	1619,64	MLFN 5 nós	1327,26	MLFN 5 nós	1544,73	MLFN 5 nós	910,78	MLFN 5 nós	690,76
MLFN 6 nós	943,59	MLFN 6 nós	918,05	MLFN 6 nós	5220,82	MLFN 6 nós	1206,43	MLFN 6 nós	1444,70	MLFN 6 nós	1899,48	MLFN 6 nós	1217,36
MLFN 7 nós	715,20	MLFN 7 nós	1355,12	MLFN 7 nós	801,11	MLFN 7 nós	1101,17	MLFN 7 nós	1644,67	MLFN 7 nós	989,70	MLFN 7 nós	4989,51
MLFN 8 nós	2408,66	MLFN 8 nós	3589,88	MLFN 8 nós	2296,98	MLFN 8 nós	1265,31	MLFN 8 nós	1773,68	MLFN 8 nós	883,73	MLFN 8 nós	2282,41
MLFN 9 nós	1206,31	MLFN 9 nós	3700,99	MLFN 9 nós	3076,98	MLFN 9 nós	1564,60	MLFN 9 nós	1360,82	MLFN 9 nós	2375,90	MLFN 9 nós	627,11
MLFN 10 nós	535,62	MLFN 10 nós	1413,58	MLFN 10 nós	1394,93	MLFN 10 nós	1495,50	MLFN 10 nós	1192,42	MLFN 10 nós	645,19	MLFN 10 nós	1459,60
		MLFN 11 nós	3462,68	MLFN 11 nós	2407,93	MLFN 11 nós	1238,74					MLFN 11 nós	694,15
<b>8</b>	<b>ERRO</b>	MLFN 12 nós	1887,93	MLFN 12 nós	2575,68	MLFN 12 nós	1242,05					MLFN 12 nós	2667,50
GRNN	656,69	MLFN 13 nós	4518,32	MLFN 13 nós	1680,66			<b>12</b>	<b>ERRO</b>	<b>13</b>	<b>ERRO</b>	MLFN 13 nós	593,14
MLFN 2 nós	1868,27	MLFN 14 nós	2381,23	MLFN 14 nós	1948,70			GRNN	1023,90	GRNN	1249,82		
MLFN 3 nós	1421,43	MLFN 15 nós	5174,71	MLFN 15 nós	5174,71			MLFN 2 nós	1337,61	MLFN 2 nós	900,26		
MLFN 4 nós	1763,79					<b>11</b>	<b>ERRO</b>	MLFN 3 nós	2081,08	MLFN 3 nós	3863,92	<b>14</b>	<b>ERRO</b>
MLFN 5 nós	1315,24			<b>15</b>	<b>ERRO</b>	GRNN	616,85	MLFN 4 nós	3642,16	MLFN 4 nós	9011,75	GRNN	536,85
MLFN 6 nós	2119,25	<b>9</b>	<b>ERRO</b>	GRNN	607,96	MLFN 2 nós	1529,80	MLFN 5 nós	691,78	MLFN 5 nós	8262,64	MLFN 2 nós	1354,36
MLFN 7 nós	2977,80	GRNN	536,85	MLFN 2 nós	2102,92	MLFN 3 nós	3064,47	MLFN 6 nós	695,60	MLFN 6 nós	1733,83	MLFN 3 nós	940,81
MLFN 8 nós	1643,81	MLFN 2 nós	1354,36	MLFN 3 nós	1365,85	MLFN 4 nós	679,27	MLFN 7 nós	882,51	MLFN 7 nós	1815,04	MLFN 4 nós	869,68
MLFN 9 nós	1482,23	MLFN 3 nós	940,81	MLFN 4 nós	1035,43	MLFN 5 nós	2403,48	MLFN 8 nós	1299,76	MLFN 8 nós	1721,97	MLFN 5 nós	564,70
MLFN 10 nós	1474,94	MLFN 4 nós	869,68	MLFN 5 nós	1130,07	MLFN 6 nós	1489,72	MLFN 9 nós	1339,52	MLFN 9 nós	2152,63	MLFN 6 nós	964,05
		MLFN 5 nós	564,70	MLFN 6 nós	628,07	MLFN 7 nós	1148,29	MLFN 10 nós	3341,51	MLFN 10 nós	8764,17	MLFN 7 nós	2231,21
<b>10</b>	<b>ERRO</b>	MLFN 6 nós	964,05	MLFN 8 nós	1915,86	MLFN 8 nós	1137,80	MLFN 11 nós	1149,67	MLFN 11 nós	3889,55	MLFN 8 nós	1780,70
GRNN	1090,55	MLFN 7 nós	2231,21	MLFN 9 nós	791,99	MLFN 9 nós	2843,95	MLFN 12 nós	1217,54	MLFN 12 nós	1340,08	MLFN 9 nós	1272,86
MLFN 2 nós	1679,79	MLFN 8 nós	1780,70	MLFN 10 nós	1121,20	MLFN 10 nós	986,51			MLFN 13 nós	306907,13	MLFN 10 nós	904,70
MLFN 3 nós	1018,31	MLFN 9 nós	1272,86	MLFN 11 nós	1358,25	MLFN 11 nós	1087,63					MLFN 11 nós	791,36
MLFN 4 nós	1366,27	MLFN 10 nós	904,70	MLFN 12 nós	1109,97	MLFN 12 nós	2277,19					MLFN 12 nós	1100,11
MLFN 5 nós	1137,65			MLFN 12 nós	880,38								
MLFN 6 nós	1940,27												
MLFN 7 nós	1847,20												
MLFN 8 nós	1768,12												
MLFN 9 nós	1514,17												
MLFN 10 nós	2164,80												

## **Anexo VI**

### Previsão Instantânea para diferentes valores de Temperatura

Tabela 18. Previsão Instantânea a várias Temperaturas para a Base de dados sem gorduras.

Dia	Temperatura °C (média)	Temperatura °C (média)	Temperatura °C (média)	Temperatura °C (média)	Temperatura °C (média)	Temperatura °C (média)	Temperatura °C (média)	Biogás Total REAL média m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia
	REAL	valor fixo	valor fixo	valor fixo	valor fixo	valor fixo	valor fixo		Temp. REAL	Temp. = 35	Temp. = 36	Temp. = 37	Temp. = 38	Temp. = 39	Temp. = 40
3-Jan-12	37,00	35	36	37	38	39	40	624,4	879,8	879,8	879,8	879,8	879,8	2221,0	2221,3
18-Jan-12	37,00	35	36	37	38	39	40	1186,7	1183,9	1077,6	1559,3	1183,9	2248,2	2239,7	2225,3
24-Jan-12	38,00	35	36	37	38	39	40	1171,7	879,8	879,8	879,8	879,8	879,8	2216,9	2221,3
31-Jan-12	34,00	35	36	37	38	39	40	738,3	691,0	1126,4	990,3	909,6	1891,2	2222,8	2221,6
7-Feb-12	38,00	35	36	37	38	39	40	807,3	886,4	895,7	894,8	884,3	886,4	2221,6	2221,4
22-Feb-12	34,00	35	36	37	38	39	40	438,6	577,0	1071,3	1277,2	1024,5	2241,2	2229,6	2223,1
28-Feb-12	32,00	35	36	37	38	39	40	244,7	194,7	978,4	913,2	888,2	1954,2	2221,7	2221,4
6-Mar-12	34,00	35	36	37	38	39	40	621,7	881,7	880,3	879,9	879,8	880,2	2221,3	2221,3
14-Mar-12	35,00	35	36	37	38	39	40	929,4	879,8	879,8	879,8	879,8	879,8	1291,5	2221,3
27-Mar-12	38,00	35	36	37	38	39	40	813,9	879,8	879,8	879,8	879,8	879,8	2031,6	2221,3
3-Abr-12	36,00	35	36	37	38	39	40	538,6	879,8	879,8	879,8	879,8	879,8	1141,7	2221,3
20-Abr-12	37,00	35	36	37	38	39	40	949,3	879,8	879,9	879,8	879,8	879,8	2220,9	2221,3
26-Abr-12	32,00	35	36	37	38	39	40	791,6	894,9	883,9	880,7	880,0	879,9	2221,3	2221,3
4-Mai-12	37,00	35	36	37	38	39	40	570,3	879,8	880,0	879,8	879,8	879,8	2219,7	2221,3
9-Mai-12	38,00	35	36	37	38	39	40	719,0	879,8	880,1	879,9	879,8	879,8	2220,1	2221,3
16-Mai-12	38,00	35	36	37	38	39	40	803,7	934,1	1202,5	1413,8	1075,3	934,1	2232,4	2223,7
24-Mai-12	38,00	35	36	37	38	39	40	1183,4	880,6	886,3	881,4	880,1	880,6	2221,3	2221,3
29-Mai-12	37,00	35	36	37	38	39	40	1096,7	888,4	1018,6	917,0	888,4	1545,3	2221,7	2221,4
5-Jun-12	37,00	35	36	37	38	39	40	774,6	880,2	888,8	881,8	880,2	1162,7	2221,3	2221,3
14-Jun-12	36,00	35	36	37	38	39	40	1322,7	971,2	1178,7	971,2	901,8	885,4	2222,3	2221,5
20-Jun-12	37,00	35	36	37	38	39	40	1715,0	884,5	956,3	900,2	884,5	900,9	2221,5	2221,4
29-Jun-12	37,00	35	36	37	38	39	40	950,0	881,7	916,6	888,5	881,7	2107,4	2221,4	2221,3

