



INSTITUTO SUPERIOR DE ENGENHARIA DE LISBOA

Departamento de Engenharia Eletrotécnica de Energia e Automação

Sistema de otimização para gestão de armazenamento de energia elétrica em baterias

Gustavo Afonso Burgoa Dias
Licenciado em Engenharia Eletrotécnica

Dissertação para obtenção do grau de Mestre
em Engenharia Eletrotécnica – Ramo de Energia

Orientador (es):

Professor Doutor Filipe André de Sousa Figueira Barata
Professor Doutor Pedro Miguel Neves da Fonte

Júri:

Presidente: Professor Doutor Hiren Canacsinh

Vogais:

Professor Doutor João Hermínio Ninitas Lagarto
Professor Doutor Filipe André de Sousa Figueira Barata

Maio de 2023

Sistema de otimização para gestão de armazenamento de energia elétrica em baterias

Gustavo Afonso Burgoa Dias
Licenciado em Engenharia Eletrotécnica

Dissertação para obtenção do grau de Mestre
em Engenharia Eletrotécnica – Ramo de Energia

Orientador (es):

Professor Doutor Filipe André de Sousa Figueira Barata
Professor Doutor Pedro Miguel Neves da Fonte

Júri:

Presidente: Professor Doutor Hiren Canacsinh

Vogais:

Professor Doutor João Hermínio Ninitas Lagarto
Professor Doutor Filipe André de Sousa Figueira Barata

Maio de 2023

Resumo

Face ao caminho que é percorrido com o objetivo de promover a descarbonização das indústrias e da economia mundial, ao longo dos últimos anos tem vindo a ser estabelecidas várias metas e objetivos com o propósito de reduzir a dependência dos combustíveis fósseis. Neste âmbito, a estrutura do ISEL decidiu desenvolver um conjunto de medidas, contempladas na iniciativa ISELGreen. A implementação destas iniciativas previa a instalação de um sistema solar fotovoltaico para a produção de energia para autoconsumo, concluído no final de 2019.

Tendo em mente a otimização das necessidades energéticas do ISEL, para poder delinear estratégias num futuro próximo, serão desenvolvidos modelos de previsão associados ao consumo e à produção solar fotovoltaica, através de redes neuronais artificiais (RNA). Desta forma ao longo deste estudo foram definidas as variáveis que constituem estes dois modelos de previsão.

Com base nos modelos de previsão foi desenvolvido um sistema de otimização que visa a implementação de um sistema de armazenamento (SAE). O desenvolvimento deste modelo tem como foco minimizar o custo da energia consumida da rede, otimizando as trocas de energia entre o *campus* e a rede elétrica. Este sistema será desenvolvido através de um modelo de programação linear.

O objetivo será entender o impacto da implementação de um modelo de otimização com recurso a um SAE, onde o conjunto de entrada deste modelo tem como base os modelos de previsão desenvolvidos com recurso às RNA. No final do estudo será verificada a robustez/validade do modelo de previsão, comparando os resultados do modelo de otimização, com os valores de consumo e produção solar reais/medidos.

Combinando o modelo de previsão com o modelo de otimização foi possível estimar que a implementação de um SAE poderá resultar na redução de 1.1% no custo da energia consumida da rede, valor que foi obtido tendo em consideração os valores previstos. Considerando um modelo de previsão com erro nulo (valores medidos), foi conseguida uma redução no custo da energia consumida da rede de 1.6%.

Palavras-Chave: Modelos de previsão, otimização, redes neuronais artificiais, sistemas de armazenamento de energia.

Abstract

In light of the efforts being made with the objective of promoting the decarbonization of industries and of the global economy, multiple goals and objectives have been set in the past few years with the purpose of reducing fossil fuel dependence. Within this scope, the structure of ISEL has decided to develop a set of measures, contemplated in the ISELGreen initiative. The application of these measures predicted the installation of a photovoltaic system for the production of energy for self-consumption, concluded by the end of 2019.

Keeping in mind the optimization of the energetic demands of ISEL, in order to delineate strategies within the near future, forecasting models associated to the consumption and to the photovoltaic solar production will be developed, through artificial neural networks (ANN). As such, throughout this study, the variables that constitute these two forecasting models will be defined.

Based on the forecasting models, an optimization system will be developed aiming to implement an energy storage system (ESS). The development of this model will focus on minimizing the cost of energy consumption in the network, optimizing the energy exchanges between the *campus* and the electric network. This system will be developed using a linear programming model.

The final objective will be to understand the impact of the execution of an optimization model resorting to a ESS, where the origin set of this model is based on the forecast models developed with ANN's. At the end of the study the validity/robustness of the forecast model will be verified, by comparing the optimization model when the predicted values had a null prediction error. In a more practical sense, these consumption and solar production values correspond to the real/measured values.

By combining the forecast model with the optimization model, it was possible to estimate a 1.1% energy consumption cost reduction when implementing an ESS, a value obtained taking into consideration the forecast values. Considering a null error forecast model (measured values), a 1.6% energy consumption reduction was obtained.

Keywords: Artificial neural network, forecasting models, optimization, energy storage systems.

Agradecimentos

Aos professores Filipe Barata e Pedro Fonte, por me acompanharem no desenvolvimento desta dissertação, contribuindo para a resolução das inúmeras dúvidas e dificuldades que foram surgindo ao longo deste caminho. Agradeço a enorme paciência e disponibilidade de ambos, que estiveram sempre disponíveis para aconselhar e orientar-me até à conclusão deste estudo.

Aproveito para agradecer aos colegas e amigos de curso que fizeram parte desta viagem, nomeadamente ao Luís Manito, colega e amigo com quem passei uma quantidade infindável de tardes/noites durante a licenciatura e o mestrado, sempre com o foco e determinação para concluir esta etapa.

Aos meus pais e irmã que sempre me deram forças para conseguir concluir este percurso, que em momentos onde a convicção e a determinação se perdiam, as palavras certas e o apoio incondicional eram o suficiente para recuperar a força e o foco. As palavras de agradecimento estendem-se para além deste parágrafo, uma vez que esta dissertação não poderia ser concluída sem ajuda deles.

À Beli, que em momentos de muita dúvida, sempre teve a capacidade de mostrar-me que eu seria capaz de concluir esta fase da minha vida académica. Alguém que me acompanhou durante todo percurso do mestrado, ajudando-me a conciliar a minha vida profissional, pessoal e académica. O seu espírito combativo conseguiu contagiar-me, dando-me motivação e força para nunca desistir, mesmo nos momentos em que pensei que não seria capaz de concluir este estudo.

Índice

Resumo	iv
Abstract.....	v
Agradecimentos	vi
Índice	vii
Lista de Figuras	x
Lista de Tabelas	xii
Lista de Siglas.....	xiii
Lista de Símbolos	xiv
1 Introdução	2
1.1 Motivação	2
1.2 Objetivos.....	3
1.3 Estrutura da dissertação	3
2 Estado da Arte.....	6
2.1 Modelo de previsão solar	6
2.1.1 Modelos Físicos.....	7
2.1.2 Modelos Estatísticos.....	7
2.1.3 Sistemas Inteligentes	13
2.2 Modelo da previsão de carga	13
2.3 Sistemas de Armazenamento de Energia (SAE).....	15
2.4 Métodos de otimização/gestão da procura.....	16
2.5 Definição de bateria	19
2.5.1 BMS – Sistema de Gestão de uma bateria	19
2.5.2 Composição de uma Bateria.....	20
2.5.3 Classes de Baterias	21
2.5.4 Parâmetros de uma Bateria.....	23

2.6	Redes Neurais Artificiais	24
2.6.1	Modelo do perceptrão de Rosenblatt.....	26
2.6.2	Algoritmos de aprendizagem	30
2.6.3	Construção de uma rede neuronal	37
3	Modelos de Previsão	44
3.1	Caracterização do Problema	44
3.2	Dados do Problema	48
3.3	RNA – Conjunto de treino	53
3.3.1	Conjunto treino - Carga.....	53
3.3.2	Conjunto treino – Produção fotovoltaica	56
3.4	RNA – Conjunto de teste	59
3.4.1	Conjunto teste – Carga	59
3.4.2	Conjunto teste – Produção solar fotovoltaica.....	59
3.5	RNA – Simulação das redes	59
3.5.1	Simulação – Carga	59
3.5.2	Simulação – Produção solar fotovoltaica	65
4	Gestão da bateria / Caso aplicado	71
4.1	Capacidade da bateria	71
4.2	Modelo de gestão da bateria	72
4.2.1	Construção do modelo de otimização	72
4.2.2	Modelos de otimização – programação linear.....	75
4.3	Caso de estudo	78
4.3.1	Conjunto de dados	78
4.3.2	Parâmetros da bateria	80
4.3.3	Simulação do modelo de gestão do sistema	80
5	Conclusões	104
5.1	Sugestões de trabalho futuro	107

Referências Bibliográficas.....	108
ANEXOS	112
ANEXO A – Previsões de consumo mensal 2021	112
ANEXO B – Previsões de produção solar mensal 2021	114
ANEXO C – Modelo de otimização SAE 2021 (capacidade 2500 kWh e conversor 100 kW).....	116

Lista de Figuras

Figura 2.1 - Diferentes tipos de modelos de previsão solar [1].....	7
Figura 2.2 - Diferentes tipos de SAE baseado em [19]	16
Figura 2.3 - Características de um SAE - Bateria.....	16
Figura 2.4 - Técnicas de DSM adaptado de [20].....	17
Figura 2.5 - Reações eletroquímicas numa bateria.....	21
Figura 2.6 - Neurónio McCulloch e Pitts (1943) [32]	25
Figura 2.7 - Modelo do perceptrão [32]	27
Figura 2.8 - (1) Função escalo; (2) Função linear; (3) Função sigmóide [33].....	27
Figura 2.9 - Classes linearmente separáveis (\mathbb{R}^2) [32]	28
Figura 2.10 - (1) Função Booleana conjunção; (2) Função booleana disjunção [32]	28
Figura 2.11 - (1) Classes não linearmente separáveis; (2) Função booleana disjunção exclusiva (XOR).....	29
Figura 2.12 - Exemplo de rede do tipo perceptrão multicamada [33].....	29
Figura 2.13 - Rede <i>feedforward</i> com uma camada escondida [33].....	30
Figura 2.14 - RNA <i>feedback</i> [32].....	30
Figura 2.15 - Perda da capacidade de generalização [32]	39
Figura 2.16 - Característica teóricas do erro médio quadrático (MSE) do treino e validação.....	40
Figura 3.1- ODS adotadas pelo ISEL na categoria Energia [36].....	45
Figura 3.2 – Painéis instalados no edifício E e G (Adaptada Google Earth)	46
Figura 3.3 - Consumo 2021 vs PV 21 - abril.....	49
Figura 3.4 - Consumo 2019 vs PV 21 - abril.....	49
Figura 3.5 – Consumo do ISEL em 649 dias (Tamanho da amostra)	51
Figura 3.6 – Produção solar fotovoltaica do ISEL em 649 dias (Tamanho da amostra) 52	
Figura 3.7 – Modelo RNA – Entradas e Objetivo (Consumo ISEL).....	54
Figura 3.8 – Arquitetura da RNA a implementar (Consumo)	56
Figura 3.9 – Modelo RNA – Entradas e Objetivo (Produção solar).....	57
Figura 3.10 – Arquitetura da RNA a implementar (Produção fotovoltaica)	58
Figura 3.11- Carga ISEL – Previsto versus Real (REDE 1).....	60
Figura 3.12 – Carga ISEL – Previsto versus Real (REDE 3)	61
Figura 3.13 – Carga ISEL perfil verão – Previsto versus Real (REDE 1).....	62
Figura 3.14 - Carga ISEL perfil verão – Previsto versus Real (REDE 3)	62

Figura 3.15 – Carga ISEL – Previsto versus Real (RNA Final).....	63
Figura 3.16 – Média do MSE das 15 <i>redes</i> (maio 2021).....	64
Figura 3.17 – Carga ISEL – Previsto versus Real (maio 2021)	65
Figura 3.18 – Produção solar ISEL – Previsto versus Real (REDE 5).....	66
Figura 3.19 - Produção solar ISEL – Previsto versus Real (REDE 13).....	67
Figura 3.20 - Produção solar ISEL – Previsto versus Real (RNA Final)	67
Figura 3.21 - MSE das 16 <i>redes</i> (maio 2021).....	68
Figura 3.22 – Produção solar fotovoltaica ISEL – Previsto versus Real (maio 2021) ...	69
Figura 4.1 – Produção Solar Média (Apenas horas com produção).....	71
Figura 4.2 – Controlo do ciclo de carga e descarga de uma bateria, adaptado de [44] ..	72
Figura 4.3 – Somatório da potência excedente diária (Valores previstos)	73
Figura 4.4 – Modelo de gestão da Bateria (24 horas) adaptado de [45], [46]	74
Figura 4.5 – Tarifa energética praticada na figura 4.4.....	74
Figura 4.6 – Consumo previsto versus real	78
Figura 4.7 – Produção solar prevista versus real	78
Figura 4.8 – Consumo e produção solar do ISEL – Previsto (20/4/2021)	79
Figura 4.9 – Modelo de otimização – Dados previstos (20/4/2021)	81
Figura 4.10 – Custo de utilização da rede – Dados previstos (20/4/2021).....	84
Figura 4.11 - Modelo de otimização – Dados reais (20/4/2021).....	85
Figura 4.12 – Diferenças entre figuras 4.9 e 4.11 (20/4/21).....	86
Figura 4.13 - Custo de utilização da rede – Dados reais (20/4/2021)	87
Figura 4.14 – Diferenças entre figuras 4.9 e 4.11 (20/4/21).....	88
Figura 4.15 - Modelo de otimização – Dados previstos (20/4/2021)	90
Figura 4.16 - Custo de utilização da rede – Dados previstos (20/4/2021).....	91
Figura 4.17 - Modelo de otimização – Dados previstos (20/4/2021)	93
Figura 4.18 - Custo de utilização da rede – Dados previstos (20/4/2021).....	94
Figura 4.19 - Modelo de otimização (à esquerda) e Custo de utilização da rede (à direita) - Dados previstos.....	96
Figura 4.20 - Modelo s/ SAE (à esquerda) e Custo de utilização da rede (à direita) - Dados previstos	97
Figura 4.21 - Modelo de otimização (à esquerda) e Custo de utilização da rede (à direita) - Dados reais.....	99
Figura 4.22 - Modelo s/ SAE (à esquerda) e Custo de utilização da rede (à direita) - Dados reais	99

Lista de Tabelas

Tabela 3.1- Características elétricas do módulo DH-60-315	47
Tabela 3.2 – Eficiências dos Inversores instalados	47
Tabela 3.3 – Rácio do consumo da carga comparativamente com ano 2019 (Mensal) .	49
Tabela 3.4 – MSE para RNA com 50,40 e 10 elementos na camada escondida (ECE).	55
Tabela 3.5 – Média dos valores do MSE para RNA com 50, 40 e 30 neurónios na camada escondida	56
Tabela 3.6 – Redes utilizadas na previsão da carga	60
Tabela 3.7 - Redes utilizadas na previsão da produção solar fotovoltaica	65
Tabela 4.1 – Parâmetros de entrada do modelo de gestão da bateria	80
Tabela 4.2 – Comparação de custos – valores previstos versus reais.....	89
Tabela 4.3 - Parâmetros de entrada do modelo de gestão da bateria.....	89
Tabela 4.4 – Comparação de custos para diferentes capacidades	92
Tabela 4.5 - Parâmetros de entrada do modelo de gestão da bateria.....	92
Tabela 4.6 - Comparação de custos entre figura 4.10 e 4.18.....	95
Tabela 4.7 - Comparação de custos entre figura 4.15 e 4.19.....	96
Tabela 4.8 - Comparação de custos entre figura 4.19 e 4.20.....	97
Tabela 4.9 - Comparação de custos entre figura 4.21 e 4.22.....	100
Tabela 4.10 – Comparação de lucro entre modelo de previsão construído e modelo de previsão com erro nulo (SAE implementado)	100
Tabela 4.11 - Comparação de lucro entre modelo de previsão construído e modelo de previsão com erro nulo (Sem SAE).....	101
Tabela 4.12 - Comparação de custos entre sistema com SAE e sem SAE (modelo de previsão desenvolvido).....	101
Tabela 4.13 - Comparação de custos entre sistema com SAE e sem SAE (modelo de previsão com erro nulo).....	102

Lista de Siglas

ADALINE	<i>Adaptative Linear Element</i> (elemento adaptativo linear)
AG	Algoritmos genéticos
ANN	<i>Artificial neural network</i> (rede neuronal artificial)
AR	Modelos auto-regressivos
BMS	<i>Battery management system</i> (sistema de gestão da bateria)
DSM	<i>Demand Side Management</i> (gestão da procura)
ECE	Elementos na camada escondida
EMS	Modelo de Saída
ESS	<i>Energy storage system</i> (sistema de armazenamento de energia)
HFB	<i>Hybrid flow battery</i> (bateria de fluxo híbrida)
ISEL	Instituto Superior de Engenharia de Lisboa
MSE	Erro médio quadrático
MURE	Medidas de utilização racional de energia
ODS	Objetivos de Desenvolvimento Sustentável
PNT	Previsão numérica do tempo
POSEUR	Programa Operacional de Sustentabilidade e Eficiência no Uso de Recursos
RFB	<i>Redox flow battery</i> (bateria de fluxo redox)
RNA	Rede neuronal artificial
SAE	Sistema de armazenamento de energia
SI	Sistema inteligente
SoC	<i>State of charge</i> (estado da carga)
SoH	<i>State of health</i> (estado de saúde)

Lista de Símbolos

b_t	Estimativa da tendência da série – alisamento exponencial
C_{rede}	Preço da tarifa energética [cent/kWh]
C_{tot}	Custo da aquisição da energia elétrica da rede [cent]
d	Valores de saída observados - modelo do perceptrão
DSout	Dia da semana do dia a prever
DTout	Dia de trabalho do dia a prever
E_{bat}	Energia da bateria [kWh]
E_{max}	Energia máxima armazenada na bateria [kWh]
E_{min}	Energia mínima armazenada na bateria [kWh]
E_{rede}	Energia consumida da rede elétrica [kWh]
e_t	Erro – modelo AR
E_T^2	Erro quadrático total – Regra de delta
$f(y)$	Função ativação
F_t	Valor a prever – média móvel
G_t	Radiância instantânea t [W/m^2]
HoraAno24	Hora do ano do dia a prever [horas]
IrradGb24	Radiância direta do dia a prever [W/m^2]
L_t	Estimativa do nível da série – alisamento exponencial
MSE	Erro médio quadrático
N	Janela temporal do processo de otimização [horas]
o	Valores de saída observada – modelo do perceptrão
p	Números de padrões – retro-propagação dos erros
P_{bat}	Potência – carga/descarga da bateria [kW]
$P_{Consumo}$	Potência – Perfil de consumo do ISEL [kW]
P_{max}	Potência máxima de carregamento [kW]
P_{min}	Potência máxima de descarregamento [kW]
P_{pv}	Potência – produção solar fotovoltaica [kW]
P_{rede}	Potência – rede elétrica [kW]
pdin24	Valor da carga, nas 24 horas anteriores, ao dia a prever [kW]
pdinSM	Valor da carga há uma semana, relativamente ao dia a prever [kW]
pdout	Valor medido da carga do dia a prever [kW]

P_{net}	Diferença entre o valor do consumo e a produção solar, horário
Q_a	Carga disponível na bateria [Ah]
Q_r	Carga restante na bateria [Ah]
S_t	Componente sazonal – alisamento exponencial
SMAout	Semana do ano do dia a prever
SoC(t)	Estado da carga para o instante t [%]
TempAR24	Previsão da temperatura média horária do ar do dia a prever [°C]
w_0	Termo independente – modelo do perceptrão
w_i	Peso de ligação – modelo do perceptrão
X	Vetor de entrada – modelo do perceptrão
y	Resultado da soma ponderada – modelo do perceptrão
y_i	Variável dependente - modelo de regressão
α	Capacidade de alisamento
γ	Constante de alisamento exponencial
δ	Erro admissível
δ_j	Erro do neurónio j – algoritmo da retro-propagação dos erros
ΔT	Tempo entre cada interação
η	Coefficiente de aprendizagem
θ	Coefficiente do modelo da média móvel
φ	Coefficiente do modelo AR

Capítulo I

Introdução

Resumo:

Neste capítulo apresenta-se a motivação do estudo e os objetivos a alcançar. Também é definida a estrutura da dissertação, apresentado as várias etapas da mesma.