Nota: o termo “Temp.” corresponde à temperatura.

Continuação da tabela 18. Previsão Instantânea a várias Temperaturas para a base de dados sem gorduras.

Dia	Temperatura °C (média)	Temperatura °C (média)	Temperatura °C (média)	Temperatura °C (média)	Temperatura °C (média)	Temperatura °C (média)	Temperatura °C (média)	Biogás Total REAL média m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia
	REAL	valor fixo	valor fixo	valor fixo	valor fixo	valor fixo	valor fixo		Temp. REAL	Temp. = 35	Temp. = 36	Temp. = 37	Temp. = 38	Temp. = 39	Temp. = 40
5-Jul-12	36,00	35	36	37	38	39	40	924,7	920,1	1025,5	920,1	889,2	963,6	2221,8	2221,4
19-Jul-12	37,00	35	36	37	38	39	40	1608,1	1034,0	929,5	1265,2	1034,0	1877,3	2230,5	2223,3
27-Jul-12	37,00	35	36	37	38	39	40	1550,9	1554,7	1211,3	1211,0	1554,7	2560,5	2662,7	3470,1
17-Ago-12	35,00	35	36	37	38	39	40	1402,4	880,3	880,3	879,9	879,8	892,4	2221,3	2221,3
23-Ago-12	38,00	35	36	37	38	39	40	2061,0	2251,4	3649,7	2282,0	1249,8	2251,4	2238,1	2224,7
30-Ago-12	38,00	35	36	37	38	39	40	2128,0	2324,8	4161,3	2637,4	1354,0	2324,8	2242,7	2225,7
6-Set-12	38,00	35	36	37	38	39	40	2805,3	2904,1	1209,7	1208,1	1232,6	2904,1	4527,0	5064,6
12-Set-12	38,00	35	36	37	38	39	40	3500,7	3087,4	1208,9	1206,7	1248,1	3087,4	4832,3	4523,9
19-Set-12	38,00	35	36	37	38	39	40	3132,6	3414,8	1208,7	1210,1	1297,2	3414,8	5204,1	4250,0
26-Set-12	38,00	35	36	37	38	39	40	2418,4	2147,7	1400,9	997,7	904,6	2147,7	2222,3	2221,5
3-Out-12	38,00	35	36	37	38	39	40	1430,0	1373,5	1264,2	966,0	897,9	1373,5	2222,1	2221,5
16-Out-12	38,00	35	36	37	38	39	40	1138,0	879,8	881,3	880,1	879,9	879,8	2221,0	2221,3
24-Out-12	38,00	35	36	37	38	39	40	798,4	879,8	879,9	879,8	879,8	879,8	2221,1	2221,3
1-Nov-12	37,00	35	36	37	38	39	40	1393,7	880,1	887,4	881,4	880,1	905,4	2221,3	2221,3
8-Nov-12	38,00	35	36	37	38	39	40	1273,6	2991,9	2614,6	4795,3	3468,4	2991,9	2393,3	2256,9
14-Nov-12	38,00	35	36	37	38	39	40	901,3	880,1	879,8	879,8	879,8	880,1	2221,3	2221,3
21-Nov-12	38,00	35	36	37	38	39	40	828,4	880,1	905,9	886,0	881,2	880,1	958,5	2221,3
30-Nov-12	38,00	35	36	37	38	39	40	908,0	879,8	880,1	879,8	879,8	879,8	1126,7	2221,3
6-Dez-12	37,50	35	36	37	38	39	40	760,6	879,8	879,8	879,8	879,8	881,4	2221,3	2221,3
12-Dez-12	37,50	35	36	37	38	39	40	873,2	879,8	880,1	879,9	879,8	879,8	1306,4	2221,3
20-Dez-12	38,00	35	36	37	38	39	40	1265,3	879,8	879,9	879,8	879,8	879,8	1296,3	2221,3
26-Dez-12	38,00	35	36	37	38	39	40	1282,6	884,5	879,8	879,8	879,8	884,5	2221,3	2221,3

Nota: o termo "Temp." corresponde à temperatura.



Continuação da tabela 18. Previsão Instantânea a várias Temperaturas para a base de dados sem gorduras.

Dia	Temperatura °C (média)	Temperatura °C (média)	Temperatura °C (média)	Temperatura °C (média)	Temperatura °C (média)	Temperatura °C (média)	Temperatura °C (média)	Biogás Total REAL media m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia
	REAL	valorfixo	valor fixo	valor fixo	valorfixo	valor fixo	valor fixo		Temp. REAL	Temp. = 35	Temp. = 36	Temp. = 37	Temp. = 38	Temp. = 39	Temp. = 40
2-Jan-13	37,00	35	36	37	38	39	40	1037,7	879,8	879,8	879,8	879,8	879,8	1860,1	2221,3
10-Jan-13	37,00	35	36	37	38	39	40	1216,3	880,4	892,2	882,6	880,4	2210,9	2221,3	2221,3
18-Jan-13	37,00	35	36	37	38	39	40	965,9	879,8	880,8	880,0	879,8	880,3	2221,3	2221,3
28-Jan-13	37,00	35	36	37	38	39	40	585,9	879,8	880,4	879,9	879,8	881,5	2221,3	2221,3
11-Fev-13	36,50	35	36	37	38	39	40	1074,6	880,2	883,5	880,7	880,0	880,0	2221,3	2221,3
22-Fev-13	36,50	35	36	37	38	39	40	893,3	1033,3	564,4	1068,6	974,2	937,7	2227,5	2222,7
1-Mar-13	37,50	35	36	37	38	39	40	830,7	879,8	880,2	879,9	879,8	879,8	2220,7	2221,3
8-Mar-13	37,50	35	36	37	38	39	40	826,0	880,1	889,2	882,8	880,5	879,9	1444,9	2221,3
21-Mar-13	38,00	35	36	37	38	39	40	1751,6	880,2	911,3	887,9	881,6	880,2	2221,3	2221,3
4-Abr-13	36,00	35	36	37	38	39	40	506,1	882,8	889,7	882,8	880,5	888,2	2221,4	2221,3
12-Abr-13	36,00	35	36	37	38	39	40	598,9	501,2	-765,2	501,2	899,1	899,9	1019,9	2222,8
19-Abr-13	36,00	35	36	37	38	39	40	1228,4	1189,3	1206,5	1189,3	1120,1	917,8	1803,1	2874,7
22-Abr-13	36,00	35	36	37	38	39	40	1125,4	904,7	980,2	904,7	885,4	2222,5	2221,6	2221,4
3-Mai-13	36,75	35	36	37	38	39	40	807,3	964,1	-63,0	862,3	954,2	905,8	2212,6	2222,8
8-Mai-13	36,75	35	36	37	38	39	40	1089,7	1202,4	1209,6	1205,4	1204,9	2684,5	3753,7	4812,9
13-Mai-13	36,75	35	36	37	38	39	40	1060,0	1074,2	1652,8	1358,8	1018,1	1664,8	2228,3	2222,8
20-Mai-13	36,75	35	36	37	38	39	40	1627,1	879,8	879,8	879,8	879,8	879,8	910,9	2221,3
28-Mai-13	36,75	35	36	37	38	39	40	942,7	879,8	879,9	879,8	879,8	1628,9	2221,3	2221,3
3-Jun-13	37,30	35	36	37	38	39	40	998,1	891,7	1212,2	963,9	898,6	2206,3	2222,1	2221,5
12-Jun-13	37,30	35	36	37	38	39	40	2682,4	2542,7	1243,6	2074,6	2808,7	2981,5	2433,7	2267,7
19-Jun-13	37,30	35	36	37	38	39	40	1795,4	1529,3	1477,2	2435,0	1792,5	1173,6	2279,1	2233,6
10-Jul-13	38,20	35	36	37	38	39	40	2249,6	2218,9	880,0	879,8	879,8	2104,8	2221,3	2221,3
16-Jul-13	38,20	35	36	37	38	39	40	2876,6	2257,3	2247,7	1656,1	1095,5	2262,1	2231,8	2223,5
24-Jul-13	38,20	35	36	37	38	39	40	2107,7	2731,7	1557,0	3024,6	2893,1	2893,8	2378,2	2254,6
30-Jul-13	38,20	35	36	37	38	39	40	3603,4	3341,9	1268,5	2029,8	3378,0	3624,6	2605,2	2306,2
05-Ago-13	37,75	35	36	37	38	39	40	5173,3	5142,3	1264,4	1826,6	3713,2	4736,8	3056,7	2414,5
13-Ago-13	37,25	35	36	37	38	39	40	2148,0	1818,0	1204,0	1221,5	1560,7	3623,3	4496,1	3018,6
20-Ago-13	37,75	35	36	37	38	39	40	1992,4	2220,5	1201,3	1198,3	1399,1	2639,7	4338,4	3015,5
29-Ago-13	37,93	35	36	37	38	39	40	1826,4	1950,0	1278,4	2276,4	2363,4	2370,3	2344,6	2247,9
04-Set-13	37,93	35	36	37	38	39	40	1617,7	1724,8	1068,8	1088,9	1866,9	1673,5	2468,1	2279,7
10-Set-13	37,93	35	36	37	38	39	40	1686,4	1525,5	1525,8	1293,5	1000,5	1967,9	2227,5	2222,6
24-Set-13	37,93	35	36	37	38	39	40	672,9	901,9	994,7	910,7	887,0	967,4	2221,6	2221,4

Nota: O termo "Temp." corresponde à temperatura.

Continuação da tabela 18. Previsão Instantânea a várias Temperaturas para a base de dados sem gorduras.

Dia	Temperatura °C (média)	Temperatura °C (média)	Temperatura °C (média)	Temperatura °C (média)	Temperatura °C (média)	Temperatura °C (média)	Temperatura °C (média)	Biogás Total REAL média m <sup>3</sup> /dia	Biogás Total PREVISTO m <sup>3</sup> /dia	Biogás Total PREVISTO m <sup>3</sup> /dia	Biogás Total PREVISTO m <sup>3</sup> /dia	Biogás Total PREVISTO m <sup>3</sup> /dia	Biogás Total PREVISTO m <sup>3</sup> /dia	Biogás Total PREVISTO m <sup>3</sup> /dia	Biogás Total PREVISTO m <sup>3</sup> /dia
	REAL	valor fixo	valor fixo	valor fixo	valor fixo	valor fixo	valor fixo		Temp. REAL	Temp. = 35	Temp. = 36	Temp. = 37	Temp. = 38	Temp. = 39	Temp. = 40
01-Out-13	37,93	35	36	37	38	39	40	679,4	879,8	881,6	880,2	879,9	879,9	2221,3	2221,3
10-Out-13	37,93	35	36	37	38	39	40	501,7	880,8	879,8	879,8	879,8	884,2	2221,3	2221,3
15-Out-13	37,93	35	36	37	38	39	40	501,1	880,8	918,9	890,3	882,2	882,3	2221,4	2221,3
23-Out-13	37,93	35	36	37	38	39	40	722,1	884,8	1100,8	953,0	898,0	885,9	2222,2	2221,5
31-Out-13	37,93	35	36	37	38	39	40	680,9	880,2	883,1	880,5	879,9	881,3	2221,3	2221,3
07-Nov-13	37,93	35	36	37	38	39	40	588,6	915,6	927,1	891,2	882,3	1024,0	2221,4	2221,3
12-Nov-13	37,93	35	36	37	38	39	40	526,3	881,6	900,3	884,8	880,9	886,7	2221,4	2221,3
19-Nov-13	37,93	35	36	37	38	39	40	539,1	882,9	935,5	895,3	883,4	890,2	2221,5	2221,3
27-Nov-13	37,93	35	36	37	38	39	40	400,3	879,8	880,7	880,0	879,8	879,8	2220,4	2221,3
04-Dez-13	37,93	35	36	37	38	39	40	583,9	879,8	881,9	880,3	879,9	879,9	2221,3	2221,3
10-Dez-13	37,93	35	36	37	38	39	40	703,6	955,1	879,9	879,8	879,8	1160,9	2221,3	2221,3
18-Dez-13	37,93	35	36	37	38	39	40	942,7	884,7	880,1	879,8	879,8	901,3	2221,3	2221,3
2-Jan-14	37,10	35	36	37	38	39	40	1046,3	881,0	899,5	885,6	881,2	880,1	2221,2	2221,3
8-Jan-14	37,10	35	36	37	38	39	40	616,6	879,8	879,8	879,8	879,8	1272,6	2221,3	2221,3
14-Jan-14	37,10	35	36	37	38	39	40	706,9	879,8	880,1	879,9	879,8	879,8	2221,3	2221,3
21-Jan-14	37,10	35	36	37	38	39	40	667,1	879,8	880,4	879,9	879,8	879,9	2221,3	2221,3
29-Jan-14	37,10	35	36	37	38	39	40	922,9	916,9	194,4	897,5	920,3	892,9	900,1	2222,0
6-Fev-14	37,93	35	36	37	38	39	40	695,3	880,0	880,1	879,9	879,8	880,7	2221,3	2221,3
12-Fev-14	37,93	35	36	37	38	39	40	541,3	882,7	863,8	908,7	889,9	882,4	1024,8	2221,4
20-Fev-14	37,93	35	36	37	38	39	40	736,7	880,3	899,2	887,8	881,9	880,3	1483,5	2221,3
27-Fev-14	37,93	35	36	37	38	39	40	665,4	882,0	898,2	905,3	887,8	881,8	1419,4	2221,4
7-Mar-14	37,94	35	36	37	38	39	40	776,9	899,5	-465,0	700,6	916,7	898,2	1267,2	2222,5
14-Mar-14	38,01	35	36	37	38	39	40	646,4	881,4	880,3	879,9	879,8	881,3	2221,3	2221,3
19-Mar-14	37,93	35	36	37	38	39	40	876,6	890,6	1232,3	1034,8	921,2	890,3	2223,4	2221,8
27-Mar-14	37,66	35	36	37	38	39	40	893,7	909,8	152,3	920,1	940,9	899,2	921,8	2222,4
3-Abr-14	37,27	35	36	37	38	39	40	862,1	879,8	880,7	880,0	879,8	879,9	2221,3	2221,3
10-Abr-14	37,00	35	36	37	38	39	40	984,4	881,6	912,0	887,8	881,6	892,7	2221,4	2221,3
15-Abr-14	36,80	35	36	37	38	39	40	1327,1	881,0	898,3	883,9	880,7	888,4	2221,4	2221,3
23-Abr-14	36,86	35	36	37	38	39	40	916,9	879,9	881,4	880,1	879,9	1772,8	2221,3	2221,3
29-Abr-14	35,93	35	36	37	38	39	40	735,9	879,8	879,8	879,8	879,8	914,7	2221,3	2221,3
6-Mai-14	35,75	35	36	37	38	39	40	512,0	879,8	879,8	879,8	879,8	880,9	2221,3	2221,3
21-Mai-14	37,60	35	36	37	38	39	40	1104,4	879,8	880,3	879,9	879,8	879,8	880,4	2221,3
28-Mai-14	38,03	35	36	37	38	39	40	1168,1	879,9	887,9	881,6	880,2	879,9	2168,8	2221,3