1 Introdução

1.1 Motivação

Com base no contexto geopolítico e instabilidade energética que envolve a economia mundial, é imperativo consciencializar a população para novas soluções, seguindo o caminho da descarbonização global. Neste processo de renovação existem várias rotas, entre elas a energia solar fotovoltaica, onde prima pela sua fácil aplicabilidade, tanto num meio citadino/urbano como no meio rural. Contudo a sua rentabilidade está fortemente dependente das condições meteorológicas e dos preços da energia elétrica definidos pelos mercados de energia. Atenuar estas lacunas/limitações é a chave para solidificar a energia solar fotovoltaica, conseguindo assim rivalizar com as energias fósseis.

Um dos pontos de estudo desta dissertação será compreender o perfil energético de uma instalação, neste caso o Instituto Superior de Engenharia de Lisboa (ISEL) bem como a capacidade de produção fotovoltaica. Nesta análise serão tratados os elementos associados ao consumo e autoprodução do *campus*, tendo sido recolhidos estes dados durante o intervalo temporal 2019-2021.

Estas análises têm como objetivo estudar a possibilidade de otimizar o consumo proveniente da rede elétrica, tentando numa primeira fase compreender o perfil de consumo da instalação. Uma vez mapeado o consumo do ISEL, a próxima etapa passará por dimensionar um sistema de baterias, de forma a alcançar uma gestão otimizada entre a energia consumida da rede e a energia vendida à rede. Este sistema de armazenamento poderá ser uma ferramenta importante, conseguindo mitigar a dependência da rede elétrica, conferindo ao consumidor a possibilidade de evitar o período de maior procura energética, colmatando esta necessidade com a energia armazenado no banco de baterias.

1.2 Objetivos

O desenvolvimento deste trabalho passa pela criação de um algoritmo de previsão de consumo e produção baseado em RNA's do tipo percepção multicamada. Em paralelo com o sistema das redes neuronais será criado um algoritmo responsável pela gestão otimizada das baterias.

O desenvolvimento do estudo passará pelos seguintes objetivos:

- Analisar os consumos de energia elétrica e de produção de energia fotovoltaica das instalações do ISEL, tendo em conta um conjunto de dados entre os anos de 2020 e 2021;
- Com base nos dados de consumo de produção solar fotovoltaica, será desenvolvida uma RNA com o objetivo de prever valores de consumo e produção solar das infraestruturas do ISEL;
- Desenvolvimento de um algoritmo de otimização de gestão dos sistemas armazenamento, dimensionado com base nos valores de consumo e produção fotovoltaica do ISEL;
- Simulação do algoritmo com a criação de diferentes casos de estudo, alterando os parâmetros do SAE, tentando entender o impacto do SAE na redução da tarifa energética do ISEL. Os valores de saída da RNA, também serão utilizados em conjunto com o modelo de otimização com o propósito de validar a aderência/qualidade do modelo de previsão desenvolvido neste estudo.

1.3 Estrutura da dissertação

A presente dissertação é constituída por 5 capítulos. No capítulo 1 é apresentada a motivação por detrás do estudo desenvolvido nesta dissertação, bem como os objetivos que são pretendidos alcançar no final do estudo.

No capítulo 2 são descritos diversos pressupostos teóricos que estão relacionados com os modelos e sistemas que foram desenvolvidos ao longo deste estudo. Neste capítulo também é feita uma breve caracterização/explicação do conceito de sistema de armazenamento de energia, incidindo principalmente nas baterias ião-lítio. De seguida

é feita uma exposição relacionada com as RNA, explicando a sua estrutura, bem como os diversos aspetos que compõem este tipo de sistema inteligente.

No capítulo 3 é desenvolvida a análise do conjunto de dados associado ao consumo do ISEL e da produção solar fotovoltaica. Neste mesmo capítulo são desenvolvidos os modelos de previsão de consumo e de produção solar fotovoltaica recorrendo a uma rede neuronal do tipo perceptrão multicamada, sendo avaliada a capacidade de previsão da RNA desenvolvida.

No capítulo 4 é criado o modelo de otimização com recurso a um sistema de armazenamento. Neste capítulo serão estabelecidos os parâmetros da bateria a implementar no sistema de otimização, e desenvolvido um problema de programação linear, responsável por gerir o sistema de otimização.

No capítulo 5 serão apresentadas algumas conclusões sobre os resultados obtidos ao longo do estudo como também serão elaboradas algumas propostas de melhoria para projetos futuros.

A secção denominada por Anexos, contém alguns resultados obtidos no capítulo 3 e 4 de forma mais aprofundada.

Capítulo II

Estado da Arte

Resumo:

Neste capítulo é abordado o estado da arte. São apresentadas algumas técnicas associadas a modelos de previsão de consumo e produção solar fotovoltaica assim como a caracterização de um sistema de armazenamento de energia e de uma rede neuronal artificial.

2 Estado da Arte

2.1 Modelo de previsão solar

Na prática a produção de energia através de sistemas solares fotovoltaicos encontra-se principalmente dependente de duas variáveis, a radiação e a temperatura a que as células fotovoltaicas são expostas. A influência da radiação prende-se com o facto de esta ter um grande impacto no valor da corrente produzida pelas células. No que diz respeito à temperatura, esta encontra-se diretamente relacionada com o valor de tensão gerada nas células fotovoltaicas, o aumento da temperatura irá causar uma diminuição da tensão. Outro fator que poderá ser equacionado é a velocidade do vento, contudo esta variável acaba por estar relacionada com a temperatura do painel solar. Um aumento da velocidade do vento poderá contribuir para o arrefecimento das células. Para lá destes, devem ser tidos em conta outros fatores que influenciam a produção de energia, como a localização geográfica onde a estrutura é instalada e a orientação e inclinação dos painéis. Paralelamente, a hora do dia e a altura do ano também têm um peso fundamental na quantidade de energia gerada.

Contudo a variável chave é a radiação solar, podendo ser dividida em 3 tipos: radiação direta, sendo esta toda aquela que incide diretamente sobre as células, radiação difusa, toda a radiação que é refletida pela atmosfera (nuvens e neblinas) e a radiação refletida, referente à radiação que é refletida pelo solo envolvente.

Uma vez definidas as variáveis do modelo de previsão solar, estão reunidas as condições para analisar diversas as categorias/modelos que caracterizam um modelo de previsão fotovoltaica[1]. Os modelos de previsão estão divididos em três categorias, modelos físicos, modelos estatísticos e sistemas inteligentes, como se mostra na figura 2.1.

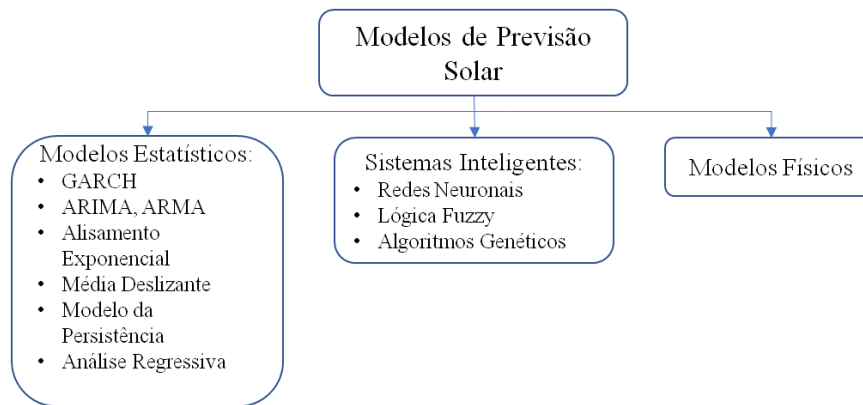


Figura 2.1 - Diferentes tipos de modelos de previsão solar [1]

2.1.1 Modelos Físicos

Para construir um sistema físico é necessário recolher dados meteorológicos. Esta análise pode ter como base a Previsão Numérica do Tempo (PNT), e estes mesmos dados devem ser ajustados ao local geográfico a estudar [2]. Este conjunto de dados pode ser aplicado a diversas formas de produção de energia renováveis, sendo que para o caso em estudo, os dados são adaptados ao modelo dos painéis fotovoltaicos. Com o propósito de atenuar o erro de previsão, associa-se ao modelo base o conceito da Estatística do Modelo de Saída (EMS) o qual por vezes se torna uma opção viável [3]. Esta metodologia acaba por não ser a escolha de eleição devido a exigir a capacidade de processamento encontrada em supercomputadores. Deste modo é utilizada fundamentalmente pelos serviços de previsão meteorológica.

2.1.2 Modelos Estatísticos

Analisando a figura 2.1, verifica-se que os modelos estatísticos contêm uma vasta gama de métodos de previsão. Estas soluções são normalmente utilizadas para conceber sistemas de previsão a curto-prazo [4]. Comparativamente com um modelo físico, um sistema construído numa base estatística poderá apresentar previsões com menor precisão. Todavia apresenta uma grande vantagem, apesar da sua simplicidade, pois face a um modelo físico permite obter resultados satisfatórios de uma forma mais rápida. De seguida serão abordados alguns tipos de modelos estatísticos.

2.1.2.1 Modelos de Regressão

Num modelo de regressão é estabelecida uma linha de tendência do conjunto de dados estatísticos, onde esta mesma linha será aplicada na projeção dos dados futuros. Na criação deste sistema poderão ser definidas equações de tendência, tanto do tipo linear como não linear [5]. É com base na análise dos padrões de tendência que será possível relacionar comportamentos registrados no passado com os valores que se pretendem prever no futuro. O modelo de regressão permite extrair a linha de tendência do conjunto de dados. A equação referente a um problema linear é descrita segundo a expressão (2.1):

$$y_t = X_t\beta + E_t \quad 2.1$$

A expressão (2.1) é composta pelas seguintes variáveis:

- y_t – valor previsto em t ;
- X_t – vetor de dimensão x variáveis explanatórias em t ($X_t = (1, x_{1t}, x_{2t}, \dots, x_{nt})$);
- β – vetor de coeficientes ($\beta = (\beta_0, \beta_1, \dots, \beta_n)$);
- E_t – erro em determinado t ($t = 1, \dots, N$).

Por outro lado, um problema não linear[1] poderá ser descrito através da expressão (2.2):

$$Y = f(X, \beta) + E \quad 2.2$$

Onde:

- Y – valor a ser previsto;
- β – vetor de coeficientes;
- f – função regressiva;
- E – termo referente ao erro.

Modelos lineares e não lineares são utilizados com frequência em modelos que têm o objetivo de prever valores de radiância solar ou velocidades do vento.

2.1.2.2 Modelos de Persistência

Talvez considerado o método de compreensão mais simples, o seu princípio de aplicação parte de assumir que os valores previstos serão iguais aos valores atuais. Neste modelo não é tido em conta o conjunto de dados no seu todo, apenas são considerados os dados anteriores ao instante a prever [6]. O modelo da previsão aplicado à previsão da radiação pode ser descrito segundo a expressão (2.3).

$$G_{t+1} = G_t \quad 2.3$$

Onde:

- G_t – valor de radiação no instante t (atual) [W/m^2];
- G_{t+1} – valor de radiação a prever [W/m^2].

Este modelo de persistência simples, apresentada na forma da expressão (2.3), pode ser melhorado ao ser considerado o “rácio de céu limpo” [7]. Assim é possível escrever a expressão (2.4).

$$G_{t+1} = G_t \cdot \frac{G_{t+1}^{\text{céu limpo}}}{G_t^{\text{céu limpo}}} \quad 2.4$$

Onde:

- $G_t^{\text{céu limpo}}$ - valor de radiação no instante t (atual), considerando céu limpo [W/m^2];
- $G_{t+1}^{\text{céu limpo}}$ - valor de radiação a prever, considerando céu limpo [W/m^2].

2.1.2.3 Modelos da Média Móvel

A este tipo de modelo é conferida a capacidade de alisar o conjunto de dados a estudar. O alisamento dos dados históricos é uma técnica fundamental para a detecção de um comportamento/ tendência. Dentro do conceito de média móvel existem divisões a ter em conta, como a média móvel simples ou mesmo a média móvel ponderada [8].

Um modelo assente na média móvel simples pode ser escrito sob a forma da expressão (2.5)

$$F_t = \sum_{j=-m}^m \frac{Y_{(t+j)}}{N} \quad 2.5$$

Na expressão 2.5, F_t representa o valor a prever com base na observação atual, Y é o valor observado. Trata -se de um modelo de média móvel de ordem k , onde $m = \frac{k-1}{2}$. Com isto, a ordem do modelo, m , deve ser escolhida com atenção, uma vez que este valor irá influenciar o comportamento da linha de tendência [9].

É de opinião geral de que a tendência será melhor capturada quanto maior for o intervalo de estudo capturado [1]. Uma das desvantagens apontadas a este modelo deve-se ao fato de todos os dados históricos apresentarem o mesmo peso. Ao analisar dados meteorológicos facilmente consegue-se entender a questão. Os dados vão perdendo importância conforme o intervalo de tempo aumenta. Valores registados há vários meses apresentam a mesma importância de um valor registado há um mês. Desta forma poderá conduzir a um modelo de previsão desatualizado com o presente.

2.1.2.4 Alisamento Exponencial

O método por alisamento exponencial poderá ser considerado como uma extensão/complemento do modelo de média móvel. Os dados históricos neste modelo serão organizados consoante o seu peso, valores mais antigos do conjunto de dados perdem importância de forma exponencial [10]. Dentro deste modelo existem várias categorias de alisamento exponencial, entre as quais, simples, duplo e triplo alisamento exponencial. A escolha da categoria a optar poderá ser realizada através de métodos iterativos, através dos quais será decidido o peso dos dados observados [9].

- Alisamento Exponencial Simples

Esta categoria de alisamento pode ser descrita segundo expressão (2.6)

$$F_{(t+1)} = \alpha \times Y_t(1 + \alpha)F_t \quad 2.6$$

O parâmetro F_t é o valor previsto da observação atual, F_{t+1} representa o valor previsto da amostra subsequente e por fim o valor de α determina a capacidade de alisamento, variando entre 0 e 1.

- Alisamento Exponencial Duplo (*Holt's linear trend method*)

Neste método, é necessário adicionar duas expressões, uma correspondente ao nível da série (2.7) e a outra correspondente à tendência da série (2.8).

$$L_t = \alpha Y_t + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad 2.7$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad 2.8$$

Analisando os elementos das expressões (2.7) e (2.8), α (nível) e β (tendência) são constantes de alisamento, enquanto l_t e b_t representam uma estimativa do nível da série e a uma estimativa da tendência da série, respetivamente.

- Alisamento Exponencial Triplo (*Holt-Winter's seasonal method*)

Nesta nova categoria é adicionada mais uma expressão, esta relacionada com a componente sazonal, com é apresentado na expressão 2.9.

$$S_t = \gamma(L_t - L_{t-1} - b_{t-1}) + (1 - \gamma)S_{t-s} \quad 2.9$$

A expressão 2.9 representa a componente sazonal (S_t), onde γ é a constante de alisamento sazonal, constante que varia entre 0 e 1.

2.1.2.5 Modelos Auto Regressivos (AR)

Num modelo AR, os valores atuais das variáveis são representados através de uma função regressiva baseada em dados mais antigos [11]. Desta forma, este sistema é reconhecido por ser uma regressão de valores anteriores. Aliado ao modelo da média móvel, será criada uma poderosa ferramenta apelidada de modelo ARMA. A junção destes dois métodos pode ser descrita da segundo a expressão (2.10).

$$Y_t = \varphi_1 Y_{t-1} + \varphi_2 Y_{t-2} + \dots + \varphi_p Y_{t-p} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad 2.10$$

Na expressão 2.10, p representa a ordem do modelo da média deslizante, e por sua vez o q representa a ordem do modelo autorregressivo. Deve ser tido em conta a escolha apropriada da ordem destes dois sistemas de modo a conferir uma boa capacidade de previsão ao modelo ARMA. A aplicabilidade deste sistema limita-se a problemas em que o conjunto de dados apresente uma natureza estacionária.

Analisando a expressão 2.10, Y_t representa o valor que é observado no instante t , φ representa o coeficiente do modelo AR, θ é designado como o coeficiente do modelo da média móvel, e_t é definido como o erro, e como mencionado no paragrafo anterior p e q são a ordens de ambos os modelos, média deslizando e AR respectivamente. No caso de o utilizador pretender aplicar a função 2.10 a um modelo de série temporal, será necessário ter em consideração três pontos:

- Garantir que o conjunto original Y_t é estacionário quanto à média e à variância;
- Escolher a ordem que se adequa ao problema;
- Definir os parâmetros θ e φ de acordo com o modelo.

Geralmente estes parâmetros são definidos recorrendo a uma ferramenta de otimização não linear, que tenta minimizar o somatório dos erros quadráticos.

2.1.2.6 Modelos ARIMA

Quando é descrito um modelo ARIMA é necessário ter em consideração que este tem em conta a componente irregular de uma série temporal. O modelo permite que sejam realizadas auto-correlações de valores diferentes de zero, o que irá permitir construir um sistema mais robusto [12]. Com o modelo ARIMA são aplicadas regressões às variáveis dependentes relativamente aos erros dos dados passados. Este novo modelo garante uma melhor capacidade de previsão face ao modelo AR perante dados que apresentem tendências sazonais. Devido à sua capacidade integral, o sistema ARIMA permite eliminar as componentes não-estacionárias, recorrendo à diferença entre séries temporais [9]. Os métodos da diferenciação têm como principal objetivo garantir a transformação de uma série temporal em uma série estacionária. Estando realizada esta transformação, o impacto da tendência e da sazonalidade referente à média da série temporal diminuem. A diferença entre estas séries temporais está explícita na expressão 2.11.

$$Y_t = Y_t - Y_{t-1} \tag{2.11}$$

2.1.3 Sistemas Inteligentes

Em problemas onde o conjunto de dados a estudar apresenta um comportamento não-estacionário ou irregular, utilizar um sistema inteligente (SI) pode ser uma opção viável [13].