Nota: o termo "Temp." corresponde à temperatura.

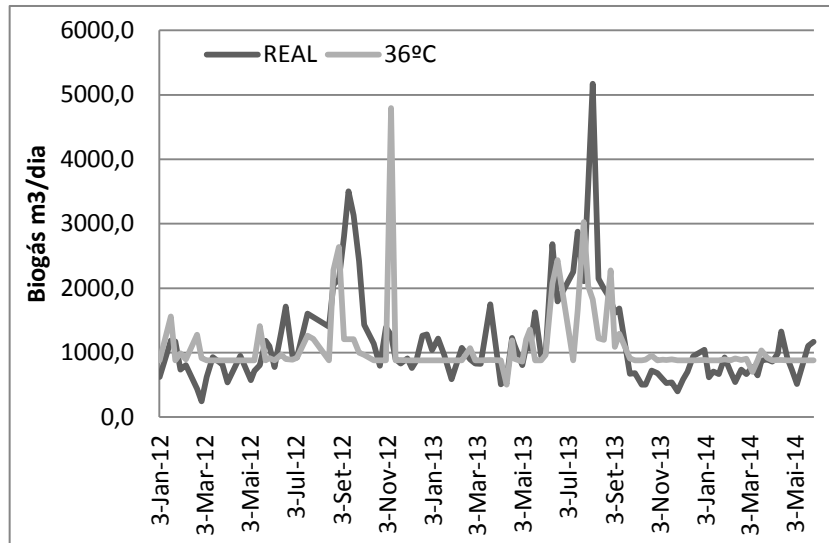


Gráfico 11. Comparação entre o biogás real (cinzento) com o biogás previsto a 36 °C (cinzento claro) para a rede "A2".

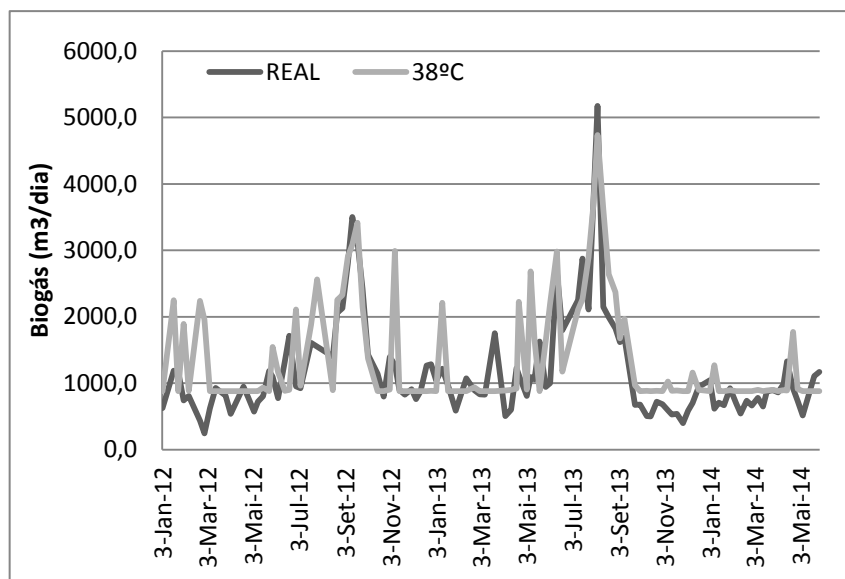


Gráfico 10. Comparação entre o biogás real (cinzento) com o biogás previsto a 38 °C (cinzento claro) para a rede "A2".

Tabela 19. Previsão Instantânea a várias Temperaturas para a base de dados com gorduras.

Dia	Gorduras (m3/dia)	Temperatura	Temperatura	Temperatura	Temperatura	Temperatura	Temperatura	Temperatura	Biogás Total REAL média m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia
		°C (média)	°C (média)	°C (média)	°C (média)	°C (média)	°C (média)	°C (média)								
		REAL	valor fixo	valor fixo	valor fixo	valor fixo	valor fixo	valor fixo		Temp. REAL	Temp. = 35	Temp. = 36	Temp. = 37	Temp. = 38	Temp. = 39	Temp. = 40
22-Abr-13	0	36,0	35	36	37	38	39	40	1125,4	1125,4	1178,9	1125,4	1178,9	1178,9	1178,9	1178,9
3-Mai-13	15,18	36,8	35	36	37	38	39	40	807,3	807,3	1178,9	1178,9	807,3	1178,9	1178,9	1178,9
8-Mai-13	0	36,8	35	36	37	38	39	40	1089,7	1089,7	1178,9	1178,9	1089,7	1178,9	1178,9	1178,9
13-Mai-13	0	36,8	35	36	37	38	39	40	1060,0	1178,9	1178,9	1178,9	998,1	672,9	1178,9	1178,9
20-Mai-13	0	36,8	35	36	37	38	39	40	1627,1	1627,1	1178,9	1178,9	1627,1	1178,9	1178,9	1178,9
28-Mai-13	1,1	36,8	35	36	37	38	39	40	942,7	942,7	1178,9	1178,9	942,7	1178,9	1178,9	1178,9
3-Jun-13	1,2	37,3	35	36	37	38	39	40	998,1	998,1	1178,9	1178,9	998,1	2876,6	1178,9	1178,9
12-Jun-13	0,8	37,3	35	36	37	38	39	40	2682,4	2682,4	1178,9	1178,9	2682,4	1826,4	1178,9	1178,9
19-Jun-13	0	37,3	35	36	37	38	39	40	1795,4	1795,4	1178,9	1178,9	1795,4	1826,4	1178,9	1178,9
10-Jul-13	0	38,2	35	36	37	38	39	40	2249,6	1178,9	1178,9	1178,9	616,6	1178,9	1178,9	1178,9
16-Jul-13	2,8	38,2	35	36	37	38	39	40	2876,6	2876,6	1178,9	1178,9	998,1	2876,6	1178,9	1178,9
24-Jul-13	0	38,2	35	36	37	38	39	40	2107,7	2107,7	1178,9	1178,9	1178,9	2107,7	1178,9	1178,9
30-Jul-13	0,6	38,2	35	36	37	38	39	40	3603,4	3603,4	1178,9	1178,9	2682,4	3603,4	1178,9	1178,9
05-Ago-13	0,9	37,8	35	36	37	38	39	40	5173,3	5173,3	1178,9	1178,9	1178,9	5173,3	1178,9	1178,9
13-Ago-13	0,5	37,3	35	36	37	38	39	40	2148,0	2148,0	1178,9	1178,9	2148,0	1816,3	1178,9	1178,9
20-Ago-13	0	37,8	35	36	37	38	39	40	1992,4	1178,9	1178,9	1178,9	2148,0	1178,9	1178,9	1178,9
29-Ago-13	0,4	37,9	35	36	37	38	39	40	1826,4	1826,4	1178,9	1178,9	2682,4	1826,4	1178,9	1178,9
04-Set-13	0	37,9	35	36	37	38	39	40	1617,7	1178,9	1178,9	1178,9	1178,9	1178,9	1178,9	1178,9
10-Set-13	6	37,9	35	36	37	38	39	40	1686,4	539,1	1178,9	1178,9	1178,9	539,1	1178,9	1178,9
24-Set-13	0,8	37,9	35	36	37	38	39	40	672,9	672,9	1178,9	1178,9	1327,1	672,9	1178,9	1178,9
01-Out-13	3,9	37,9	35	36	37	38	39	40	679,4	679,4	1178,9	1178,9	1327,1	679,4	1178,9	1178,9
10-Out-13	10,7	37,9	35	36	37	38	39	40	501,7	501,7	1178,9	1178,9	1178,9	501,7	1178,9	1178,9
15-Out-13	9,8	37,9	35	36	37	38	39	40	501,1	501,1	1178,9	1178,9	667,1	501,1	1178,9	1178,9
23-Out-13	2,3	37,9	35	36	37	38	39	40	722,1	722,1	1178,9	1178,9	1046,3	722,1	1178,9	1178,9
31-Out-13	2,1	37,9	35	36	37	38	39	40	680,9	680,9	1178,9	1178,9	706,9	680,9	1178,9	1178,9

Nota: o termo "Temp." corresponde à temperatura.

Continuação da tabela 19. Previsão Instantânea a várias Temperaturas para a base de dados com gorduras.

Dia	Gorduras (m3/dia)	Temperatura °C (média)	Temperatura °C (média)	Temperatura °C (média)	Temperatura °C (média)	Temperatura °C (média)	Temperatura °C (média)	Temperatura °C (média)	Biogás Total REAL media m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia
		REAL	valor fixo	valor fixo	valor fixo	valor fixo	valor fixo	valor fixo		Temp. REAL	Temp. = 35	Temp. = 36	Temp. = 37	Temp. = 38	Temp. = 39	Temp. = 40
07-Nov-13	0	37,9	35	36	37	38	39	40	588,6	672,9	1178,9	1178,9	1327,1	672,9	1178,9	1178,9
12-Nov-13	23	37,9	35	36	37	38	39	40	526,3	526,3	1178,9	1178,9	984,4	526,3	1178,9	1178,9
19-Nov-13	4,4	37,9	35	36	37	38	39	40	539,1	539,1	1178,9	1178,9	1046,2	539,1	1178,9	1178,9
27-Nov-13	0	37,9	35	36	37	38	39	40	400,3	400,3	1178,9	1178,9	1046,3	400,3	1178,9	1178,9
04-Dez-13	0	37,9	35	36	37	38	39	40	588,9	588,9	1178,9	1178,9	1046,3	588,9	1178,9	1178,9
10-Dez-13	20,95	37,9	35	36	37	38	39	40	708,6	1178,9	1178,9	1178,9	1178,9	1178,9	1178,9	1178,9
18-Dez-13	2,6	37,9	35	36	37	38	39	40	942,7	942,7	1178,9	1178,9	616,6	942,7	1178,9	1178,9
2-Jan-14	1,3	37,1	35	36	37	38	39	40	1046,3	1046,3	1178,9	1178,9	1046,3	581,0	1178,9	1178,9
8-Jan-14	0,9	37,1	35	36	37	38	39	40	616,6	616,6	1178,9	1178,9	616,6	942,7	1178,9	1178,9
14-Jan-14	3,4	37,1	35	36	37	38	39	40	706,9	706,9	1178,9	1178,9	706,9	646,4	1178,9	1178,9
21-Jan-14	6,5	37,1	35	36	37	38	39	40	667,1	667,1	1178,9	1178,9	667,1	695,3	1178,9	1178,9
29-Jan-14	2,5	37,1	35	36	37	38	39	40	922,9	1178,9	1178,9	1178,9	1178,9	776,9	1178,9	1178,9
6-Fev-14	8,03	37,9	35	36	37	38	39	40	695,3	695,3	1178,9	1178,9	667,1	695,3	1178,9	1178,9
12-Fev-14	8,03	37,9	35	36	37	38	39	40	541,3	1178,9	1178,9	1178,9	1178,9	1178,9	1178,9	1178,9
20-Fev-14	1,9	37,9	35	36	37	38	39	40	736,7	736,7	1178,9	1178,9	1178,9	736,7	1178,9	1178,9
27-Fev-14	1,4	37,9	35	36	37	38	39	40	665,4	665,4	1178,9	1178,9	1178,9	665,4	1178,9	1178,9
7-Mar-14	0	37,9	35	36	37	38	39	40	776,9	776,9	1178,9	1178,9	1178,9	776,9	1178,9	1178,9
14-Mar-14	1	38,0	35	36	37	38	39	40	646,4	646,4	1178,9	1178,9	706,9	646,4	1178,9	1178,9
19-Mar-14	2,4	37,9	35	36	37	38	39	40	876,6	722,1	1178,9	1178,9	1056,9	722,1	1178,9	1178,9
27-Mar-14	24	37,7	35	36	37	38	39	40	893,7	893,7	1178,9	1178,9	1178,9	893,7	1178,9	1178,9
3-Abr-14	22,3	37,3	35	36	37	38	39	40	862,1	862,1	1178,9	1178,9	862,1	526,3	1178,9	1178,9
10-Abr-14	24,02	37,0	35	36	37	38	39	40	984,4	984,4	1178,9	1178,9	984,4	526,3	1178,9	1178,9
15-Abr-14	0	36,8	35	36	37	38	39	40	1327,1	1327,1	1178,9	1178,9	1327,1	679,4	1178,9	1178,9
23-Abr-14	0	36,9	35	36	37	38	39	40	916,9	916,9	1178,9	1178,9	916,9	1178,9	1178,9	1178,9
29-Abr-14	0	35,9	35	36	37	38	39	40	735,9	735,9	1178,9	735,9	1178,9	1178,9	1178,9	1178,9
6-Mai-14	0	35,8	35	36	37	38	39	40	512,0	512,0	1178,9	512,0	1178,9	1178,9	1178,9	1178,9
21-Mai-14	0	37,6	35	36	37	38	39	40	1104,4	1178,9	1178,9	1178,9	1178,9	1178,9	1178,9	1178,9
28-Mai-14	0	38,0	35	36	37	38	39	40	1168,1	1168,1	1178,9	1178,9	1178,9	1168,1	1178,9	1178,9

Nota: o termo "Temp." corresponde à temperatura.