Os SI estão definidos em diversas categorias/métodos, os mais utilizados nos diversos estudos e aplicações serão os sistemas criados com base em redes neuronais artificiais (RNA), algoritmos genéticos (AG) ou lógica *fuzzy*. Dependendo do tipo de problema a implementação destes sistemas pode variar, sendo por vezes a melhor opção a construção de um sistema híbrido, onde a junção de dois ou mais métodos poderá conduzir a uma melhor capacidade de previsão [14].

2.2 Modelo da previsão de carga

Ter a capacidade de prever a carga no futuro, concede a capacidade de planejar e gerir recursos de uma forma otimizada. Este estudo permite compreender quais as exigências de uma rede/consumidor, diagnosticando os diversos períodos críticos de consumo e desse modo traçar um plano de gestão da rede, sempre com o intuito de garantir a continuidade de serviço. Na maioria dos casos estudados, um diagrama de carga apresenta menos variabilidade comparando com um diagrama de produção solar fotovoltaico[15]. Normalmente as cargas apresentam um perfil de consumo com poucas variações, estando bem definidos os períodos de maior consumo, não existindo grandes oscilações no perfil de consumidor. Apesar de não existirem grandes oscilações de consumo ao longo de ano, a alteração mais significativa dá-se quando se pretende comparar um perfil de consumo de Verão com um perfil de consumo de Inverno, razão pela qual estes modelos devem ser construídos com a informação de carga de no mínimo um ano completo, assegurando assim o estudo dos diferentes cenários de consumo.

As previsões de carga podem ser definidas consoante três medidas temporais: curto-prazo, médio-prazo e longo-prazo [16]. Independentemente da medida temporal que esteja a ser utilizada, o método de previsão é construído muitas vezes com base em algum tipo de sistema inteligente [15]. Uma vez que a escala de previsão a utilizar neste estudo será a medida a curto-prazo, será esta sobre a qual iremos incidir.

Quando se escolhe trabalhar na base da previsão a curto-prazo, é essencial ter em consideração certos aspetos, entre os quais devem ser destacados os dados meteorológicos, o preço da energia, dados temporais e o perfil do consumidor. Os dados temporais podem ser compostos por diversas medidas de tempo, como a semana do ano, a hora do dia ou mesmo o dia da semana [16]. Dentro destas categorias ainda é possível criar outras subcategorias, nomeadamente, dentro dos dias da semana pode criar-se a divisão entre dias laborais e dias não-laborais. Todas estas medidas temporais tentam criar correlações entre o consumo e o período do ano, por exemplo, ao utilizar a semana do ano, são definidos diferentes períodos de consumo ao longo de um ano, enquanto a medida de tempo, dia da semana, irá permitir diferenciar um dia laboral de um dia não laboral, bem como traçar o comportamento da carga de uma forma mais pormenorizada. A criação deste modelo poderá tornar-se mais complexa quanto mais dados forem incluídos. Dependendo do perfil de consumidor poderá ser necessário introduzir outro tipo de dados, como a hora do ano ou até mesmo os feriados celebrados na zona geográfica em estudo. O peso dos dados meteorológicos é inegável, uma vez que o perfil de consumo sofre alterações consoante as oscilações da meteorologia, em função da temperatura medida no local, a qual deve ser tida em conta na construção de um modelo de previsões de carga. O terceiro ponto a considerar incide sobre o perfil do consumidor, existindo várias categorias a considerar, doméstico, comercial e industrial. No tratamento de dados a curto-prazo, existe uma série de técnicas estatísticas que foram desenvolvidas com a função de criar modelos de previsão de carga a curto-prazo. Algumas das técnicas têm como base o método de aproximação com dias similares, métodos de regressão, séries temporais, lógica *fuzzy* ou redes neuronais [1] [16].

A aproximação com base nos dados de um dia semelhante, tem como objetivo encontrar o dia com as características semelhantes ao dia que é pretendido prever. Esta busca inclui nos seus parâmetros os dados meteorológicos, o dia da semana e o dia do ano. Como resultado é expectável devolver como o valor previsto, a carga que reúna os parâmetros semelhantes a um dia presente na base de dados do modelo construído.

A construção de um modelo com base em métodos de regressão, por norma tenta englobar no seu sistema variáveis como a meteorologia, tipo de dia, perfil do consumidor, com o objetivo de encontrar relações entre estes pontos e a carga consumida [1].

Sistemas baseados em lógica *fuzzy* poderão ser utilizados na construção do modelo de previsão, sendo baseado em técnicas heurísticas [15]. Neste caso não existe um modelo

matemático por detrás do sistema criado, mas sim um conjunto de regras criadas pelo utilizador, que irão definir uma relação entre variáveis de entrada, por exemplo, dados meteorológicos e medidas temporais, e com base nas regras definidas, será devolvido um valor de carga como resultado da análise das restrições.

Por fim, o método que será abordado no final deste ponto é baseado em redes neuronais artificiais do tipo perceptrão multicamada. Este modelo irá combinar diversos perfis de carga e temperatura com o objetivo de encontrar relações matemáticas entre eles, e desse modo tentar prever a carga com um horizonte temporal de 24 horas. Devido à sua capacidade de encontrar relações entre variáveis com perfis tão distintos, ao longo deste projeto será explicada e abordada a implementação das redes neuronais no modelo de previsão da carga bem como na previsão da carga solar.

2.3 Sistemas de Armazenamento de Energia (SAE)

Um sistema de armazenamento de energia elétrica (SAE) é um conjunto de dispositivos, tecnologias e equipamentos que permitem o armazenamento e utilização de energia elétrica gerada por uma fonte primária, como um sistema de geração de energia renovável, ou ainda por sistemas de geração de energia convencionais[17]. Esta conversão irá permitir ao utilizador gerir/utilizar a sua reserva energética consoante as suas necessidades. Os SAE têm um papel preponderante tanto na escala do pequeno consumidor como no auxílio da gestão de uma rede elétrica. Estes sistemas têm a capacidade de regular o fluxo/direção da energia elétrica, deste modo permitindo controlar melhor a oferta e a procura no mercado elétrico. Uma clara vantagem deste sistema é o facto de oferecer uma nova flexibilidade no que diz respeito à gestão de cargas, permitindo por exemplo, armazenar energia nas horas de vazio para utilizar posteriormente esta mesma energia nas horas de ponta [18].

Os SAE podem dividir-se nas seguintes categorias: mecânicos, elétricos, químicos/eletroquímicos e térmicos [19]. Dentro de cada uma das categorias enumeradas anteriormente, é possível definir diferentes tipos de SAE, como é apresentado na figura 2.2.

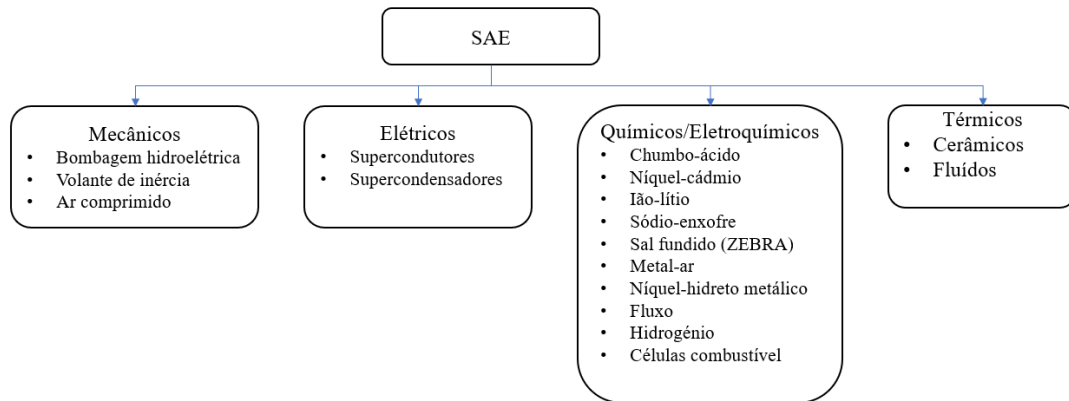


Figura 2.2 - Diferentes tipos de SAE baseado em [19]

O foco desta dissertação está na categoria dos SAE químicos/eletoquímicos, mais especificamente num sistema baseado em baterias. Para dimensionar um sistema de baterias é preciso analisar os parâmetros que definem esta tecnologia, como é apresentado na figura 2.3.




Figura 2.3 - Características de um SAE - Bateria

2.4 Métodos de otimização/gestão da procura

Os métodos de otimização/gestão de procura têm como propósito modelar o consumo do ponto de vista do consumidor, evitando-se incrementos do lado da produção. Esta gestão/otimização de procura é vulgarmente designada por *Demand Side Management* (DSM). Podem ser considerados alguns tipos de DSM, como a eficiência energética, os desvios de consumo ou corte de pontas [20].

O facto deste método atuar no perfil do consumidor, permite um melhor uso da energia disponível da rede, evitando assim, investir/expandir as infraestruturas elétricas, e possibilita a atenuação do consumo proveniente da rede. O princípio do DSM é garantir que as necessidades da carga são ajustadas às condições da produção. Sendo assim consegue definir-se estes métodos de gestão em três categorias diferentes [20], [21].

- Gestão de cargas: Redistribui a procura de energia com o objetivo de diminuir o consumo nos períodos de maior procura, transitando a necessidade energética para os períodos de menor procura;
- Conservação estratégica: Reduzir o consumo de energia, recorrendo a medidas de eficiência energética;
- Crescimento estratégico da carga: Alocar o consumo de energia aos períodos de menor procura

Dentro de cada uma das categorias apresentadas nos pontos anteriores, existem diversas técnicas que permitem otimizar a gestão de carga. Este conjunto de métodos encontra-se resumido na figura 2.4.

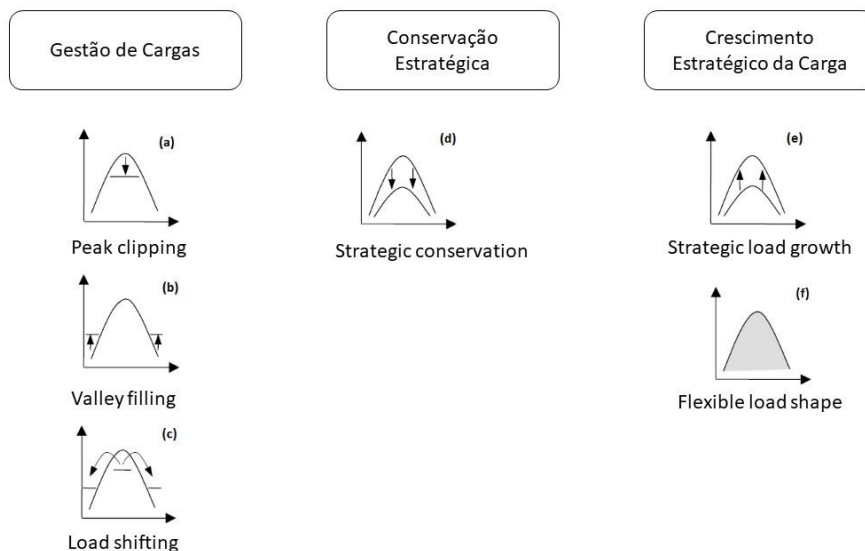


Figura 2.4 - Técnicas de DSM adaptado de [20]

- **Peak clipping**: Tem como princípio reduzir os picos de carga do sistema durante um período específico. Método utilizado em sistemas que não tenham a capacidade de satisfazer as necessidades da carga em horas de ponta;
- **Valley filling**: Tem como objetivo promover o aumento da carga em períodos de menor procura;
- **Load shifting**: Estes métodos têm como base a deslocação de cargas do período de ponta para o período de vazio. A utilização desta técnica obriga o consumidor a alterar o seu perfil de consumo de forma a consumir energia fora dos períodos em que a tarifa energética é mais elevada. A este método pode ser associado um SAE, onde nas horas em que a tarifa é mais baixa, o sistema é carregado,

utilizando a energia armazenada nas horas de ponta, atenuando o custo da energia consumida da rede.

- **Strategic conservation**: Esta estratégia pressupõe uma diminuição da carga num panorama geral, tanto nas horas de vazio como nas horas de ponta. A conservação energética passa por tornar o sistema energeticamente mais eficiente, contudo o objetivo deste método é garantir o mesmo nível de serviços. Existem dois tipos de medidas a considerar neste método, medidas passivas, onde o consumidor substitui os seus equipamentos antigos por equipamentos mais eficientes, ou medidas ativas, onde são implementados sistemas de controlo automático/dinâmicos.
- **Strategic load growth**: Estas soluções têm como princípio o aumento da carga em todos os períodos de consumo, incentivando os consumidores a substituir os seus equipamentos por sistemas mais eficientes. O objetivo é reduzir o custo médio de serviço, tentando dissipar o custo fixo através de uma maior base de venda de energia.
- **Flexible load shape**: Neste método é considerada a existência de um sistema que permita controlar os equipamentos dos consumidores, através do controlo de cargas. Esta solução pretende promover a estabilidade do sistema de fornecimento de energia.

Aliando estes métodos de DSM a um modelo matemático é possível desenvolver ferramentas de gestão/análise, que permitem ao utilizador aproximar a sua curva de consumo desejado. Este controlo fará com que em períodos onde o preço da energia seja elevado o consumo será reduzido, e períodos onde o preço da energia seja reduzido o consumo seja incrementado. O objetivo final desta análise é conseguir otimizar a relação custo/utilização, sem prejudicar a continuidade de serviço dos sistemas. Uma forma de tornar este sistema mais robusto, poderá passar por juntar a este método um SAE, tentando implementar o método dos desvios de consumo. Um bom exemplo de uma análise que tenta otimizar o perfil de consumo de um utilizador, tendo sempre em mente a carga desejada encontra-se descrita em [22].

Uma das formas de rentabilizar a energia proveniente de um sistema fotovoltaico é através do desenvolvimento de um SAE. Contudo, o funcionamento de um sistema de baterias também precisa de ser otimizado consoante as necessidades do sistema. Este controlo é feito através de um sistema de gestão de baterias, também conhecido como

battery management system (BMS). Por exemplo, em [23] é descrito um modelo onde o estado de carga/*state of charge* (SoC) de uma bateria é otimizado recorrendo a um BMS.

Um dos objetivos a alcançar neste estudo é tentar compreender qual a melhor forma de gerir o SoC, tentando atenuar o consumo proveniente da rede. Desta forma a bateria será carregada durante as horas de vazio e descarregada durante os períodos de ponta.

2.5 Definição de bateria

2.5.1 BMS – Sistema de Gestão de uma bateria

Quando existe a necessidade de construir um SAE, neste caso, um sistema com base em baterias, uma das etapas envolve o desenvolvimento de um sistema de gestão de baterias (BMS)[24]. Este sistema é composto por um controlador eletrónico que têm como funções controlar diversos parâmetros da bateria, sempre com o propósito de garantir uma utilização otimizada como também reduzir um certo grau de degradação associado aos ciclos de carga/descarga. Tipicamente um BMS pode ser responsável pela monitorização/controle de diversos aspetos de uma bateria como os mencionados nos seguintes pontos [25]:

- Proteção das células das baterias – Controlar parâmetros como a tensão, corrente, temperatura, evitando que estes atinjam valores próximos dos limites de construção;
- Equalização da carga entre baterias – Num sistema composto por um banco de baterias, esta função garante que todas as células têm o mesmo nível de tensão;
- Controlo carga/descarga – Garante que os carregamentos da bateria se mantêm dentro das recomendações especificadas pelo fabricante;
- Cálculo do estado de saúde das baterias/*State of Health* (SoH) –Indica o estado de saúde da bateria comparativamente com uma bateria nova;
- Cálculo do SoC – Parâmetro relevante na gestão de uma bateria, uma vez que este indica qual a capacidade restante de um sistema de baterias;

- Histórico – Importante devido a ter a capacidade de armazenar os dados associados a diferentes parâmetros, sendo possível analisar se a bateria foi sujeita a más utilizações;
- Comunicação – Ferramenta responsável por permitir a comunicação entre a bateria e outros equipamentos, sendo útil na realização de diagnósticos ou despistes.

A função de um BMS é permitir uma maior longevidade da bateria, tentando sempre atenuar os riscos associados à utilização indevida deste tipo de SAE.

2.5.2 Composição de uma Bateria

Numa primeira aproximação uma bateria pode ser resumida como um equipamento, composto por uma ou várias células, que têm a capacidade de transformar a energia química que está armazenada no seu interior em energia elétrica. Esta conversão acontece devido a uma reação eletroquímica de oxidação-redução [26]. A célula de uma bateria é composta por quatro elementos:

- Ânodo (Eléctrodo Negativo) – Fornece ao circuito externo os electrões, onde de seguida é oxidado devido a uma reação eletroquímica;
- Cátodo (Eléctrodo Positivo) – Recebe os electrões do circuito externo, sofrendo uma redução durante a reação eletroquímica;
- Eletrólito – Designado como meio de transferência de iões, localizado entre o ânodo e o cátodo, sendo normalmente um meio líquido com boa condutividade iónica;
- Separador – Este elemento tem como propósito impedir um curto-circuito entre os eléctrodos. Nem todos os tipos de baterias requerem este componente.

Na figura 2.5 está representado um esquema que traduz as reações que sucedem no interior de uma bateria, entre os elementos mencionados nos pontos anteriores.




Figura 2.5 - Reações eletroquímicas numa bateria

2.5.3 Classes de Baterias

Na categoria dos SAE baterias, é possível dividir este tipo tecnologia nas seguintes classes:

- **Baterias Primárias**

O tipo de bateria mais convencional, este tipo de bateria não tem a capacidade de ser recarregada, ou seja, não consegue transformar energia elétrica em energia química [27]. Estas baterias têm apenas uma utilização, uma vez que não é possível recarregá-las;

- **Baterias Secundárias**

Este tipo de bateria permite armazenar energia sob a forma de energia química, através de mecanismos/conversões designadas por processos redox. Através do uso de energia elétrica é possível reverter as reações químicas, desta forma as células no interior da bateria conseguem regenerar as suas propriedades químicas iniciais, sendo iniciado o recarregamento destas [17][28].

Dentro do universo das baterias secundárias existe uma vasta gama de tecnologias, entre as quais podem destacar-se a bateria de chumbo-ácido, enxofre-sódio, níquel-cádmio, níquel sódio e íons lítio [29].

Um ponto importante a ter em consideração é o nível de degradação de uma bateria, influenciado por um conjunto de fatores. O estado da carga, a temperatura ambiente da bateria ou mesmo o conceito denominado por *C-rate* são alguns dos aspetos que contribuem para a degradação do sistema de baterias. O conceito de *C-rate* pode ser definido como a taxa que relaciona o ritmo a que uma bateria vai descarregando comparativamente com a capacidade máxima desta. Não é fácil determinar o parâmetro da degradação, uma vez que estes fatores apresentam características não-lineares [30].