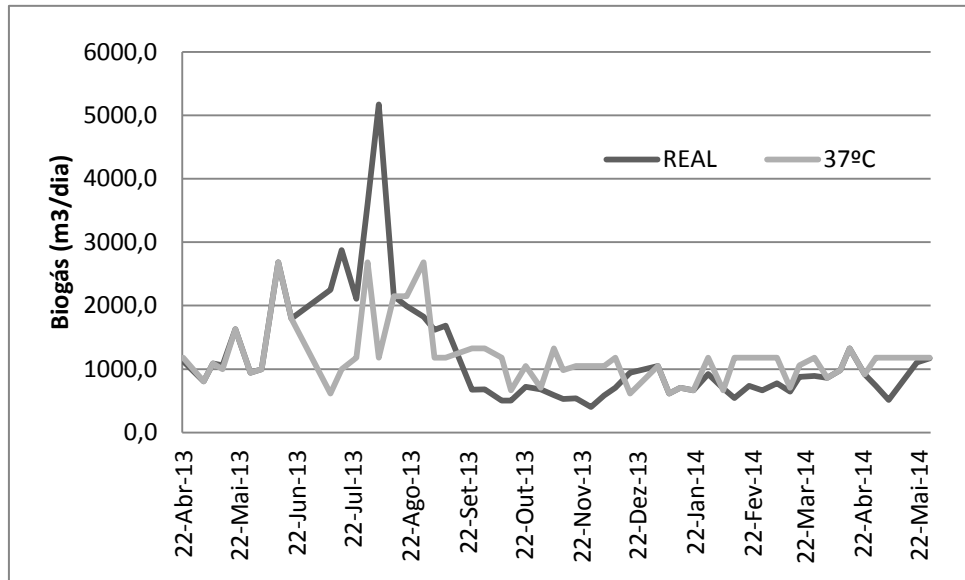


Gráfico 12. Comparação entre o biogás real (cinzento) com o biogás previsto a 38 °C (cinzento claro) para a rede "A2".

## **Anexo VII**

Comparação do Biogás Real com o Biogás  
Previsto pelas redes “A2” e “B15”

Tabela 20. Dados relativos ao Biogás Real produzido na ETAR do Ave, ao biogás previsto pela rede "A2" e o respetivo desvio padrão.

Dia	Temperatura °C (média)	Biogás Total REAL média m3/dia	Biogás Total PREVISTO m3/dia	Desvio Padrão
3-Jan-12	37,00	624,40	879,78	180,6
18-Jan-12	37,00	1186,71	1183,89	2,0
24-Jan-12	38,00	1171,71	879,78	206,4
31-Jan-12	34,00	738,29	690,99	33,4
7-Fev-12	38,00	807,29	886,37	55,9
22-Fev-12	34,00	438,57	577,05	97,9
28-Fev-12	32,00	244,71	194,69	35,4
6-Mar-12	34,00	621,71	881,74	183,9
14-Mar-12	35,00	929,43	879,78	35,1
27-Mar-12	38,00	813,86	879,78	46,6
3-Abr-12	36,00	538,57	879,78	241,3
20-Abr-12	37,00	949,29	879,79	49,1
26-Abr-12	32,00	791,57	894,86	73,0
4-Mai-12	37,00	570,29	879,79	218,9
9-Mai-12	38,00	719,00	879,79	113,7
16-Mai-12	38,00	803,71	934,11	92,2
24-Mai-12	38,00	1183,43	880,58	214,1
29-Mai-12	37,00	1096,71	888,39	147,3
5-Jun-12	37,00	774,57	880,23	74,7
14-Jun-12	36,00	1322,71	971,25	248,5
20-Jun-12	37,00	1715,00	884,50	587,3
29-Jun-12	37,00	950,00	881,70	48,3
5-Jul-12	36,00	924,71	920,14	3,2
19-Jul-12	37,00	1608,14	1033,97	406,0
27-Jul-12	37,00	1550,86	1554,67	2,7
17-Ago-12	35,00	1402,43	880,28	369,2
23-Ago-12	38,00	2061,00	2251,40	134,6
30-Ago-12	38,00	2128,00	2324,75	139,1
6-Set-12	38,00	2805,29	2904,07	69,9
12-Set-12	38,00	3500,71	3087,36	292,3
19-Set-12	38,00	3132,57	3414,76	199,5
26-Set-12	38,00	2418,43	2147,69	191,4
3-Out-12	38,00	1430,00	1373,55	39,9
16-Out-12	38,00	1138,00	879,81	182,6
24-Out-12	38,00	798,43	879,80	57,5
1-Nov-12	37,00	1393,71	880,11	363,2
8-Nov-12	38,00	1273,57	2991,86	1215,0
14-Nov-12	38,00	901,29	880,12	15,0
21-Nov-12	38,00	828,43	880,07	36,5
30-Nov-12	38,00	908,00	879,79	20,0
6-Dez-12	37,50	760,57	879,78	84,3
12-Dez-12	37,50	873,17	879,79	4,7
20-Dez-12	38,00	1265,29	879,78	272,6
26-Dez-12	38,00	1282,57	884,54	281,5



Continuação da tabela 20. Dados relativos ao Biogás Real produzido na ETAR do Ave, ao biogás previsto pela rede "A2" e o respetivo desvio padrão.

<b>Dia</b>	<b>Temperatura °C (média)</b>	<b>Biogás Total REAL média m3/dia</b>	<b>Biogás Total PREVISTO m3/dia</b>	<b>Desvio Padrão</b>
2-Jan-13	37,00	1037,71	879,78	111,7
10-Jan-13	37,00	1216,29	880,37	237,5
18-Jan-13	37,00	965,86	879,84	60,8
28-Jan-13	37,00	585,86	879,81	207,9
11-Fev-13	36,50	1074,57	880,20	137,4
22-Fev-13	36,50	893,29	1033,33	99,0
1-Mar-13	37,50	830,71	879,79	34,7
8-Mar-13	37,50	826,00	880,13	38,3
21-Mar-13	38,00	1751,57	880,21	616,1
4-Abr-13	36,00	506,14	882,84	266,4
12-Abr-13	36,00	598,86	501,17	69,1
19-Abr-13	36,00	1228,43	1189,28	27,7
22-Abr-13	36,00	1125,43	904,70	156,1
3-Mai-13	36,75	807,29	964,08	110,9
8-Mai-13	36,75	1089,71	1202,42	79,7
13-Mai-13	36,75	1060,00	1074,24	10,1
20-Mai-13	36,75	1627,14	879,78	528,5
28-Mai-13	36,75	942,71	879,79	44,5
3-Jun-13	37,30	998,14	891,71	75,3
12-Jun-13	37,30	2682,43	2542,72	98,8
19-Jun-13	37,30	1795,43	1529,35	188,1
10-Jul-13	38,20	2249,57	2218,95	21,7
16-Jul-13	38,20	2876,57	2257,26	437,9
24-Jul-13	38,20	2107,71	2731,68	441,2
30-Jul-13	38,20	3603,43	3341,89	184,9
05-Ago-13	37,75	5173,29	5142,32	21,9
13-Ago-13	37,25	2148,00	1818,00	233,3
20-Ago-13	37,75	1992,43	2220,50	161,3
29-Ago-13	37,93	1826,43	1950,04	87,4
04-Set-13	37,93	1617,71	1724,85	75,8
10-Set-13	37,93	1686,43	1525,55	113,8
24-Set-13	37,93	672,86	901,87	161,9
01-Out-13	37,93	679,43	879,82	141,7
10-Out-13	37,93	501,71	880,78	268,0
15-Out-13	37,93	501,14	880,84	268,5
23-Out-13	37,93	722,14	884,81	115,0
31-Out-13	37,93	680,86	880,16	140,9
07-Nov-13	37,93	588,57	915,55	231,2
12-Nov-13	37,93	526,29	881,56	251,2
19-Nov-13	37,93	539,14	882,85	243,0
27-Nov-13	37,93	400,29	879,80	339,1
04-Dez-13	37,93	583,86	879,83	209,3
10-Dez-13	37,93	703,57	955,12	177,9
18-Dez-13	37,93	942,71	884,68	41,0

Continuação da tabela 20. Dados relativos ao Biogás Real produzido na ETAR do Ave, ao biogás previsto pela rede "A2" e o respetivo desvio padrão.

Dia	Temperatura °C (média)	Biogás Total REAL média m <sup>3</sup> /dia	Biogás Total PREVISTO m <sup>3</sup> /dia	Desvio Padrão
2-Jan-14	37,10	1046,29	880,99	116,9
8-Jan-14	37,10	616,57	879,79	186,1
14-Jan-14	37,10	706,86	879,80	122,3
21-Jan-14	37,10	667,14	879,81	150,4
29-Jan-14	37,10	922,86	916,85	4,2
6-Fev-14	37,93	695,29	879,99	130,6
12-Fev-14	37,93	541,29	882,67	241,4
20-Fev-14	37,93	736,71	880,34	101,6
27-Fev-14	37,93	665,43	881,98	153,1
7-Mar-14	37,94	776,86	899,50	86,7
14-Mar-14	38,01	646,43	881,41	166,2
19-Mar-14	37,93	876,57	890,63	9,9
27-Mar-14	37,66	893,71	909,77	11,4
3-Abr-14	37,27	862,14	879,81	12,5
10-Abr-14	37,00	984,43	881,62	72,7
15-Abr-14	36,80	1327,14	880,98	315,5
23-Abr-14	36,86	916,86	879,87	26,2
29-Abr-14	35,93	735,86	879,78	101,8
6-Mai-14	35,75	512,00	879,78	260,1
21-Mai-14	37,60	1104,43	879,79	158,8
28-Mai-14	38,03	1168,14	879,86	203,8




Gráfico 13. Comparação entre o Biogás real da ETAR (cinzento) com o Biogás previsto pela rede "A2" (cinzento claro).

Tabela 21. Dados relativos ao Biogás Real produzido na ETAR do Ave, ao biogás previsto pela rede “B15” e o respetivo desvio padrão

Dia	Temperatura °C (média)	Gorduras (m3/dia)	Biogás Total REAL média m3/dia	Biogás Total PREVISTO m3/dia	Desvio Padrão
22-Abr-13	36,0	0	1125,4	1125,4	0,0
3-Mai-13	36,8	15,18	807,3	807,3	0,0
8-Mai-13	36,8	0	1089,7	1089,7	0,0
13-Mai-13	36,8	0	1060,0	1178,9	84,0
20-Mai-13	36,8	0	1627,1	1627,1	0,0
28-Mai-13	36,8	1,1	942,7	942,7	0,0
3-Jun-13	37,3	1,2	998,1	998,1	0,0
12-Jun-13	37,3	0,8	2682,4	2682,4	0,0
19-Jun-13	37,3	0	1795,4	1795,4	0,0
10-Jul-13	38,2	0	2249,6	1178,9	757,1
16-Jul-13	38,2	2,8	2876,6	2876,6	0,0
24-Jul-13	38,2	0	2107,7	2107,7	0,0
30-Jul-13	38,2	0,6	3603,4	3603,4	0,0
05-Ago-13	37,8	0,9	5173,3	5173,3	0,0
13-Ago-13	37,3	0,5	2148,0	2148,0	0,0
20-Ago-13	37,8	0	1992,4	1178,9	575,3
29-Ago-13	37,9	0,4	1826,4	1826,4	0,0
04-Set-13	37,9	0	1617,7	1178,9	310,3
10-Set-13	37,9	6	1686,4	539,1	811,3
24-Set-13	37,9	0,8	672,9	672,9	0,0
01-Out-13	37,9	3,9	679,4	679,4	0,0
10-Out-13	37,9	10,7	501,7	501,7	0,0
15-Out-13	37,9	9,8	501,1	501,1	0,0
23-Out-13	37,9	2,3	722,1	722,1	0,0
31-Out-13	37,9	2,1	680,9	680,9	0,0
07-Nov-13	37,9	0	588,6	672,9	59,6
12-Nov-13	37,9	23	526,3	526,3	0,0
19-Nov-13	37,9	4,4	539,1	539,1	0,0
27-Nov-13	37,9	0	400,3	400,3	0,0
04-Dez-13	37,9	0	583,9	583,9	0,0
10-Dez-13	37,9	20,95	703,6	1178,9	336,1
18-Dez-13	37,9	2,6	942,7	942,7	0,0

Continuação da tabela 21. Dados relativos ao Biogás Real produzido na ETAR do Ave, ao biogás previsto pela rede “B15” e o respetivo desvio padrão.

Dia	Temperatura °C (média)	Gorduras (m3/dia)	Biogás Total REAL média m3/dia	Biogás Total PREVISTO m3/dia	Desvio Padrão
2-Jan-14	37,1	1,3	1046,3	1046,3	0,0
8-Jan-14	37,1	0,9	616,6	616,6	0,0
14-Jan-14	37,1	3,4	706,9	706,9	0,0
21-Jan-14	37,1	6,5	667,1	667,1	0,0
29-Jan-14	37,1	2,5	922,9	1178,9	181,0
6-Fev-14	37,9	8,03	695,3	695,3	0,0
12-Fev-14	37,9	8,03	541,3	1178,9	450,8
20-Fev-14	37,9	1,9	736,7	736,7	0,0
27-Fev-14	37,9	1,4	665,4	665,4	0,0
7-Mar-14	37,9	0	776,9	776,9	0,0
14-Mar-14	38,0	1	646,4	646,4	0,0
19-Mar-14	37,9	2,4	876,6	722,1	109,2
27-Mar-14	37,7	24	893,7	893,7	0,0
3-Abr-14	37,3	22,3	862,1	862,1	0,0
10-Abr-14	37,0	24,02	984,4	984,4	0,0
15-Abr-14	36,8	0	1327,1	1327,1	0,0
23-Abr-14	36,9	0	916,9	916,9	0,0
29-Abr-14	35,9	0	735,9	735,9	0,0
6-Mai-14	35,8	0	512,0	512,0	0,0
21-Mai-14	37,6	0	1104,4	1178,9	52,6
28-Mai-14	38,0	0	1168,1	1168,1	0,0




Gráfico 14. Comparação entre o Biogás real da ETAR (cinzento) com o Biogás previsto pela rede “B15” (cinzento claro).

## **Anexo VIII**

### Previsão Instantânea para diferentes valores de Gorduras

Tabela 22. Previsão Instantânea a várias Temperaturas para a base de dados com gorduras.