Dando um maior foco às baterias de íões de lítio, este tipo de SAE apresenta valores elevados de energia e potência específica, como também grandes ciclos de vida, comparativamente a outros tipos de bateria. Graças à constituição dos materiais catódicos que se encontram presentes no interior das baterias íões de lítio, esta classe de baterias consegue apresentar valores na ordem dos 85% - 98% relativamente a eficiências de ciclo. No que diz respeito a valores de auto-descarga, estes situam-se entre os 0.1% - 0.3% [29].

- **Baterias de Fluxo**

As baterias de fluxo podem ser divididas em dois grupos, redox e híbridas [17].

As baterias de fluxo redox, também conhecidas como *Redox Flow Battery* (RFB), têm como princípio de funcionamento reações de redução e oxidação. Este tipo de bateria é normalmente utilizado como complemento a UPS's.[28].

A segunda classe de baterias de fluxo é designada por híbridas, também conhecidas por *Hybrid Flow Battery* (HFB). Neste tipo de SAE um dos elétrodos é armazenado na célula eletroquímica, enquanto o eléctrodo oposto se encontra no estado líquido, armazenado no exterior. Esta categoria de bateria apresenta características mistas, tanto de uma bateria secundária como de uma bateria de fluxo [28].

Os pontos fortes deste tipo de SAE prendem-se com o fato de as baterias de fluxo apresentarem longos ciclos de vida, elevadas capacidades de potência, na ordem do MW, conjugando custos de manutenção acessíveis. Geralmente são utilizadas em produções de energia renovável em redes isoladas ou em *micro-grids* [17], [28].

2.5.4 Parâmetros de uma Bateria

Neste ponto serão abordados os diversos parâmetros que podem definir uma bateria. Tipicamente estes dados são fornecidos pelo fabricante, tendo sido obtidos sob condições específicas de funcionamento. É com base nestes dados que o utilizador irá seleccionar qual a bateria que melhor satisfaz as suas necessidades. De seguida serão apresentados alguns destes parâmetros [18] [31].

- **Capacidade (C)** – Corresponde à energia armazenada na bateria, sendo expressa em ampere-hora (*Ah*);
- **Capacidade Nominal (C_n)** – Corresponde à quantidade máxima de energia que uma bateria consegue armazenar. Este valor é calculado com base em condições específicas de funcionamento, desta forma este valor pode não corresponder ao valor máximo de energia que a bateria irá efectivamente armazenar (*Ah*);
- **Tensão Nominal** – Valor médio de tensão que é expectável observar durante o período de descarga (*V*);
- **Tensão de Circuito Aberto** – Valor de tensão medido nos terminais da bateria num momento em que não existe carga. Este parâmetro é muitas vezes associado à quantidade de energia que ainda resta na bateria. Este valor deve ser registado após um período de repouso da bateria (*V*);
- **Tensão de Final de Descarga** – Valor mínimo de tensão (em carga) que a bateria pode alcançar (*V*);
- **Energia e Potência Específica** – Corresponde à quantidade total de energia em watt-hora (*Wh*) e potência (*W*) que é armazenada na bateria por quilograma (*Kg*). Este parâmetro é bastante utilizado ao comparar baterias diferentes;
- **Densidade Energética** – Quantidade de energia (*Wh*) que uma bateria consegue armazenar por unidade de volume (m^3);
- **Densidade de Potência** – Quantidade de potência (*W*) que uma bateria consegue armazenar por unidade de volume (m^3);
- **Ciclo de Vida** – Corresponde ao número de ciclos de carga/descarga de uma bateria até ao ponto em que a bateria quando é carregada não consegue alcançar o valor 70% do seu valor nominal de tensão;
- **SoC** – O estado da carga (SoC) representa a relação entre a energia disponível na bateria e a energia que é possível armazenar nesta, dado em percentagem. Com

base neste parâmetro é possível apurar a quantidade de energia que as baterias têm para fornecer, sendo assim possível calcular o tempo de funcionamento do SAE. O SoC pode ser descrito segundo a expressão 2.12.

$$SoC(t) = \frac{Q_a(t)}{Q_n} \times 100\% \quad 2.12$$

O termo Q_a na expressão 2.14 refere-se à capacidade disponível em ordem ao tempo, enquanto o termo Q_n está relacionado com a capacidade nominal da bateria. É de fácil compreensão o significado por detrás deste parâmetro, um valor de 100% indica que a bateria se encontra totalmente carregada, por outro lado, um SoC de 0% significa que a bateria se encontra sem carga ativa.

Apesar de estes parâmetros determinarem as condições de funcionamento de uma bateria, temas como a temperatura, a amplitude das correntes de carga/descarga, ou o tempo a que o sistema se encontra exposto a estes picos de corrente devem ter sido em conta uma vez que estes têm a capacidade de alterar as características e comportamentos do sistema de baterias, podendo levar a um desgaste mais precoce, ou até, no limite, conduzir à destruição da bateria [31].

2.6 Redes Neurais Artificiais

Este tipo de SI é inspirado na anatomia do neurónio biológico, o propósito deste método passa por tentar replicar as características do neurónio num modelo computacional. Com base neste princípio é criado um modelo, conhecido como RNA. O propósito de uma RNA será replicar algumas das características do neurónio biológico, nomeadamente [32]:

- Capacidade de aprendizagem e generalização;
- Flexibilidade, de modo a facilmente adaptar-se a novas situações aprendendo a lidar com as mesmas;
- Capacidade de lidar com facilidade com informação inconsistente e altamente ruidosa, de modo a retirar o essencial, desprezando a informação que não contenha dados relevantes;
- Processamento paralelo de grandes quantidades de informação.

Numa primeira aproximação a estrutura de uma RNA pode definir-se como um conjunto de neurónios, também designados por unidades, que estando ligados entre si

através de canais de comunicação unidirecionais transportam dados numéricos e processam essa informação[32].

Atualmente, as redes neuronais artificiais têm uma ampla variedade de aplicações, como o reconhecimento de fala e imagem, medicina, esporte, engenharia e até mesmo no controlo de ações domésticas simples. No entanto, são geralmente utilizadas em situações em que não se conhece completamente o sistema em estudo, não havendo uma relação facilmente identificável entre as entradas e saídas do sistema[32], [33].

Por conseguinte, a principal vantagem das RNA's é que não é necessário conhecer profundamente o sistema a ser estudado previamente. O estudo das redes neuronais artificiais teve início com a publicação de um artigo intitulado "*A Logical Calculus of the Ideas Immanent in Nervous Activity*" por Warren McCulloch e Walter Pitts em 1943 no *Bulletin of Mathematical Biophysics* [34]. Os autores descreveram que uma rede neuronal pode ser caracterizada como um conjunto de unidades (neurónios) interligados por canais de comunicação unidirecionais (chamados ligações), que transportam dados numéricos e processam informações. Este neurónio pode ser representado segundo a figura 2.6:




Figura 2.6 - Neurónio McCulloch e Pitts (1943) [32]

Existem muitos modelos e algoritmos disponíveis para ajustar os parâmetros de uma RNA. Quanto aos modelos, é possível distinguir duas categorias [34]:

- **Redes estáticas** - em que a saída de cada neurónio depende apenas do valor atual das suas entradas;
- **Redes dinâmicas** - em que as unidades são governadas por equações diferenciais ou de diferenças.

No que se refere aos algoritmos de aprendizagem, estes operam ao nível das conexões entre os neurónios, ajustando os pesos dessas conexões. A maioria das redes neuronais possui uma regra de adaptação que permite que os seus parâmetros sejam

ajustados com base em padrões que são apresentados à mesma. Esse pormenor é extremamente importante, pois permite que a rede aprenda com exemplos, sem que seja necessário sintetizar completamente o modelo. Assim sendo, é possível caracterizar as RNA quanto a algoritmos de aprendizagem da seguinte forma [32]:

- **Aprendizagem supervisionada:** Neste tipo de rede o treino da mesma é realizado com base nos valores de entrada e saída que lhe são apresentados. É com base num determinado valor de precisão que o processo de aprendizagem é concluído. Para as situações em que o valor devolvido não esteja compreendido no intervalo desejado, a rede irá tentar corrigir esse mesmo valor. Em paralelo, decorre um fluxo associado aos erros de todos os elementos afetos ao processo de aprendizagem. Durante este fluxo, o erro tende a ser minimizado, uma vez que os pesos das conexões vão sendo continuamente ajustados, até ao ponto em que a RNA alcance uma determinada precisão.
- **Aprendizagem Não-Supervisionada** – categorizado como um método de aprendizagem, onde a rede irá aprender sem existir treino prévio. Desta forma, o valor desejado para a saída é obtido através de entradas repetitivas até ser atingido o ponto em que a RNA seja capaz de reter o conhecimento. Neste cenário não existem influências externas capazes de ajustar o peso de cada variável. Na realidade este sistema de aprendizagem irá criar redundâncias entre os dados com o propósito de encontrar padrões/características no conjunto de dados observados.

2.6.1 Modelo do perceptrão de Rosenblatt

Em 1958, Rosenblatt prosseguiu com as pesquisas de McCulloch e Pitts, criando um modelo de um neurónio discriminador linear chamado de perceptrão. Este modelo simplificado é representado na figura 2.7.




Figura 2.7 - Modelo do perceptron [32]

O perceptron recebe um vetor de entrada, composto por números reais $\mathbf{X} = [x_1, x_2, \dots, x_n]$, onde n depende do número de entradas do perceptron, calculando a soma ponderada de cada peso w_i ($i = 1, \dots, n$) multiplicado pelo valor de entrada x_i , e do valor do termo independente ou de polarização multiplicado pelo peso w_0 . Ao resultado dessa soma ponderada, y , é aplicada uma função de ativação $f(y)$, que é uma função não linear que produz uma saída observada (o).

O modelo do perceptron pode ser descrito segundo a expressão 2.13.

$$o = f\left(\sum_{i=1}^n w_i x_i + w_0\right) \quad 2.13$$

No que diz respeito às funções de ativação, estas podem assumir a forma de uma função escalo, linear ou sigmóide. Na figura 2.8 estão exemplificadas as funções mencionadas anteriormente




Figura 2.8 - (1) Função escalo; (2) Função linear; (3) Função sigmóide [33]

Recorrendo a uma função de ativação do tipo escalo, é conferido ao perceptron a capacidade de classificar padrões e separar conjuntos de dados. Neste processo, os padrões de uma determinada classe produzem uma saída com valor 0, enquanto os

padrões da outra classe produzem uma saída com valor 1. Sobre a função de classificador, o perceptron só consegue separar classes que formem conjuntos no espaço \mathbb{R}^n , segundo a expressão 2.14 [32].

$$w_0 + \sum_{i=1}^n w_i x_i = 0 \quad 2.14$$

O objetivo da expressão 2.14 é separar a região que produz a saída 0 da região que produz a saída com o valor 1. Esta separação pode ser observada na figura 2.9.




Figura 2.9 - Classes linearmente separáveis (\mathbb{R}^2) [32]

Os modelos apresentados na figura 2.8 têm a capacidade para resolver alguns problemas de álgebra Booleana, atribuindo o valor 0 a uma condição falsa e o valor 1 a uma condição verdadeira. Este comportamento permite mapear o conjunto x e o conjunto y , como é exemplificado na 2.10 [33], [34].




Figura 2.10 - (1) Função Booleana conjunção; (2) Função booleana disjunção [32]

Enquanto o peceptrão consegue resolver funções lógicas nos conjuntos representados nas figuras 2.9 e 2.10, nos problemas que apresentem classes não linearmente separáveis ou sejam caracterizados por uma função Booleana disjunção exclusiva (XOR), este não irá conseguir resolver o problema. Na figura 2.11 estão ilustrados estes dois casos.




Figura 2.11 - (1) Classes não linearmente separáveis; (2) Função booleana disjunção exclusiva (XOR)

Assim sendo, é possível observar que para resolver o problema da disjunção exclusiva, é necessário adicionar mais perceptrões, criando mais uma camada. Esta adição irá originar uma nova tipologia designada por perceptrão multicamada, retratado na figura 2.12.

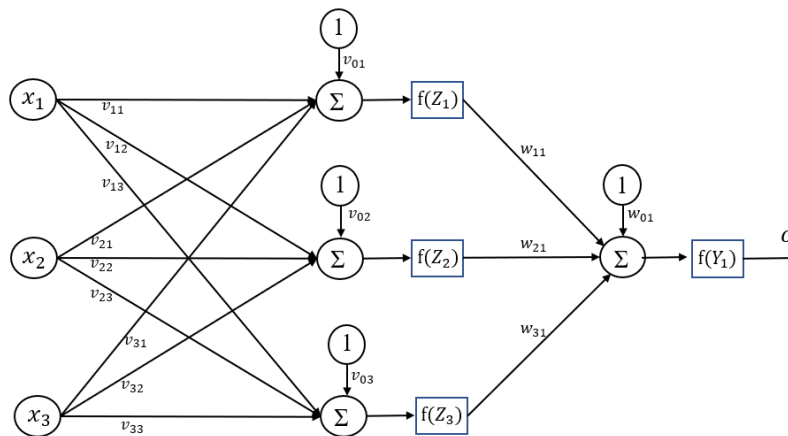


Figura 2.12 - Exemplo de rede do tipo perceptrão multicamada [33]

A informação é propagada da entrada para as camadas seguintes. A camada seguinte é composta pelos neurónios que recebem as saídas da camada de entrada e assim por diante, até chegar à camada de saída. As camadas que não são nem a de entrada nem a de saída são conhecidas como camadas escondidas [34], [35].

Em relação ao número de camadas escondidas, geralmente é recomendado usar apenas uma, já que George Cybenko demonstrou que uma única camada escondida é suficiente para resolver qualquer problema de aproximação de funções em uma rede do tipo *feedforward*, desde que o universo de dados seja contínuo e limitado. Na figura 2.13 está exemplificada uma rede *feedforward* [32].




Figura 2.13 - Rede *feedforward* com uma camada escondida [33]

Uma rede também pode ser do tipo rede *feedback*. Nesta tipologia de rede, é utilizada a técnica de alimentar as entradas com recurso às suas saídas. Ao contruir-se uma rede segundo este tipo de ligações, é possível criar um sistema dinâmico, onde o comportamento cíclico dos dados conduz à criação de uma espécie de memória a curto-prazo. Na figura 2.14 está exemplificado este tipo de ligação.




Figura 2.14 - RNA *feedback* [32]

2.6.2 Algoritmos de aprendizagem

Quando o problema a resolver envolve a implementação de funções booleanas disjunção ou conjunção de duas variáveis, a escolha dos pesos das ligações entre

neurónios é relativamente simples. Contudo, em problemas em que as RNA apresentem arquiteturas mais complexas a escolha dos pesos das ligações torna-se mais desafiante, uma vez que aumenta o número de graus de liberdade do problema. Com o objetivo de contornar esta dificuldade, Rosenblatt propôs um método para a resolução do problema.

- **Perceptrão de Rosenblatt**

Rosenblatt propôs um método de aprendizagem para resolver problemas de classificação utilizando o perceptrão representado na figura 2.7 e a função de ativação escalo ilustrada na figura 2.8. O algoritmo começa com uma inicialização aleatória dos pesos w_i e atualiza esses pesos sucessivamente durante o processo de aprendizagem. Este processo é realizado com base na expressão 2.15.

$$\begin{cases} \Delta w_i = 0 & \text{se } o = d \\ \Delta w_i = \eta x_i & \text{se } o = 0 \text{ e } d = 1 \\ \Delta w_i = -\eta x_i & \text{se } o = 1 \text{ e } d = 0 \end{cases} \quad 2.15$$

Onde:

- o – Valores de saída observados;
- d – Valores de saída desejados;
- x_i – Vetor composto pelos valores de entrada;
- η – Coeficiente de aprendizagem.

Rosenblatt apresentou um algoritmo de aprendizagem para problemas de classificação usando o perceptrão e a função de ativação apropriada. Ele demonstrou que o algoritmo converge para uma solução em tempo finito, desde que seja apresentado um número finito de padrões e que cada padrão ocorra um número infinito de vezes numa sequência apropriada, de forma a garantir convergência [32].

- **Regra de delta**

Em paralelo, Windrow e Hoff, desenvolveram um modelo neuronal linear, onde é desconsiderada a função de ativação. Esta estrutura foi apelidada de *Adaptive Linear Element* (ADALINE). Ao contrário do perceptrão de Rosenblatt, esta estrutura produz uma saída analógica [32].

Considerando um conjunto com k padrões de treino é possível representar este algoritmo de aprendizagem através da expressão 2.16.

$$o^k = \sum_{i=1}^n w_i x_i + w_0 \quad 2.16$$

Recorrendo ao erro quadrático total, é possível avaliar a *performance* da estrutura, procedimento descrito através da expressão 2.17.

$$E_T^2 = \sum_k (o^k - d^k)^2 \quad 2.17$$

A função de erro quadrático total depende dos pesos da rede neuronal e o objetivo do processo de treino é encontrar os pesos que minimizam essa função. Uma abordagem para alcançar essa minimização é o método de descida do gradiente.

Calculando a derivada parcial da expressão 2.17 em ordem a w_i , onde $e^k = o^k + d^k$, obtém-se a expressão 2.18.

$$\frac{\partial E_T^2}{\partial w_i} = 2 \sum_k e^k x_i^k \quad 2.18$$

O objetivo da expressão 2.18, é alcançar um valor de w_i que minimize o erro quadrático do conjunto X^k . Esta validação corresponde à condição apresentada na expressão 2.19.

$$E(w_i^{(n+1)}) \leq E(w_i^{(n)}) \quad 2.19$$

Através do método do gradiente, considerando um ponto arbitrário, $w(0)$, é possível prosseguir em direção ao ponto mínimo. Assim sendo é necessário evoluir sempre no sentido oposto ao do gradiente naquele mesmo ponto. Este processo é representado na expressão 2.20:

$$w_i^{(n+1)} = w_i^{(n)} + \eta \sum_k x_i^k e^k \quad 2.20$$

Na expressão 2.20, η representa uma constante positiva, responsável pela dimensão do passo que será dado em direção ao ponto mínimo. Também considerado como parâmetro do passo de aprendizagem.

O problema do método apresentado na expressão 2.20, prende-se com o fato de a aprendizagem ser lenta, devido aos pesos só serem atualizados depois de todos os padrões de entrada serem analisados.

De forma a contornar este problema, Windrow e Hoff redesenharam o modelo de forma aos pesos serem atualizados após a apresentação de cada padrão de entrada. Assim sendo, a expressão 2.20 foi reescrita, criando a expressão 2.21

$$w_i^{(n+1)} = w_i^{(n)} + \eta x_i^k e^k \quad 2.21$$

Contudo é possível simplificar a expressão 2.21, obtendo uma versão mais generalizada, apresentada na expressão 2.22.

$$w_i^{(n+1)} = w_i^{(n)} + \Delta w_i^{(n)} \quad 2.22$$

A expressão 2.22 representa o algoritmo designado por regra de delta. Para os casos em que o parâmetro η for reduzido, o efeito obtido após percorrer todos os padrões é semelhante ao resultado obtido através do método do gradiente. Em determinadas situações este método pode corresponder a um método estocástico de gradiente descendente.

- **Algoritmo da retro-propagação dos erros**

Como mencionado anteriormente um algoritmo de aprendizagem tem como propósito ajustar o valor dos pesos de uma rede, tendo sempre no seu horizonte a minimização do erro entre os valores desejados e observados. Estando definido o método de aprendizagem de uma RNA, neste caso aprendizagem supervisionada, é usual escolher como algoritmo de treino o método da retro-propagação dos erros. Estabelecido como um método de gradiente descende, procura minimizar o erro quadrático das saídas de uma RNA, durante o decorrer do processo de treino[34].

O algoritmo da retro-propagação dos erros pode dividir-se em duas etapas, *forward* e *backward*. Na primeira fase, *forward*, a rede é inicialmente sujeita a um

estímulo, onde de seguida é registado o erro da resposta em relação ao valor de saída que era esperado. Desta forma, avança-se para a etapa *backward*, onde o erro da etapa anterior é propagado pela rede, originando uma cadeia de ajustes nos pesos das ligações entre os neurónios. O método da retro-propagação dos erros é definido como sendo um método de primeira ordem, isto é, recorre apenas aos dados das derivadas de primeira ordem do erro quadrático do valor das saídas para ajuste dos pesos, tendo como principal objetivo minimizar o erro [32].

Este algoritmo mede o desempenho da rede, recorrendo à soma dos erros quadráticos, que pode ser escrita segundo a expressão 2.23.

$$E = \frac{1}{2} \sum_p \sum_{i=1}^k (d_i^p - y_i^p)^2 \quad 2.23$$

Os elementos da expressão 2.23 podem ser definidos da seguinte forma:

- E – Erro total;
- p – Número de padrões;
- k – Número de unidades de saída;
- d_i – Saída desejada i ;
- y_i – Valor observado i .

Como complemento à regra de delta é necessário definir as funções de ativação, descritas através das expressões 2.24 e 2.25.

$$y_j^p = f_j(\text{net}_j^p) \quad 2.24$$

$$\text{net}_j^p = \sum_{i=1}^n x_i^p w_{ji} + w_{j0} \quad 2.25$$

Os elementos das funções de ativação 2.24 e 2.25 são caracterizados da seguinte forma:

- n – Número de ligações de entrada ao neurónio j ;
- w_{ji} – Pesos de ligação;
- w_{j0} – Peso do termo independente (*bias*);
- x_i^p - Elemento de entrada.

Ao ser considerado que a minimização de um padrão conduz à minimização do erro total, a expressão 2.16 pode ser reescrita conforme a expressão 2.26.

$$E = \frac{1}{2} \sum_{i=1}^k (d_i^p - y_i^p)^2 \quad 2.26$$

Um dos princípios da regra de delta define que a variação dos pesos seja estipulada de acordo com o gradiente descendente do erro em relação ao peso. Sendo assim é possível escrever a expressão 2.27 [33], [34].

$$\Delta w_{ji} = \frac{-\partial E}{\partial w_{ji}} \quad 2.27$$

O passo seguinte é definir a forma como o peso de cada neurónio da rede é ajustado, podendo ser escrito segundo a expressão 2.28.

$$\frac{\partial E}{\partial w_{ji}} = \frac{\partial E}{\partial net_j} \cdot \frac{\partial net_j}{\partial w_{ji}} \quad 2.28$$

A expressão 2.28 ainda pode ser reescrita, dando origem à expressão 2.29 e 2.30.

$$net_j = \sum_{i=1}^n x_i w_{ji} \quad 2.29$$

$$\frac{\partial net_j}{\partial w_{ji}} = \frac{\partial \sum_{i=1}^n x_i w_{ji}}{w_{ji}} = x_i \quad 2.30$$

Por outro lado, o erro do neurónio j pode ser descrito sob a forma da expressão 2.31.

$$\delta_j = \frac{\partial E}{\partial net_j} = \frac{\partial E}{\partial y_j} \cdot \frac{\partial y_j}{\partial net_j} \quad 2.31$$

Simplificando a expressão 2.31, é possível definir o termo $\frac{\partial y_j}{\partial net_j}$ através da expressão 2.32.

$$\frac{\partial y_j}{\partial net_j} = \frac{\partial f(net_j)}{\partial net_j} = f'(net_j) \quad 2.32$$

Na expressão 2.32 é possível constatar que a primeira derivada, $\frac{\partial E}{\partial y_j}$, encontra-se dependente da posição do neurónio j , sendo assim, no caso de o neurónio estar localizado na última camada, o seu próprio erro pode ser descrito através da expressão 2.33.

$$\frac{\partial E}{\partial y_j} = \frac{\partial \left(\frac{1}{2} (\sum_{i=1}^k (d_i - y_i)^2) \right)}{\partial y_j} = (d_j - y_j) \quad 2.33$$

Desta forma consegue reescrever-se a expressão 2.31, numa nova expressão simplificada, dando origem à equação 2.34.

$$\delta_j = (d_j - y_j) f'(net_j) \quad 2.34$$

No caso de um neurónio j que não esteja localizado na camada de saída, este pode ser descrito através das expressões 2.35 e 2.36.

$$\frac{\partial E}{\partial y_j} = \sum_{l=1}^M \frac{\partial E}{\partial net_l} \cdot \frac{\partial net_l}{\partial y_j} = \sum_{l=1}^M \frac{\partial E}{\partial net_l} \cdot \frac{\partial \sum_{i=1}^n w_{il} y_i}{\partial y_j} = \sum_{l=1}^M \frac{\partial E}{\partial net_l} \cdot w_{jl} \quad 2.35$$

$$\sum_{l=1}^M \frac{\partial E}{\partial net_l} \cdot w_{jl} = \sum_{l=1}^M \delta_l w_{jl} \quad 2.36$$

Assim sendo, a expressão 2.31 pode ser adaptada da seguinte forma, permitindo calcular o erro associado às camadas intermédias através da nova expressão 2.37.

$$\delta_j = f'(net_j) \sum_l \delta_l w_{lj} \quad 2.37$$

No que toca à expressão responsável pelos ajustes dos pesos, expressa na equação 2.27, esta pode ser generalizada sob a forma das expressões 2.38 e 2.39.

$$\Delta w_{ji} = \eta \delta_j x_i \quad 2.38$$

$$w_{ji}(t + 1) = w_{ji}(t) + \eta \delta_j(t) x_i(t) \quad 2.39$$

Com base nas expressões definidas anteriormente, o erro de um neurónio de saída pode ser definido através da expressão 2.34, já o erro de qualquer outro tipo de neurónio pode ser caracterizado pela através da expressão 2.37 [34].

2.6.3 Construção de uma rede neuronal

Durante o processo de construção de uma RNA é necessário ter em consideração três etapas:

- Escolha e caracterização dos dados para a aprendizagem;
- Escolha da arquitetura da rede;
- Critério de paragem.

2.6.3.1 Escolha dos dados para a aprendizagem

Esta etapa é uma das mais importantes no processo de construção de rede neuronal, uma vez que a qualidade desta está fortemente dependente de uma criteriosa escolha dos dados a aplicar aos conjuntos de entrada e saída das redes. A escolha do tamanho deste conjunto de dados deve ser ponderada, visto que a escolha de um universo de dados pequeno poderá conduzir à construção de modelos com uma capacidade de previsão bastante baixa. Ao contrário de um universo de dados pequeno, se for fornecido à rede um conjunto de dados maior, esta poderá utilizar todos estes recursos durante o seu processo de aprendizagem. A própria RNA terá a capacidade de diferenciar a informação útil da informação que é prescindível, através das relações que são estabelecidas entre os valores de entrada e os valores de saída. A RNA irá atribuir aos dados que não forem utilizados um peso nulo, afastando assim a informação que seja irrelevante para a aprendizagem [32].

2.6.3.2 Escolha da arquitetura da rede

A próxima etapa passa pela escolha da arquitetura da rede, visto que esta também desempenha um papel importante na qualidade da aprendizagem de uma rede.

Tipicamente uma rede do tipo perceptron multicamada é composta por uma camada de entrada, uma camada escondida e uma camada de saída, podendo em determinados problemas ser adicionada uma segunda camada escondida.

O número de entradas e saídas é definido pelo tamanho dos padrões, x^p e y^p , utilizados no treino.

Para definir a arquitetura de uma rede também é preciso escolher o número de elementos da camada escondida. Este parâmetro não está definido por nenhum teorema específico, que clarifique qual a técnica para determinar o melhor número de unidades da camada escondida, contudo foram desenvolvidos diversos métodos que permitem caracterizar a camada escondida.

Um dos métodos é definido com base numa expressão que permite calcular o número de unidades da camada escondida, estando expressa segundo 2.40.

$$N > \frac{W}{\delta} \quad 2.40$$

Os elementos da expressão 2.40 são caracterizados da seguinte forma:

- N – Número de padrões de treino;
- W – Número dos pesos de ligações entre as unidades da rede;
- δ – Erro admissível.

Outro método considera que o número de ligações entre unidades dever ser aproximadamente igual a 10% do número de padrões de treino [32].

Outra alternativa define como critério de escolha o número de unidades da camada escondida através da expressão $2n + 1$, onde n representa o número de variáveis de entrada [32].

Outros autores calculam o número de unidades da camada escondida recorrendo à expressão $s(i + 1)$, onde s é o número de unidades de saída e i o número de entradas. Em sistemas mais pequenos, o número de neurónios pode ser calculado através da média geométrica entre o número de entradas e de saída [33], [34].

Com recurso a este tipo de métodos, é possível obter valores com potencial para serem usados na resolução de problemas de aproximação de funções e classificação de

dados. Outro pormenor está relacionado com o fato de que quanto maior for o número de elementos na camada escondida maior será o número de pesos de ligações entre unidades. Como resultado, o número de graus de liberdade da função definida após a aprendizagem será maior, resultando na melhoria do nível de aderência da função.

Contudo, quando o objeto de estudo é uma regressão, quanto maior for a aderência, menor será a capacidade de generalização da função, exemplificado na figura 2.15.




Figura 2.15 - Perda da capacidade de generalização [32]

Na figura 2.15 é possível verificar que a curva (B), com maior aderência em relação à curva (A), tem uma melhor capacidade de aproximar-se aos pontos dados, contudo a sua capacidade de generalização não é a melhor uma vez que a curva (B) apresenta um erro superior em relação à curva (A) quando são introduzidos valores diferentes [32].

2.6.3.3 Critérios de paragem

O critério de paragem mais simples baseia-se no conceito de limitar o número de iterações a um valor pré-determinado. Contudo este método não apresenta os melhores resultados, destacando-se apenas pela sua simplicidade. Também não é garantido que os pesos atribuídos às ligações entre unidades irão conduzir a um bom grau de generalização.

Também pode ser definido como um critério de paragem válido a caracterização de um patamar máximo do erro médio quadrático. A contrapartida deste sistema é o fato de o processo de treino nunca se dar por concluído, caso o sistema não atinja o valor pré-definido.

Porém existe uma variação da técnica mencionada anteriormente, onde o sistema irá aprender até ao ponto em que a diminuição do erro médio quadrático entre duas iterações seja menor que um certo valor pré-definido [32]. Um dos problemas desta técnica, prende-se com o facto deste modelo apresentar problemas de paragens prematuras, algo possível em regiões com superfícies de erro planas.

Apesar dos critérios de paragem mencionados anteriormente apresentarem características interessantes, este não tem a capacidade de resolver o problema da generalização por si só, desta forma deve ser utilizado um método que seja capaz de parar a aprendizagem no ponto em que se obtêm a máxima generalização. Este método é designado por paragem antecipada ou paragem por validação cruzada [34].

Analisando o processo de aprendizagem, é possível constatar que o erro médio quadrático do erro do treino decresce com o número de iterações. Em paralelo com o treino, a capacidade de generalização vai sendo testada, sendo aplicados os padrões do conjunto de validação à rede que está treinada até esse preciso instante. Desta forma, verifica-se na figura 2.16 que o erro médio quadrático da validação começa por diminuir e a partir de um certo número de iterações dá-se o aumento deste erro de validação.

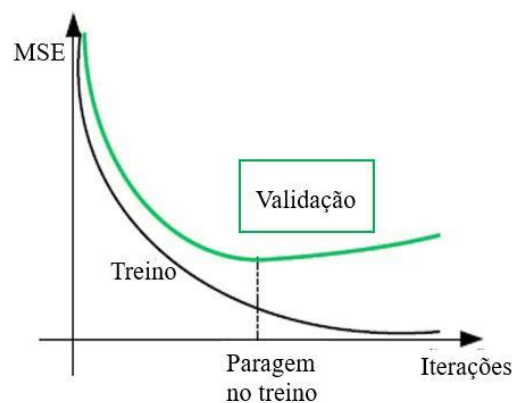


Figura 2.16 - Característica teóricas do erro médio quadrático (MSE) do treino e validação

O momento em que a rede já não consegue aprender as características principais do conjunto de treino e o conteúdo que esta aprende é apenas ruído, define-se como o ponto em que a rede está a sobreaprender, também designado como *overfitting* [32].

A desvantagem deste método reside na necessidade de retirar uma percentagem de padrões de treino para formar o de validação, divisão que poderá tornar-se um problema em casos onde o conjunto de dados já seja pequeno. Contudo este método é fortemente recomendado para aplicações práticas [32].

2.6.2.4 Caracterização dos dados para a aprendizagem

Uma vez que as funções de ativação das unidades da camada escondida são geralmente do tipo hiperbólica ou sigmóides, existe a possibilidade de as saídas poderem saturar para os valores -1, 0 ou 1. Desta forma se os valores de entrada forem suficientemente elevados, as saídas dessas unidades irão apresentar sempre o mesmo valor. Com o objetivo de normalizar os valores de saída de modo a que não saturem, foi desenvolvida uma expressão onde a cada valor do vetor de entrada X^p é subtraída a média desse mesmo vetor e dividido pelo desvio padrão, expresso através da equação 2.41. [32].

$$x_{iN}^p = \frac{x_i^p - \bar{X}^p}{\sqrt{\frac{\sum_{i=1}^n (x_i^p - \bar{X}^p)^2}{n-1}}} \quad 2.41$$

De seguida serão descritos alguns dos conceitos que ajudam a definir o processo de aprendizagem numa rede [32], [33], [35].

- **Conjunto de teste**

Este conjunto é definido por padrões que nunca foram apresentados à rede durante o decorrer do processo de aprendizagem. É com base neste conjunto que é verificada a qualidade das previsões.

- **Conjunto de treino**

Este conjunto é constituído pelos padrões que serão apresentados à rede neuronal durante a fase de treino. Quando os valores de entrada são aplicados na entrada de rede, é criado um valor observado mediante os pesos das ligações entre as unidades. A diferença entre os valores observados e os desejados será utilizada pelo algoritmo de retro-propagação dos erros com o propósito de diminuir a diferença entre o observado e o desejado.

- **Conjunto de validação**

O conjunto de validação serve para melhorar a aprendizagem da rede. Os padrões deste conjunto são aplicados de forma cíclica à rede no decorrer da fase de treino, com o objetivo de aferir a eficácia da aprendizagem, analisando a capacidade de generalização da rede. Conforme mencionado anteriormente, não existe nenhum teorema que resuma qual a dimensão adequada para este conjunto. Os valores que compõem este conjunto são extraídos aleatoriamente, garantindo que apresentam as mesmas características estatísticas do conjunto de treino, caso contrário, o critério para escolha da rede ficaria enviesado.

- **Escolha da melhor rede**

Quando se pretende treinar uma rede neuronal é preciso ter em consideração que inicialmente os pesos são atribuídos de forma aleatória, acabando o resultado da aprendizagem por depender dos valores dos pesos iniciais. Assim sendo, devem ser realizados vários ensaios para cada arquitetura, reunindo um conjunto de resultados que permita comparar as redes ensaiadas do ponto de vista estatístico, conseguindo assim eleger entre as redes ensaiadas, aquela que reúne as melhores características para a resolução do problema.

Assim pode ser escolhida a rede que apresenta o valor mediano do conjunto dos erros médios quadráticos do conjunto de validação. Ou simplesmente fazer a média entre os valores observados de todas as redes quando alimentadas pelos mesmos conjuntos de teste.

Capítulo III

Modelos de Previsão

Resumo:

Neste capítulo são apresentados os modelos de previsão que foram desenvolvidos neste estudo. Ao longo do capítulo são apresentadas as variáveis que compõem as RNA's construídas. O objetivo é comparar a aderência/qualidade de previsão dos modelos criados.

3 Modelos de Previsão

3.1 Caracterização do Problema

Com o objetivo de tornar as suas instalações mais sustentáveis, a direção do ISEL pensou em desenvolver uma iniciativa denominada por ISELGreen. Esta operação prende-se com a necessidade de criar estratégias que visem a redução do consumo de energia primária através da implementação de energias renováveis e a renovação das infraestruturas do *campus*. A iniciativa ISELGreen foi criada no âmbito do Programa Operacional de Sustentabilidade e Eficiência no Uso de Recursos (POSEUR), sendo estabelecido um conjunto de medidas que pretendem otimizar a eficiência energética no domínio da Administração Pública.

Desta forma foram desenvolvidas medidas de utilização racional de energia (MURE), com o propósito de contribuir para a melhoria efetiva da eficiência energética. Este conjunto de etapas tem como meta reduzir a dependência de combustíveis fósseis, dando ao ISEL a capacidade de participar numa economia com baixas emissões de carbono.

O percurso para a melhoria da eficiência energética no *campus* do ISEL é composto por onze MURE. Está estimado que a implementação deste conjunto de medidas leve a uma redução no consumo energia primária do ISEL em cerca de 43.5%. As onze MURE que foram desenvolvidas, estão descritas nos seguintes pontos:

1. Instalação de sistema solar fotovoltaico para produção de energia para autoconsumo;
2. Substituição da iluminação interior por tecnologia LED;
3. Instalação de sistema solar térmico para AQS;
4. Substituição dos *chillers* antigos por dois novos e mais eficientes;
5. Substituição dos *splits* por equipamento mais eficiente;
6. Substituição da iluminação exterior por tecnologia LED;
7. Aplicação de isolamento térmico pelo exterior nas paredes do edifício M;
8. Substituição das bombas de calor existentes no edifício F por equipamento mais eficiente;

9. Instalação de nova Unidade de Tratamento de Ar com melhor eficiência energética;
10. Aplicação de isolamento térmico na cobertura dos edifícios E, G e P, na ótica de remover o amianto;
11. Otimização do consumo *standby*, recorrendo a um sistema de monitorização do consumo de energia;

A implementação destas medidas está contemplada no concurso POSEUR-03-2016-65, traduzindo-se a implementação das onze MURE num investimento de 1966585.50 euros. Uma vez que este programa está inserido no POSEUR, a execução deste conjunto de medidas é cofinanciada em conjunto com a União Europeia, através do Fundo Social Europeu, e o programa Portugal 2020.

Indo ao encontro da agenda adotada por todos os estados-membros das Nações Unidas (UN), as onze iniciativas tomadas pelo ISEL, vão ao encontro dos Objetivos de Desenvolvimento Sustentável (ODS). Desta forma a UN lançou o desafio aos estados-membros de abraçar a tarefa de cumprir com a realização de dezassete objetivos até ao ano de 2030. Estes desafios têm como metas erradicar a fome no mundo, bem como promover a inovação das indústrias de forma sustentável, ou incentivar a implementação de energias renováveis, no caso do ISEL através da instalação de um solar fotovoltaico.