Dia	Temperatura °C (média)	Gorduras (m3/dia)	Gorduras (m3/dia)	Gorduras (m3/dia)	Gorduras (m3/dia)	Biogás Total REAL media m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia	Biogás Total PREVISTO m3/dia
		REAL	valor fixo	valor fixo	valor fixo		Gorduras REAL	Gorduras = 2	Gorduras = 5	Gorduras = 8
22-Abr-13	36,0	0	2	5	8	1125,4	1125,4	1125,4	1125,4	1178,9
3-Mai-13	36,8	15,18	2	5	8	807,3	807,3	1178,9	1178,9	1178,9
8-Mai-13	36,8	0	2	5	8	1089,7	1089,7	1089,7	1089,7	1178,9
13-Mai-13	36,8	0	2	5	8	1060,0	1178,9	1178,9	1178,9	1178,9
20-Mai-13	36,8	0	2	5	8	1627,1	1627,1	1627,1	1627,1	1178,9
28-Mai-13	36,8	1,1	2	5	8	942,7	942,7	942,7	942,7	1178,9
3-Jun-13	37,3	1,2	2	5	8	998,1	998,1	998,1	998,1	1178,9
12-Jun-13	37,3	0,8	2	5	8	2682,4	2682,4	2682,4	2682,4	1178,9
19-Jun-13	37,3	0	2	5	8	1795,4	1795,4	1795,4	1795,4	1178,9
10-Jul-13	38,2	0	2	5	8	2249,6	1178,9	1178,9	1178,9	1178,9
16-Jul-13	38,2	2,8	2	5	8	2876,6	2876,6	2876,6	2876,6	2876,6
24-Jul-13	38,2	0	2	5	8	2107,7	2107,7	2107,7	2107,7	1178,9
30-Jul-13	38,2	0,6	2	5	8	3603,4	3603,4	3603,4	3603,4	1178,9
05-Ago-13	37,8	0,9	2	5	8	5173,3	5173,3	5173,3	5173,3	1178,9
13-Ago-13	37,3	0,5	2	5	8	2148,0	2148,0	2148,0	2148,0	1178,9
20-Ago-13	37,8	0	2	5	8	1992,4	1178,9	1178,9	1178,9	1178,9
29-Ago-13	37,9	0,4	2	5	8	1826,4	1826,4	1826,4	1826,4	1178,9
04-Set-13	37,9	0	2	5	8	1617,7	1178,9	1178,9	1178,9	1178,9
10-Set-13	37,9	6	2	5	8	1686,4	539,1	672,9	672,9	1178,9
24-Set-13	37,9	0,8	2	5	8	672,9	672,9	672,9	539,1	501,1
01-Out-13	37,9	3,9	2	5	8	679,4	679,4	679,4	679,4	679,4
10-Out-13	37,9	10,7	2	5	8	501,7	501,7	942,7	942,7	501,7
15-Out-13	37,9	9,8	2	5	8	501,1	501,1	539,1	539,1	501,1
23-Out-13	37,9	2,3	2	5	8	722,1	722,1	722,1	722,1	501,1
31-Out-13	37,9	2,1	2	5	8	680,9	680,9	680,9	680,9	501,1
07-Nov-13	37,9	0	2	5	8	588,6	672,9	672,9	539,1	501,1
12-Nov-13	37,9	23	2	5	8	526,3	526,3	680,9	539,1	501,1
19-Nov-13	37,9	4,4	2	5	8	539,1	539,1	539,1	539,1	501,1
27-Nov-13	37,9	0	2	5	8	400,3	400,3	400,3	400,3	695,3
04-Dez-13	37,9	0	2	5	8	583,9	583,9	583,9	644,2	690,2
10-Dez-13	37,9	20,95	2	5	8	708,6	1178,9	942,7	942,7	501,7
18-Dez-13	37,9	2,6	2	5	8	942,7	942,7	942,7	942,7	695,3
02-01-2014	37,1	1,3	2	5	8	1046,3	1046,3	1046,3	1046,3	667,1
08-01-2014	37,1	0,9	2	5	8	616,6	616,6	616,6	616,6	1178,9
14-01-2014	37,1	3,4	2	5	8	706,9	706,9	706,9	704,9	667,1
21-01-2014	37,1	6,5	2	5	8	667,1	667,1	706,9	667,1	667,1
29-01-2014	37,1	2,5	2	5	8	922,9	1178,9	1178,9	1178,9	1178,9
06-02-2014	37,9	8,03	2	5	8	695,3	695,3	646,4	695,3	695,3
12-02-2014	37,9	8,03	2	5	8	541,3	1178,9	665,4	665,4	1178,9
20-02-2014	37,9	1,9	2	5	8	736,7	736,7	736,7	736,7	736,7
27-02-2014	37,9	1,4	2	5	8	665,4	665,4	665,4	667,7	736,7
07-03-2014	37,9	0	2	5	8	776,9	776,9	776,9	776,9	1178,9
14-03-2014	38,0	1	2	5	8	646,4	646,4	646,4	695,3	695,3
19-03-2014	37,9	2,4	2	5	8	876,6	722,1	722,1	722,1	501,1
27-03-2014	37,7	24	2	5	8	893,7	893,7	665,4	1178,9	1178,9
03-04-2014	37,3	22,3	2	5	8	862,1	862,1	706,9	667,1	667,1
10-04-2014	37,0	24,02	2	5	8	984,4	984,4	1046,3	667,1	667,1
15-04-2014	36,8	0	2	5	8	1327,1	1327,1	1327,1	1327,1	1178,9
23-04-2014	36,9	0	2	5	8	916,9	916,9	916,9	916,9	1178,9
29-04-2014	35,9	0	2	5	8	735,9	735,9	735,9	735,9	1178,9
06-05-2014	35,8	0	2	5	8	512,0	512,0	512,0	512,0	1178,9
21-05-2014	37,6	0	2	5	8	1104,4	1178,9	1178,9	1178,9	1178,9
28-05-2014	38,0	0	2	5	8	1168,1	1168,1	1168,1	1168,1	1178,9
	Média	4,11								
				Diminuiu+				0	1	5
				Diminuiu		Contagem		5	7	14
				Mantem				6	8	14
				Aumentou				0	0	3
				Aumentou+						




Gráfico 15. Comparação da produção de biogás real (cinzento) com a respetiva quantidade de gordura (cinzento claro).

## **Anexo IX**

Conjunto de dados relativo a Junho e Julho de  
2014



Tabela 23. Conjunto de dados a usar na previsão com a rede "A2".

<b>Dia</b>	<b>SV g/L (TLMistas)</b>	<b>Q entrada m3/dia (dig 1 + Dig 2)</b>	<b>pH (média)</b>	<b>Temperatura °C (média)</b>	<b>AGV Global mgCaCO3/L</b>	<b>Alcalinidade Global mgCaCO3/L</b>	<b>Biogás Total media m3/dia</b>
03-Jun	44,2	96	7,34	38,09	1046,5	4433	
11-Jun	47,8	102	7,41	38,04	573,5	4460	
16-Jun	26,1	187	7,19	38,08	450	4193,5	
25-Jun	10,0	183	7,33	38,05	1010	4366,5	
02-Jul	28,5	202	7,41	37,90	906,5	4566,5	
14-Jul	18,1	97	7,26	37,30	473,5	4513	
22-Jul	24,1	212	7,26	36,80	533,5	4459,5	
30-Jul	10,3	271	7,16	37,60	346,5	4087	

Tabela 24. Conjunto de dados a usar na previsão com a rede "B15".

<b>Dia</b>	<b>SV g/L (TLMistas)</b>	<b>Q entrada m3/dia (dig 1 + Dig 2)</b>	<b>pH (média)</b>	<b>Temperatura °C (média)</b>	<b>Gorduras m3/dia</b>	<b>AGV Global mgCaCO3/L</b>	<b>Alcalinidade Global mgCaCO3/L</b>	<b>Biogás Total media m3/dia</b>
03-Jun	44,2	96	7,34	38,085	0	1046,5	4433	
11-Jun	47,8	102	7,41	38,04	0	573,5	4460	
16-Jun	26,1	187	7,19	38,08	1	450	4193,5	
25-Jun	10,0	183	7,33	38,045	0,7	1010	4366,5	
02-Jul	28,5	202	7,41	37,90	2,91	906,5	4566,5	
14-Jul	18,1	97	7,26	37,30	2,91	473,5	4513	
22-Jul	24,1	212	7,26	36,80	0,00	533,5	4459,5	
30-Jul	10,3	271	7,16	37,60	2,04	346,5	4087	

Tabela 25. Valores de Biogás Real produzidos pela ETAR que o NeuralTools desconhece.

<b>Dia</b>	<b>Biogás Total media m3/dia</b>
03-Jun	1100
11-Jun	1316
16-Jun	1656
25-Jun	1739
02-Jul	1764
14-Jul	898
22-Jul	1587
30-Jul	1499