Particularmente no ISEL as MURE inserem-se nos seguintes ODS:



Figura 3.1- ODS adotadas pelo ISEL na categoria Energia [36]

Das várias metas que o ISEL estabeleceu alcançar, aquela que foi escolhida como alvo deste estudo é a primeira MURE, associada à implementação de um sistema solar fotovoltaico no *campus* do ISEL.

Este desafio foi lançado com o objetivo do ISEL desenvolver esforços perante o combate às alterações climáticas, uma vez que o *campus* apresenta um perfil de consumo intenso entre as 8 horas e as 23 horas. Considerou-se assim a aposta numa forma de energia renovável.

Assim sendo, de forma a rentabilizar a área do *campus*, sensivelmente superior a 6 hectares, composto por sete edifícios principais, foi lançada em 2018 a candidatura ao financiamento por parte do POSEUR, onde está contemplada a execução de um sistema solar fotovoltaico para produção de energia para autoconsumo.

A instalação deste sistema solar fotovoltaico permite ao *campus* atingir uma produção anual de energia com origem em fontes renováveis de mais de 550 MWh/ano. Este nível de produção permite ao ISEL reduzir as emissões de CO_2 em cerca 250 ton/ano.

A infraestrutura solar fotovoltaica do ISEL é composta por 1356 painéis fotovoltaicos, correspondendo a uma potência instalada de 427kW. Os painéis fotovoltaicos encontram-se coplanados nas estruturas metálicas dos edifícios E e G, como está representado na figura 3.2, conferindo aos painéis 10° de inclinação.




Figura 3.2 – Painéis instalados no edifício E e G (Adaptada Google Earth)

A solução fotovoltaica implementada no *campus* do ISEL foi executada com recurso aos painéis fotovoltaicos da marca Dehui Solar™. O modelo usado na execução deste projeto foi o DH-60-315. A designação do modelo é autoexplicativa, refletindo a constituição de cada painel, onde cada um é composto por 60 células monocristalinas de sílica, apresentando uma capacidade de potência de pico de 315 W [37].

Ao consultar o manual do fabricante foi possível retirar as seguintes especificações elétricas, apresentadas na tabela 3.1.

Tabela 3.1- Características elétricas do módulo DH-60-315

Potência de pico (Pmax) [W]	315
Tensão MPP (Vmp) [A]	33.70
Corrente MPP (Imp) [A]	9.37
Tensão em crircuito aberto (Voc) [V]	40.30
Corrente em CC (Isc) [A]	9.75
Eficiência do módulo [%]	19.36

Os valores apresentados na tabela 3.1 foram obtidos a partir de condições de testes estandardizados (STC). Está também indicado que, para este modelo, os testes foram conduzidos para as seguintes condições:

- Radiância – 1000 W/m²;
- Temperatura ambiente – 25°C;
- Massa do Ar (AM) – 1.5.

Aliado aos 1356 módulos solares foram instalados sete inversores, onde cinco apresentam uma potência de 60 kW e outros dois apresentam uma potência de 40 kW, criando um sistema com 380 kW. Os inversores instalados no *campus* do ISEL são da marca Huawei™ e como mencionado anteriormente foram utilizados dois modelos distintos. Na tabela 3.2 estão apresentadas as eficiências dos modelos utilizados.

Tabela 3.2 – Eficiências dos Inversores instalados

	Eficiência de pico
SUN2000-60KTL-MO	98.75% a 480 V; 98.65 % a 400 V
SUN2000-40KTL-M3	98.9 % a 480 V; 98.7 a 380/400 V

3.2 Dados do Problema

Os dados iniciais deste estudo foram recolhidos da plataforma responsável pela monitorização do consumo e autoconsumo das instalações do *campus* dos ISEL. Após a extração, foram obtidos dados de consumo e produção solar fotovoltaica entre os dias 1/01/2020 e 30/09/2021, dados disponíveis até à data do início deste estudo.

Os valores de potência e de autoconsumo estão registados em períodos de 15 minutos, período estabelecido de acordo com o DL 162/2019 [38]. Uma vez que um dos objetivos propostos é o desenvolvimento de um modelo de previsão tanto da carga como da produção fotovoltaica, foi decidido aumentar o intervalo entre os valores de potência registados. Desta forma foi estabelecido que o período entre valores seria de 1 hora. Este aumento irá resultar numa amostra mais pequena, permitindo ao modelo de previsão processar os dados de uma forma mais célere, visto que o tamanho dos vetores diminui substancialmente.

Um dos primeiros desafios no tratamento dos dados, prende-se com o facto dos dados de consumo do ISEL a partir de 2020, ano em que foi comissionado o sistema solar fotovoltaico, contemplarem exclusivamente a energia que a instalação consumiu da rede juntamente com a energia produzida. A combinação destas duas grandezas, não permite entender qual a energia que está a ser injetada na rede, como também não permite entender totalmente qual é o consumo real do ISEL.

Com o objetivo de resolver este problema considerou-se que não houve um aumento significativo do consumo em relação a 2019. Visto que no ano de 2019 ainda não tinha sido comissionado o sistema de produção de energia para autoconsumo, assume-se que a carga registada neste relatório corresponde à carga real do ISEL.

Para tentar obter o retrato mais fiel possível foram comparados os dados entre cada mês do ano de 2019 com os dados de cada mês do ano de 2020 e 2021. No ano de 2019 a variável carga é o consumo real da instalação, enquanto nos anos de 2020 e 2021 o valor de carga representa o valor da potência consumida menos a potência proveniente dos painéis. Com esta análise foi possível obter uma estimativa da redução da carga do ISEL entre o ano de 2019 e os anos de 2020 e 2021. As figuras 3.3 e 3.4 contribuíram para a compreensão das diferenças do perfil da carga entre o mês de Abril de 2019 e o mês de Abril de 2021.




Figura 3.3 - Consumo 2021 vs PV 21 - abril




Figura 3.4 - Consumo 2019 vs PV 21 - abril

Ao analisar os dados de consumo do ano de 2019 comparativamente com os dos anos seguintes, 2020 e 2021, foi possível obter o rácio entre eles. Na seguinte tabela 3.1 estão indicados os rácios para cada mês que compõem o conjunto de dados.

Tabela 3.3 – Rácio do consumo da carga comparativamente com o ano 2019 (Mensal)

Mês	Rácio	Mês	Rácio
jan/20	0.778	jan/21	0.731
fev/20	0.793	fev/21	0.616
mar/20	0.871	mar/21	0.749
abr/20	0.736	abr/21	0.824
mai/20	0.747	mai/21	0.708
jun/20	0.815	jun/21	0.906
jul/20	0.834	jul/21	0.889
ago/20	1.194	ago/21	1.207
set/20	0.899	set/21	0.964
out/20	0.855		
nov/20	0.908		
dez/20	0.923		

Com base nos valores registados na tabela 3.3 foi calculada a média dos rácios entre 2019 e os de 2020 e 2021, tendo sido obtido o valor 0.85. Este valor corresponde a uma redução média do consumo do ISEL de 15% ao longo dos anos 2020 e 2021. Desta forma foi considerado como consumo do ISEL, os valores de 2019 com uma redução de 15%.

A próxima etapa, como foi mencionado anteriormente, passou por reduzir a escala temporal de períodos médios 15 minutos para períodos médios de 1 hora. Com esta redução, o conjunto de dados associados à carga do ISEL passa a ser composto por 15336 elementos.

No que toca aos dados da produção solar, foram utilizados os dados medidos nos anos de 2020 e 2021. À semelhança do conjunto dos dados de consumo, também os valores da produção solar estavam distribuídos em intervalos médios 15 minutos.

O primeiro modelo a ser desenvolvido, foi o modelo de previsão de consumo. Com a necessidade de separar cada dia, os dados de consumo foram reagrupados numa matriz de 24 linhas por 639 colunas.

Cada uma das linhas representa uma das 24 horas de um dia, enquanto as colunas representam cada dia presente no conjunto de dados, neste caso 639 dias, referentes à totalidade do ano de 2020 e parte do ano de 2021 até dia 30/9/2021. Na figura 3.5 é possível observar uma representação do padrão de consumo de todos os dias que compõem a amostra.




Figura 3.5 – Consumo do ISEL em 649 dias (Tamanho da amostra)

Ao analisar a figura 3.5 é possível verificar que existem principalmente dois tipos de consumo. Esta diferença é notória durante o período em que decorrem as aulas, entre as 8:00 e as 23:00. No intervalo entre os 100 kW e aproximadamente os 200 kW, é onde estão situados os dias que correspondem aos fim-de-semanas e feriados. Por outro lado, o intervalo dos 300 kW e aproximadamente aos 600 kW corresponde aos dias da semana.

O segundo passo, consiste em organizar os dados referentes à produção solar, seguindo as etapas que foram realizadas para o conjunto do consumo do ISEL. A produção solar também foi reestruturada sobre a forma de uma matriz, composta por 24 linhas e 639 colunas. Nesta matriz estão compreendidos todos os valores de produção solar de hora a hora entre o dia 1 de janeiro de 2020 até o dia 30 de setembro de 2021, tendo a mesma dimensão da matriz associada ao consumo. Na figura 3.6 encontra-se representado o perfil de produção solar fotovoltaica do ISEL entre o período temporal que compõe a amostra a estudar, 639 dias distribuídos ao longo de 24 horas.




Figura 3.6 – Produção solar fotovoltaica do ISEL em 649 dias (Tamanho da amostra)

Uma diferença visível entre o conjunto do consumo e o conjunto da carga do ISEL, é o fato de a produção solar fotovoltaica apresentar um comportamento aparentemente idêntico entre todos os dias do ano. Enquanto o consumo do ISEL está dependente de perfis de consumo, seja relacionado com o dia da semana ou o período de funcionamento do *campus*, a variável solar é uma constante diária, apresentando um comportamento horário mais previsível.

3.3 RNA – Conjunto de treino

3.3.1 Conjunto treino - Carga

Para construir a RNA foi necessário em primeiro lugar estruturar e reunir as variáveis necessárias para construir o modelo de treino. De acordo com [39], [40] as variáveis escolhidas como entradas para o conjunto de treino foram as seguintes:

- Dia da semana do dia a prever (**DSout**) - Compreendido entre domingo a sábado [1 a 7];
- Dia de trabalho do dia a prever (**DTout**) - Valor definido para dia de trabalho 1, no caso de feriado ou fim de semana é atribuído o valor 0;
- Valor da carga, nas 24 horas anteriores, ao dia a prever (**pdin24**) [kW];
- Valor da carga há uma semana, relativamente ao dia a prever (**pdinSM**) [kW];
- Previsão da temperatura média horária do ar do dia a prever (**TempAR24**) [°C].

Com base nestas variáveis de entrada, a saída do conjunto de treino é definida pelas 24 horas do dia a prever. O primeiro dia prever será o dia 9 de janeiro de 2020, uma vez que é o primeiro dia que cumpre com os requisitos definidos nos critérios do conjunto de entrada.

Os valores da temperatura média horária do ar foram extraídos através da ferramenta online PVGIS. A redução do conjunto de dados através da alteração dos intervalos de 15 minutos para intervalos de 1 hora, também foi motivada pelo fato de os dados extraídos pelo PVGIS estarem organizados na escala horária. O outro fator que contribui para esta consideração, está relacionado com a escala temporal mencionada em [39], [40] e [41], sendo que em ambos os cenários é utilizada a escala horária.

Estando definidas as entradas do conjunto de treino, resta definir o conjunto de saída. Neste modelo o conjunto de treino apresenta apenas uma variável de saída:

- Valor medido da carga do dia a prever (**pdout Carga**) [kW].

O modelo de treino mencionado anteriormente pode ser esquematizado sob a forma da figura 3.7.

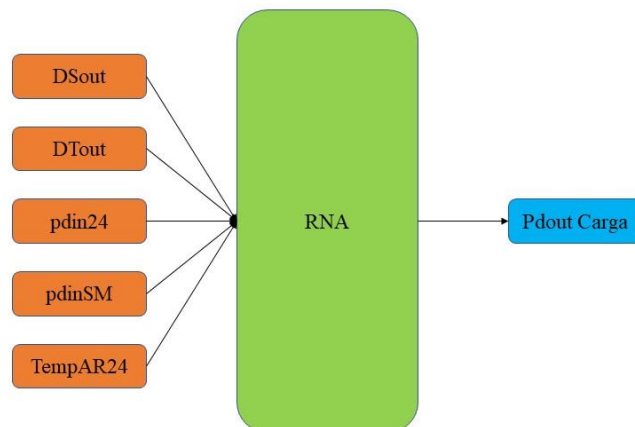


Figura 3.7 – Modelo RNA – Entradas e Objetivo (Consumo ISEL)

As variáveis de entrada foram agrupadas numa matriz, composta por 74 linhas e 358 colunas. Em cada coluna estão definidos os dados de entrada que permitem prever um dia específico. Como existem 24 valores de carga do dia anterior a prever, 24 valores de carga de à uma semana a prever, 24 valores da temperatura do ar do dia prever, um valor que define se o dia a prever é um dia laboral e outro que define o dia da semana do dia a prever, obtém-se uma matriz com 74 linhas. As 358 colunas contem a informação necessária para obter os valores entre 9 de janeiro e 31 de dezembro de 2020.

O conjunto de saída como apresenta apenas uma variável, este assume o tamanho da matriz **pdout**, correspondendo aos valores objetivos, sendo neste caso os valores de carga [kW] medidos entre 9 de janeiro e 31 de dezembro de 2020. Este conjunto apresenta as seguintes dimensões, 24 linhas por 358 colunas. Onde as colunas correspondem às 24 horas dos dias entre o dia 9 de janeiro e 31 de dezembro de 2020.

Desta forma foi construída a RNA através da ferramenta *nftool* presente no software *Matlab*. Neste módulo será necessário definir os elementos que definem a arquitetura de uma RNA. A primeira etapa passa por definir a variável *Input* e a variável *Target*.

O passo seguinte foi a escolha do número de neurónios presentes na camada escondida. Foram utilizadas três arquiteturas, para cada uma destas arquiteturas foram

construídas 15 redes. Cada uma definida com base no número de neurónios presentes na camada escondida, nomeadamente 50, 40 e 10 unidades, critério escolhido neste estudo.

Para determinar qual o número de neurónios a escolher para a camada escondida, foi utilizado o erro médio quadrático (MSE) de cada uma das redes treinadas. Após ser determinado o MSE para cada uma das redes foi calculada a média dos MSE's em cada um dos casos, segundo a expressão 3.1:

$$MSE = \frac{1}{n} \sum_i^n (y_i - \hat{y}_i)^2 \quad 3.1$$

Onde:

- y_i – valor observado de ordem i ;
- \hat{y}_i – valor a prever;
- n – número de observações.

Na tabela 3.4 estão compilados os valores do MSE para os três cenários:

Tabela 3.4 – MSE para RNA com 50,40 e 10 elementos na camada escondida (ECE)

ECE = 50	MSE	ECE = 40	MSE	ECE = 10	MSE
REDE 1	14248	REDE 1	11769	REDE 1	1942
REDE 2	11071	REDE 2	5835	REDE 2	2692
REDE 3	3404	REDE 3	12276	REDE 3	2885
REDE 4	11990	REDE 4	5802	REDE 4	2028
REDE 5	18194	REDE 5	6509	REDE 5	2267
REDE 6	8063	REDE 6	7177	REDE 6	1093
REDE 7	10756	REDE 7	2231	REDE 7	2299
REDE 8	3575	REDE 8	3703	REDE 8	2329
REDE 9	5763	REDE 9	6614	REDE 9	2902
REDE10	5778	REDE10	8756	REDE10	1622
REDE 11	4155	REDE 11	3955	REDE 11	2003
REDE 12	9279	REDE 12	35922	REDE 12	1693
REDE 13	5264	REDE 13	5622	REDE 13	3572
REDE 14	2747	REDE 14	4737	REDE 14	2685
REDE 15	6443	REDE 15	12346	REDE 15	1417

Com base nestes valores foram calculadas as médias dos 15 MSE para cada um dos três cenários, apresentados na tabela 3.3:

Tabela 3.5 – Média dos valores do MSE para RNA com 50, 40 e 10 neurónios na camada escondida

Média MSE (ECE = 50)	8049
Média MSE (ECE = 40)	8884
Média MSE (ECE = 10)	2229

Desta forma, analisando a média dos MSE's para os três cenários foi decidido utilizar a RNA com 10 neurónios na camada escondida, assim sendo a rede neuronal artificial terá arquitetura indicada figura 3.8.




Figura 3.8 – Arquitetura da RNA a implementar (Consumo)

3.3.2 Conjunto treino – Produção fotovoltaica

À semelhança do processo realizado para o modelo da carga do ISEL, aplicou-se o mesmo raciocínio ao conjunto de dados da produção fotovoltaica. Ao analisar outros estudos que desenvolveram modelos de previsão da carga solar como em [42], [43] foram escolhidas as seguintes variáveis de entrada:

- Dia da semana do dia a prever (**DSout**) - Compreendido entre domingo a sábado [1 a 7];
- Dia de trabalho do dia a prever (**DTout**) - Valor definido para dia de trabalho 1, no caso de feriado ou fim de semana é atribuído o valor 0;
- Valor da produção fotovoltaica no dia anterior, 24 horas, ao dia a prever (**pdin24**) [kW];
- Valor da produção fotovoltaica há uma semana atrás ao dia a prever (**pdinSM**) [kW];
- Temperatura do ar do dia a prever (**TempAR24**) [°C];
- Radiância direta do dia a prever (**IrradGb24**) [W/m²];

- Hora do ano do dia a prever (**HoraAno24**);
- Semana do ano do dia a prever (**SMAout**);

Este conjunto de treino está construído de forma a prever valores de produção solar para os mesmos dias que o conjunto de treino da carga, 9 de janeiro a 31 de dezembro.

Mais uma vez foi utilizada a ferramenta PVGIS, neste caso para extrair os valores de hora a hora da radiância direta.

Traçando um paralelismo com o conjunto de treino da carga, a variável de saída do conjunto de treino é:

- Valor medido da produção fotovoltaica do dia a prever (**pdout PV**) [kW].

O modelo de treino mencionado anteriormente pode ser resumido sobre a forma da figura 3.9.

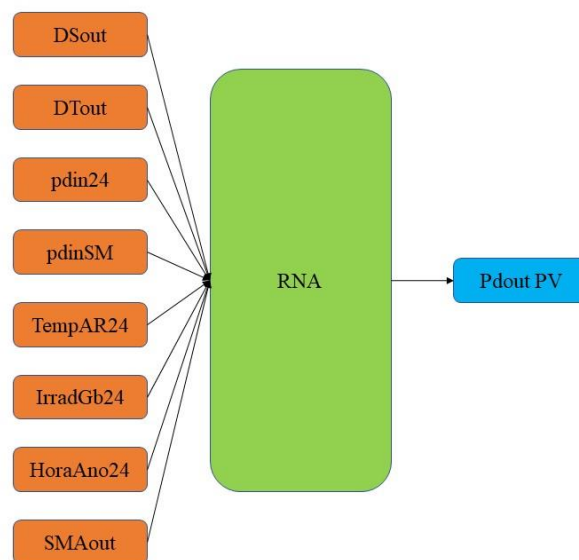


Figura 3.9 – Modelo RNA – Entradas e Objetivo (Produção solar)

Em semelhança ao processo apresentado no ponto 3.3.1, as variáveis de entrada foram agrupadas numa matriz, composta por 123 linhas e 358 colunas. As linhas contêm a seguinte informação:

- 24 valores de produção do dia anterior à previsão;

- 24 valores de produção de há uma semana do dia a prever,
- 24 valores da temperatura do ar do dia a prever;
- Um valor que define se o dia a prever é um dia laboral;
- Um valor que define o dia da semana do dia a prever;
- Previsão de 24 valores de radiância direta do dia prever;
- Hora do ano do dia a prever;
- Semana do ano do dia a prever.

Assim sendo, obtém-se uma matriz com 123 linhas. As 358 colunas contem a informação necessária para obter os valores entre 9 de janeiro e 31 de dezembro de 2020.

A variável de saída é representada de forma semelhante à variável de saída do conjunto de treino da carga. A alteração prende-se com o facto de os dados estarem nesta situação a representar os valores objetivo da produção solar. Este conjunto de saída é também definido por uma matriz com 24 linhas por 358 colunas.

Seguindo a arquitetura da RNA associada ao consumo do ISEL, foram treinadas 15 redes, onde a camada escondida é composta por 10 neurónios. O número de elementos na camada escondida foi escolhido de forma a coincidir com o número de neurónios escolhidos para o modelo da previsão do consumo. Na figura 3.10 está ilustrada a arquitetura que foi considerada para a RNA responsável pela previsão dos dados de produção solar:




Figura 3.10 – Arquitetura da RNA a implementar (Produção fotovoltaica)

3.4 RNA – Conjunto de teste

3.4.1 Conjunto teste – Carga

É através do conjunto de teste que é avaliada a capacidade de previsão da RNA que foi desenvolvida no ponto 3.3.1. A RNA terá aprendido e treinado com valores conhecidos pela rede, com todo o conjunto de dados de carga que compõem o ano de 2020. Para testar a capacidade e analisar o modelo de previsão da carga do ISEL, serão apresentados à RNA um conjunto de dados externos ao modelo construído.

O conjunto de teste compreende todos os valores de consumo entre o dia 9 de janeiro e 30 de setembro de 2021. Estes dados foram também agrupados numa matriz, tendo as seguintes dimensões, 74 linhas por 265 linhas.

3.4.2 Conjunto teste – Produção solar fotovoltaica

A par do mencionado no ponto anterior, 3.4.1, será criado um conjunto de treino para testar a capacidade e qualidade da RNA treinada no ponto 3.3.2, seguindo a mesma metodologia.

3.5 RNA – Simulação das *redes*

3.5.1 Simulação – Carga

Tendo o conjunto de teste pré-estabelecido, estão reunidas as condições para simular as 15 redes treinadas com os dados de consumo entre 9 de janeiro e 30 de setembro de 2021.

Assim sendo, foram aplicadas as 15 redes ao conjunto de teste, formando uma matriz com os valores carga [kW] previstos entre a janela temporal mencionada anteriormente. Na tabela 3.6 estão exemplificadas as redes utilizadas.

Tabela 3.6 – Redes utilizadas na previsão da carga

ECE = 10	MSE	ECE = 10	MSE	ECE = 10	MSE
REDE 1	1942	REDE 6	1093	REDE 11	2003
REDE 2	2692	REDE 7	2299	REDE 12	1693
REDE 3	2885	REDE 8	2329	REDE 13	3572
REDE 4	2028	REDE 9	2902	REDE 14	2685
REDE 5	2267	REDE10	1622	REDE 15	1417

Com o propósito de analisar a qualidade das previsões das redes simuladas, foi decidido reorganizar a matriz devolvida da simulação, com as dimensões de 24 linhas por 265 colunas. Esta reorganização têm o simples propósito de facilitar a construção da figura onde serão comparados os valores previstos com os valores reais.

Ao analisar a tabela 3.6 é possível verificar que existem redes com valores de MSE de teste diferentes, conduzindo à criação de diferentes valores de previsão. Na figura 3.11 está representada a carga real [kW] versus a carga prevista [kW] utilizando **REDE 1** e na figura 3.12 está representada a mesma informação, mas recorrendo à **REDE 3**.




Figura 3.11- Carga ISEL – Previsto versus Real (**REDE 1**)




Figura 3.12 – Carga ISEL – Previsto versus Real (**REDE 3**)

Ao analisar as figuras 3.11 e 3.12 é possível constatar a diferença entre as redes que foram simuladas. Tendo 15 simulações a próxima etapa recai sobre qual escolher, não sendo garantido que a melhor *net* seja aquela que apresente o valor de MSE menor. Do conjunto das 15 *redes* algumas são melhores a prever meses de inverno ou meses de verão, enquanto outras apresentam maior dificuldade em acompanhar o decréscimo de consumo, característico do perfil de consumo nos dias de fim de semana.

Um bom período para testar a capacidade de adaptação de cada rede é analisar o período entre 1 julho e 30 de setembro de 2021. Esta janela temporal corresponde ao período em que as instalações do ISEL apresentam o menor consumo devido à ausência de aulas, não existindo o consumo associado ao funcionamento normal das instalações.

Nas figuras 3.13 e 3.14 estão representados os consumos entre 1 de julho e 30 de setembro de 2021, utilizando novamente a **REDE 1** e a **REDE3**, respetivamente.




Figura 3.13 – Carga ISEL perfil verão – Previsto versus Real (**REDE 1**)

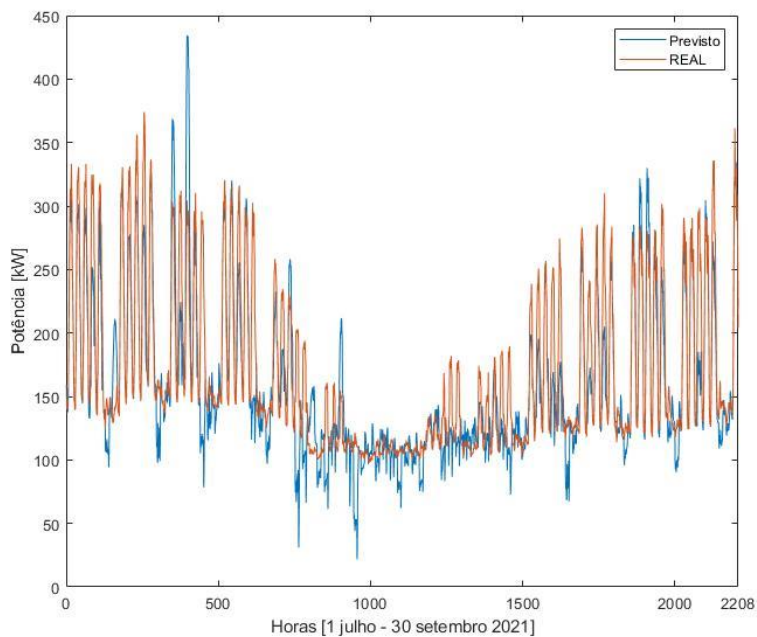


Figura 3.14 - Carga ISEL perfil verão – Previsto versus Real (**REDE 3**)

Com base nas figuras 3.13 e 3.14 é possível verificar que a **REDE 3** consegue ter uma melhor percepção dos consumos do mês de agosto, período onde existe uma redução acentuada do consumo, comparativamente com a **REDE 1**. Por outro lado, em relação ao

consumo restante a **REDE 1** têm uma melhor percepção do comportamento do consumo do ISEL tendo bem estabelecido os valores mínimos, enquanto a **REDE 3** tem mais dificuldades a estabelecer os consumos mínimos.

Visto que cada rede apresenta valores diferentes de previsão foi calculada a média aritmética entre os valores de saída das 15 redes simuladas.

A matriz que contem os valores do cálculo da média aritmética, será reorganizada da mesma forma que as matrizes das 15 redes simuladas, facilitando a construção dos gráficos. Esta transformação culmina na criação da matriz **CJ_TST_ORGZ**, representando a RNA definitiva do modelo de previsão da carga. Na figura 3.15 é representada a capacidade de previsão da RNA final.

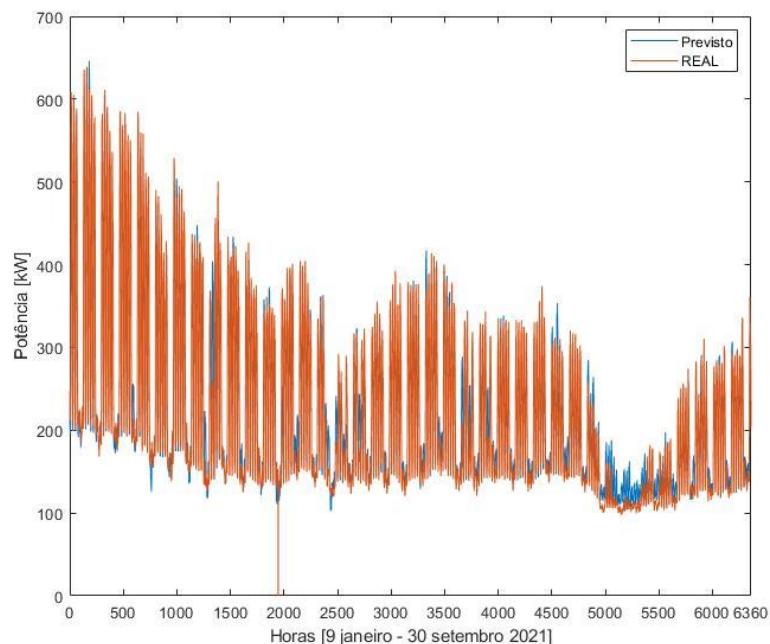


Figura 3.15 – Carga ISEL – Previsto versus Real (RNA Final)

Analisando a figura 3.15 é perceptível que os valores de consumo previstos estão relativamente próximos dos valores reais. O período mais difícil de prever é o comportamento registado no mês de agosto, contudo esta aproximação permitiu de uma forma geral criar um conjunto de dados previstos que estão bastante próximos do valor medido. O valor do MSE associado a esta aproximação é de 2229.

Particularizando, foi selecionado o intervalo entre os dias 1 de maio a 31 de maio de 2021. De forma a validar a aproximação da RNA final através do cálculo da média aritmética das quinze redes, foi analisado o MSE das redes simuladas comparativamente com a média dos quinze MSE's. Na figura 3.16 está apresentado o MSE das 15 redes mencionadas anteriormente em conjunto com a média dos MSE's, este último ilustrado na barra 16.




Figura 3.16 – Média do MSE das 15 *redes* (maio 2021)

Como complemento à análise anterior, a figura 3.17, onde é possível verificar uma aproximação razoável entre os valores previstos e os valores medidos no mês de maio de 2021, mostrando a mais-valia do método de previsão utilizado.




Figura 3.17 – Carga ISEL – Previsto versus Real (maio 2021)

3.5.2 Simulação – Produção solar fotovoltaica

Para a realizar a simulação do modelo de previsão solar fotovoltaica foi utilizado um procedimento semelhante ao apresentado no ponto 3.5.1.

No modelo da previsão solar também foi seguido o procedimento de aplicar as 15 redes aos dados de produção solar compilados na matriz que contém os valores de entrada do conjunto de teste. Desta forma foram devolvidas quinze matrizes, em que cada destas contém os valores de produção solar previsto durante o intervalo de tempo mencionado anteriormente, 9 de janeiro a 30 de setembro de 2021.

Na tabela 3.7 estão compiladas as redes na construção do modelo de previsão da produção fotovoltaica do ISEL, estando associada a cada rede o seu respetivo MSE:

Tabela 3.7 - Redes utilizadas na previsão da produção solar fotovoltaica

ECE = 10	MSE	ECE = 10	MSE	ECE = 10	MSE
REDE 1	147	REDE 6	137	REDE 11	130
REDE 2	245	REDE 7	116	REDE 12	254
REDE 3	142	REDE 8	78	REDE 13	216
REDE 4	143	REDE 9	144	REDE 14	133
REDE 5	231	REDE10	160	REDE 15	132

Os resultados provenientes da aplicação das redes presentes na tabela 3.7 ao conjunto dos dados de entrada, resultou na criação de quinze matrizes. Visto que o intervalo dos dados a prever contém 265 dias, cada rede simulada apresenta as dimensões de 24 linhas por 265 linhas. Com o propósito de facilitar a comparação entre os valores previstos e os valores reais, estas matrizes foram reorganizadas. Os valores reais da produção solar fotovoltaica do intervalo 9 de janeiro e 30 de setembro estão contidos na matriz de teste, contendo os valores objetivo.

Traçando um paralelismo com análise realizada no modelo da carga, é possível estabelecer que no modelo da previsão solar também existem redes com valores distintos de MSE, gerando diferentes cenários de previsão. Esta análise pode ser feita com recurso às figuras 3.18 e 3.19, onde são comparados os valores reais com os valores previstos de produção solar fotovoltaica, recorrendo às **REDE 5** e **REDE 13**, respetivamente.




Figura 3.18 – Produção solar ISEL – Previsto versus Real (**REDE 5**)




Figura 3.19 - Produção solar ISEL – Previsto versus Real (**REDE 13**)

Sendo visíveis as diferenças entre resultados, dependendo da rede que é utilizada na previsão, foi implementada a mesma técnica que foi mencionada no ponto 3.5.1, calcular a média aritmética, entre os valores de saída das quinze redes simuladas, contruindo assim uma RNA que contém todas as vantagens e desvantagens das quinze redes. Assim sendo, é criada uma rede que tenta prever resultados de produção solar da forma mais generalizada possível, garantindo que esta RNA apresenta uma maior adaptabilidade aos dados reais. Na figura 3.20 está representada a RNA final correspondente ao modelo de previsão solar.




Figura 3.20 - Produção solar ISEL – Previsto versus Real (RNA Final)

A figura 3.20 demonstra uma grande proximidade entre o valor previsto e o valor real da produção solar ao longo do ano de 2021. Ao contrário da carga, o movimento do sol apresenta o mesmo comportamento todos os dias do ano, ajudando a RNA a compreender/estabelecer padrões de produção. A aproximação, que culminou na criação da RNA final através da média aritmética, apresenta um MSE de 161. Este valor de MSE reforça a proximidade que existe entre o valor de produção solar medido e o valor de produção previsto.

Com o objetivo de traçar um paralelismo com modelo apresentado no ponto 3.5.1, foi escolhido o intervalo o mês de maio de 2021. Através da figura 3.21 verifica-se que a RNA final, também designada por **REDE 16** apresenta o menor MSE entre as restantes quinze redes.




Figura 3.21 - MSE das 16 *redes* (maio 2021)

A comparação entre a produção solar prevista e a produção solar real no mês de maio é retratada na figura 3.22.




Figura 3.22 – Produção solar fotovoltaica ISEL – Previsto versus Real (maio 2021)

A figura 3.22 serve para validação da proximidade entre os valores previstos e os valores reais. Assim sendo o modelo de previsão da produção solar do ISEL consegue devolver um conjunto de valores razoavelmente próximos dos valores.

Verifica-se que os valores previstos apresentam uma boa aderência aos valores medidos. Mesmo em dias em que a produção fotovoltaica apresenta grandes variações, em comparação com os restantes dias do mês, a RNA conseguiu fazer previsões de forma satisfatória. Verifica-se também que o modelo de previsão tendencialmente sobrestima os valores reais.

Capítulo IV

Aplicação do sistema de otimização / Caso aplicado

Resumo:

Neste capítulo será desenvolvido o sistema de otimização. Este modelo prevê a implementação de um SAE. O modelo será desenvolvido através de um problema de programação linear, sendo a função objetivo, a minimização do custo da energia consumida da rede. Neste ponto serão utilizados os dados obtidos através da RNA, com intuito de unir os modelos desenvolvidos ao longo deste estudo. Serão criados um conjunto de casos, com o propósito de entender a influência dos parâmetros envolvidos no modelo de otimização.

4 Gestão da bateria / Caso aplicado

4.1 Capacidade da bateria

Com o objetivo de dimensionar um SAE conectado ao sistema de produção solar fotovoltaica instalado no *campus*, é necessário definir o valor da capacidade da bateria. Para escolher o valor da capacidade nominal foi analisada a produção solar do conjunto total, entre 1 janeiro de 2020 e 30 de setembro de 2021, valores compreendidos na matriz **PVcargarORGZ**. O raciocínio passa por calcular a média da matriz, **PVcargarORGZ**, com o propósito de obter uma média da produção solar para as 24 horas. A matriz resultante tem 24 linhas, retratando um dia médio de produção solar fotovoltaica. Na figura 4.1 estão retratados os valores médios de produção solar, estando apenas representadas as horas em que houve produção solar, no total 14 horas.




Figura 4.1 – Produção Solar Média (Apenas horas com produção)

A partir da figura 4.1 é possível calcular o valor total da produção média solar, obtendo assim 1580 kWh. Desta forma, podem ser escolhidos diversos valores de capacidade de armazenamento do SAE em torno do valor total de produção solar

mencionado anteriormente, tendo como caso de estudo inicial, escolhida uma bateria com uma capacidade de 1250 kWh.

4.2 Modelo de gestão da bateria

4.2.1 Construção do modelo de otimização

Neste ponto será desenvolvido o modelo de otimização do sistema. Tanto os dados de consumo como os dados de produção solar fotovoltaica a serem utilizados no modelo, serão os dados obtidos através dos modelos de previsão.

O primeiro passo será definir os diferentes comportamentos que irão reger o modelo de gestão. Esta gestão será realizada com base no diagrama de fluxo, ilustrado na figura 4.2, onde o parâmetro inicial a ser avaliado é o valor resultante da diferença entre o valor do consumo do ISEL e a produção solar do ISEL em cada hora, sendo designado por **Pnet**.

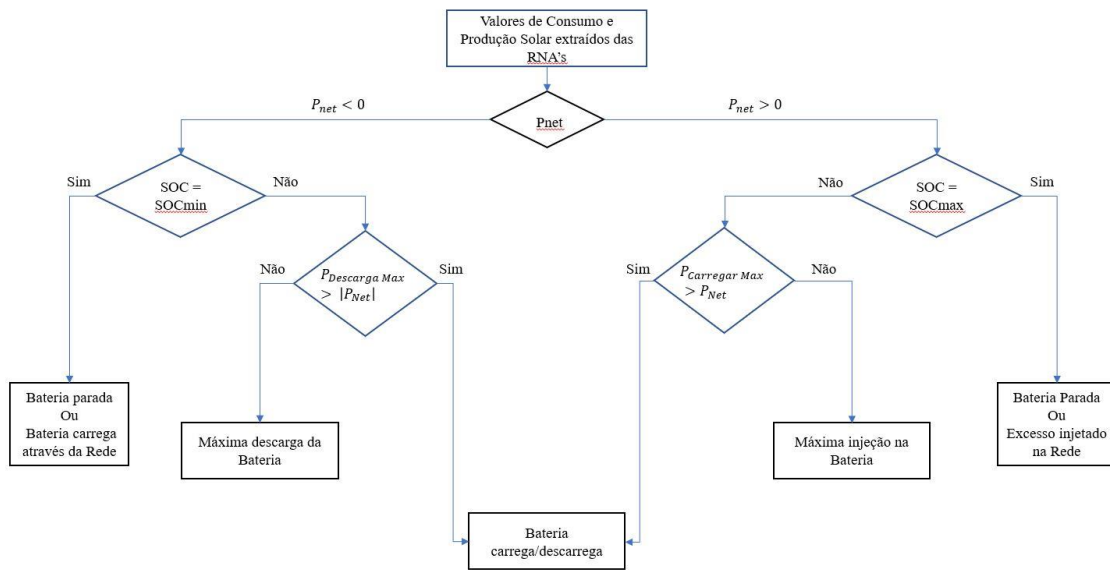


Figura 4.2 – Controlo do ciclo de carga e descarga de uma bateria, adaptado de [44]

No caso de estudo, a produção fotovoltaica está dimensionada de forma a esta ser consumida na sua totalidade, uma vez que durante os dias laborais praticamente não existe energia injetada na rede. O mesmo padrão não se verifica aos fins de semanas ou períodos de férias, pois neste tipo de dias existe excedente proveniente da produção fotovoltaica. Contudo este excedente não é suficiente para atenuar o consumo de um dia laboral de forma significativa. Na figura 4.3 é possível verificar que existe excedente proveniente

da produção fotovoltaica, encontrando-se de forma generalizada, nos fins de semana, conjuntos agrupados em pares, ou o mês de agosto.




Figura 4.3 – Somatório da potência excedente diária (Valores previstos)

Assim sendo foi pensada uma estratégia em que o funcionamento da gestão da bateria é controlado de acordo com o preço da tarifa praticada, consumo do ISEL, produção solar, e estado da carga da bateria. O sistema de otimização da figura 4.2 associado à gestão da bateria, terá como principal objetivo minimizar o custo de consumo de energia da rede. Na figura 4.4 é representada a estratégia que é pretendida implementar na gestão da bateria.




Figura 4.4 – Modelo de gestão da Bateria (24 horas) adaptado de [45], [46]

Como mencionado anteriormente, o ciclo de carga/descarga da bateria está fortemente ligado ao preço da tarifa energética, assim sendo, na mesma escala temporal da figura 4.4 a figura 4.5, apresenta a variação do preço ao longo de 24 horas.




Figura 4.5 – Tarifa energética praticada na figura 4.4

4.2.2 Modelos de otimização – programação linear

A bateria será carregada através da rede, aproveitando os períodos em que a tarifa apresente um preço baixo. De seguida o modelo de gestão será responsável por analisar qual o melhor instante para descarregar a energia armazenada, seja para compensar o consumo do ISEL ou para vender a energia contida na bateria numa hora de ponta, onde preço da energia atinge o seu valor máximo.

Para otimizar os ciclos de carga e descarga recorreu-se à programação linear, sendo necessário definir a função objetivo e as restrições do problema de otimização, aplicadas no *software Matlab*. Como abordado anteriormente, a função objetivo terá como foco minimizar o custo da aquisição da energia elétrica da rede, podendo ser escrita sobre a forma da expressão 4.1.

$$\min C_{tot} = \sum_{k=0}^N C_{rede}(k) \cdot E_{rede}(k) \quad 4.1$$

Onde:

- C_{rede} – Preço da tarifa energética [cent/kWh];
- E_{rede} – Energia consumida da rede elétrica [kWh].

Estando definida a função objetivo, o seguinte passo será estabelecer as restrições do problema de otimização. Para o caso de estudo foram definidas duas restrições, uma relacionada com a energia da bateria em cada instante, e outra associada ao balanço das potências. Esta última, garante que a potência proveniente do sistema solar em conjunto com a potência consumida da rede e a potência fornecida pela bateria, é suficiente para satisfazer as necessidades da carga, neste caso o *campus* do ISEL. As duas restrições assumem a forma das expressões 4.2 e 4.3

$$E_{bat}(k) = E_{bat}(k - 1) + P_{bat}(k)\Delta T \quad 4.2$$

Na expressão 4.2 não foi tido em conta o rendimento da bateria.

$$P_{pv}(k) + P_{rede}(k) + P_{bat}(k) = P_{Consumo}(k) \quad 4.3$$

De forma genérica 4.1, 4.2 e 4.3 podem ser representados na forma canónica, expressão 4.4.

$$\min_x f^T x \text{ sendo que } \begin{cases} A \cdot x \leq b \\ A_{eq} \cdot x = b_{eq} \end{cases} \quad 4.4$$

Com a expressão de minimização caracterizada, a próxima etapa passa por definir as variáveis de decisão do problema, apresentadas nos seguintes pontos:

- $P_{rede}(1:N)$ – Potência utilizada da rede entre o período temporal 1 a N [kW];
- $P_{bat}(1:N)$ – Potência proveniente da bateria entre o período temporal 1 a N [kW];
- $E_{bat}(1:N)$ – Energia armazenada na bateria entre o período 1 a N [kWh].

As variáveis de decisão irão compor o vetor x , presente na expressão 4.4, assumindo x a apresentada em 4.5.

$$x = [P_{grid}(1:N) \quad P_{bat}(1:N) \quad E_{bat}(1:N)]^T \quad 4.5$$

Para contruir o modelo do problema de programação linear apresentado na expressão 4.4, falta definir os vetores b_{eq} e b , como as matrizes A e A_{eq} . Ao definir estas variáveis é possível escrever as expressões 4.6, 4.7, 4.8 e 4.9.

$$A_{eq} = \begin{bmatrix} I_{N \times N} & I_{N \times N} & 0_{N \times N} \\ 0_{N \times N} & \gamma_{N \times N} & \Phi_{N \times N} \end{bmatrix}$$

$$\gamma_{3 \times 3} = \begin{bmatrix} 0 & 0 & 0 \\ \Delta T & 0 & 0 \\ 0 & \Delta T & 0 \end{bmatrix}$$

$$\Phi_{3 \times 3} = \begin{bmatrix} 1 & 0 & 0 \\ -1 & 1 & 0 \\ 0 & -1 & 1 \end{bmatrix} \quad 4.6$$

$$b_{eq} = \begin{bmatrix} P_{Consumo}(1:N) - P_{pv}(1:N) \\ E_{bat}(1) \\ 0_{N-1} \end{bmatrix} \quad 4.7$$

$$A = \begin{bmatrix} 0_{N \times N} & I_{N \times N} & 0_{N \times N} \\ 0_{N \times N} & -I_{N \times N} & 0_{N \times N} \\ 0_{N \times N} & 0_{N \times N} & I_{N \times N} \\ 0_{N \times N} & 0_{N \times N} & -I_{N \times N} \end{bmatrix} \quad 4.8$$

$$b = \begin{bmatrix} P_{max} \\ -P_{min} \\ E_{max} \\ -E_{min} \end{bmatrix} \quad 4.9$$

Onde:

- N – Janela temporal do processo de otimização (24 horas) [1:24];
- ΔT – Tempo entre cada interação [segundos];
- P_{pv} – Vetor que contém os valores previstos de produção fotovoltaica [kW];
- $P_{Consumo}$ – Vetor que contém os valores previstos de consumo [kW];
- C_{rede} – Vetor que contém os valores da tarifa energética [cent/kWh];
- P_{max} – Potência máxima de carregamento [kW];
- P_{min} – Potência máxima de descarregamento [kW];
- E_{max} – Energia máxima armazenada na bateria (SOC: 80%) [kWh];
- E_{min} – Energia mínima armazenada na bateria (SOC: 20%) [kWh].

No que diz respeito às variáveis de saída deste problema de programação linear, estas encontram-se discriminadas nos pontos seguintes:

- P_{rede} – Vetor otimizado do consumo proveniente da rede [kW];
- P_{bat} – Vetor correspondente à utilização ótima da bateria [kW];
- E_{bat} – Vetor corresponde à energia da bateria durante todo período de otimização [kWh].

4.3 Caso de estudo

4.3.1 Conjunto de dados

Para entender o funcionamento do sistema de otimização, foi selecionado um do conjunto de dados previsto, 20 de abril de 2021.

A figura 4.6 apresenta, os valores de consumo previstos e reais durante 24 horas.




Figura 4.6 – Consumo previsto versus real

Os dados da produção solar fotovoltaica para o mesmo dia, são apresentados na figura 4.7




Figura 4.7 – Produção solar prevista versus real

Juntando as figuras 4.6 e 4.7 é possível construir a imagem completa do dia 20 de abril de 2021, conseguindo obter uma melhor percepção entre o consumo e a produção

solar fotovoltaica. Para efeito deste estudo foi selecionado o conjunto de dados previstos, com o objetivo de unir o modelo de previsão com o modelo de gestão do sistema. Esta composição de dados é observada na figura 4.8.




Figura 4.8 – Consumo e produção solar do ISEL – Previsto (20/4/2021)

4.3.2 Parâmetros da bateria

Neste ponto serão definidas as condições iniciais da bateria, com base nas variáveis de entrada já identificadas no ponto 4.2.2. Desta forma, estão compilados na tabela 4.1 os parâmetros para a simulação.

Tabela 4.1 – Parâmetros de entrada do modelo de gestão da bateria

N (período de observação)	24 horas
DT [segundos]	3600
P_{pv} [kW]	Vetor PV prevista/real (20/4/2021)
$P_{Consumo}$ [kW]	Vetor consumo prevista/real (20/4/2021)
CX [cent/kWh]	Vetor tarifa energética ISEL
P_{max} [kW]	400
P_{min} [kW]	400
E_{max} [kWh]	1250
E_{min} [kWh]	250

Utilizando os valores apresentados no ponto 4.3.1 e na tabela 4.1, o modelo de gestão da bateria irá ter como resultados de saída, um conjunto de vetores, compostos pelos dados correspondentes à utilização otimizada da potência da rede, P_{rede} , e do ciclo de carga/descarga da bateria. Este último ponto divide-se em dois vetores, a utilização ótima da potência da bateria, P_{bat} , e a energia disponível da bateria a cada intervalo, E_{bat} .

O valor inicial para a capacidade da bateria foi escolhido com base no valor que está idealizado para ser instalada no *campus* do ISEL. Quanto ao valor da potência do conversor foi escolhido o valor de 400 kW, como ponto de partida. Ao longo das simulações seguintes será avaliado qual impacto da alteração da potência do conversor.

4.3.3 Simulação do modelo de gestão do sistema

- **Simulação – Condições apresentadas na tabela 4.1**

Com base nos valores estabelecidos no ponto 4.3.2, estão reunidas as condições para simular o modelo da gestão da bateria, obtendo-se os resultados apresentados na figura 4.9.

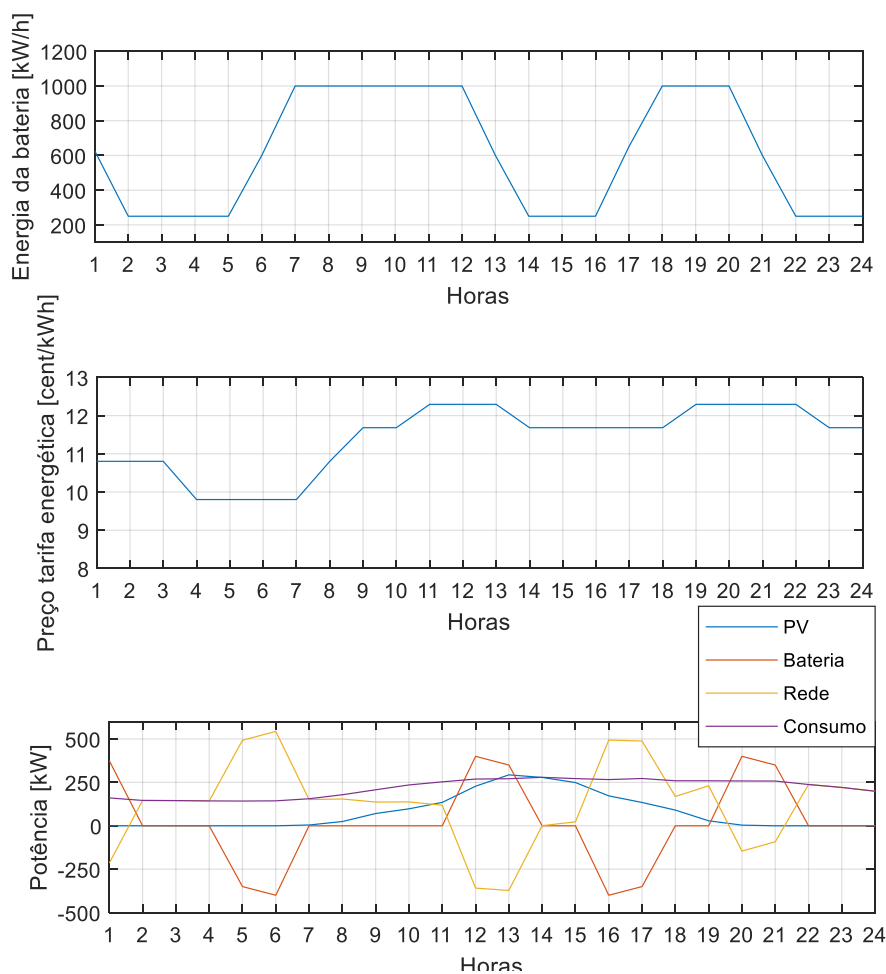


Figura 4.9 – Modelo de otimização – Dados previstos (20/4/2021)

Na figura 4.9 é possível observar a evolução temporal de 24 horas da energia da bateria que resulta da tarifa a aplicar nas diferentes horas (obtida pela leitura das faturas de energia do ISEL) e também das seguintes variáveis:

- PV – Potência proveniente dos painéis solares fotovoltaicos [kW];
- Bateria – Potência de funcionamento da bateria [kW];
- Rede – Potência trocada com a rede [kW];
- Consumo – Carga do *campus* do ISEL [kW].

Verifica-se que a energia da bateria é fortemente influenciada pelo preço da tarifa energética. Este comportamento deve-se ao fato de ser a minimização do custo a constar na função objetivo. Desta forma a bateria irá carregar nos períodos em que o preço da eletricidade seja mais baixo, aproveitando para descarregar nos períodos em que a tarifa energética é mais elevada. A produção solar fotovoltaica, neste modelo, desempenha o papel de atenuar o consumo proveniente da rede.

A análise da figura 4.9 pode ser realizada de uma forma mais pormenorizada, estabelecendo um conjunto de janelas temporais, apresentadas nos seguintes pontos.

- **(1:00 – 2:00)** – A bateria inicia a simulação com 50 % da sua capacidade, neste caso 625 kWh. Tendo energia para descarregar e prevendo que o preço da tarifa irá diminuir o modelo irá dar ordem para a bateria descarregar, aproveitando o preço que é praticado entre a 1:00 e as 2:00.
- **(2:00 – 7:00)** – No início deste período, a bateria encontra-se no seu nível mínimo de energia, apresentando um valor de 250 kWh, correspondente a SOC de 20%. O modelo garantiu que a bateria iria descarregar toda a sua energia até às 2:00, esperando pelo instante em que a tarifa atinja o seu valor mais baixo, entre as 4:00 e as 7:00, para iniciar o seu ciclo de carregamento. Durante o período em que o preço do kWh atinge o seu mínimo, 4:00 e as 7:00, a bateria é carregada através da rede, onde a variável P_{grid} , é composta pela potência de carregamento da bateria e pela potência associada ao consumo do ISEL. Assim é garantido que às 7:00 a bateria encontra-se totalmente carregada.
- **(7:00 - 12:00)** – Durante este intervalo de tempo a bateria permanece na sua carga máxima. A única variável a atenuar o consumo do ISEL é a produção fotovoltaica, conseguindo reduzir o valor da potência proveniente da rede.
- **(12:00 – 14:00)** – Uma vez que o preço da tarifa atinge o seu pico entre as 12:00 e as 13:00, a bateria irá descarregar. É neste período, que a bateria em conjunto com a produção proveniente do sistema fotovoltaico, conseguem ter maior impacto sobre o consumo do ISEL, tendo capacidade para satisfazer a carga do ISEL, como para vender energia no período em que a tarifa é mais elevada, sendo o excedente proveniente da bateria. A bateria irá descarregar toda a sua energia, atingindo o seu valor mínimo.
- **(14:00 – 16:00)** – Nesta janela temporal, a bateria permanece inativa, uma vez que a tarifa praticada neste período é elevada, não compensando iniciar o ciclo de carregamento. Entre as 14:00 e as 16:00 o único fator a atenuar o consumo proveniente da rede é a produção solar.
- **(16:00 – 18:00)** - Assim que o preço da tarifa reduz, a bateria irá iniciar o seu ciclo de carga. E enquanto entre as 11:00 e as 14:00 a bateria conseguia diminuir a potência proveniente da rede, a partir das 16:00 o cenário torna-se no oposto,

utilizando a rede para carregar a bateria, aumentando assim o valor da potência proveniente da rede.

- **(18:00 – 20:00)** – A bateria estando totalmente carregada, irá permanecer inativa durante este período até o valor da tarifa energética voltar a incrementar. Mais uma vez o consumo proveniente da rede é atenuado pela produção solar do sistema fotovoltaico.
- **(20:00 – 22:00)** – Uma vez que a tarifa energética volta a atingir o preço máximo, o modelo de gestão descarrega toda a energia da bateria. Entre aproximadamente as 19:00 e as 21:00, a bateria têm capacidade para satisfazer as necessidades energéticas do ISEL.
- **(22:00 – 24:00)** – No último período, a bateria encontra-se descarregada, tendo aproveitado o preço da energia praticado durante a janela temporal anterior. Como a tarifa praticada continua a ser elevada, o modelo de otimização opta por não carregar a bateria durante este período. Não existindo produção solar nem energia a ser descarregada por parte da bateria, todas as necessidades energéticas do *campus* são satisfeitas através da rede.

A figura 4.9 é complementada pela análise dos custos associados às trocas energéticas mencionadas nos pontos anteriores. Foram calculadas duas variáveis, uma associada ao valor da energia vendida à rede e outra relacionada com o valor da energia consumida da rede. Como preço de venda de energia à rede foi considerado o valor de 3 cent/kWh. O sinal associado à variável P_{rede} , é indicativo se existe potência a ser injetada na rede (-) ou a ser consumida (+). A figura 4.10, apresenta os momentos em que o ISEL está a vender e a comprar energia à rede-




Figura 4.10 – Custo de utilização da rede – Dados previstos (20/4/2021)

A partir da figura 4.10 é possível calcular o resultado financeiro resultante das interações entre o ISEL e a rede elétrica. Neste cenário, recorrendo ao modelo de gestão construído, foi obtido um valor de -435.63 euros.

Com o objetivo de comparar a robustez do modelo de previsão, o sistema de otimização apresentado nas figuras 4.9 e 4.10 será adaptado de forma que as variáveis que alimentam este sistema sejam os valores que correspondem a um modelo de previsão com erro nulo. Seguindo este raciocínio, tanto o vetor P_{pv} e como o vetor $P_{Consumo}$ serão compostos pelos valores de potência que correspondem aos dados reais. Os restantes parâmetros que caracterizam este sistema, são idênticos aos assinalados na tabela 4.1. Os resultados obtidos na nova simulação apresentam-se na figura 4.11

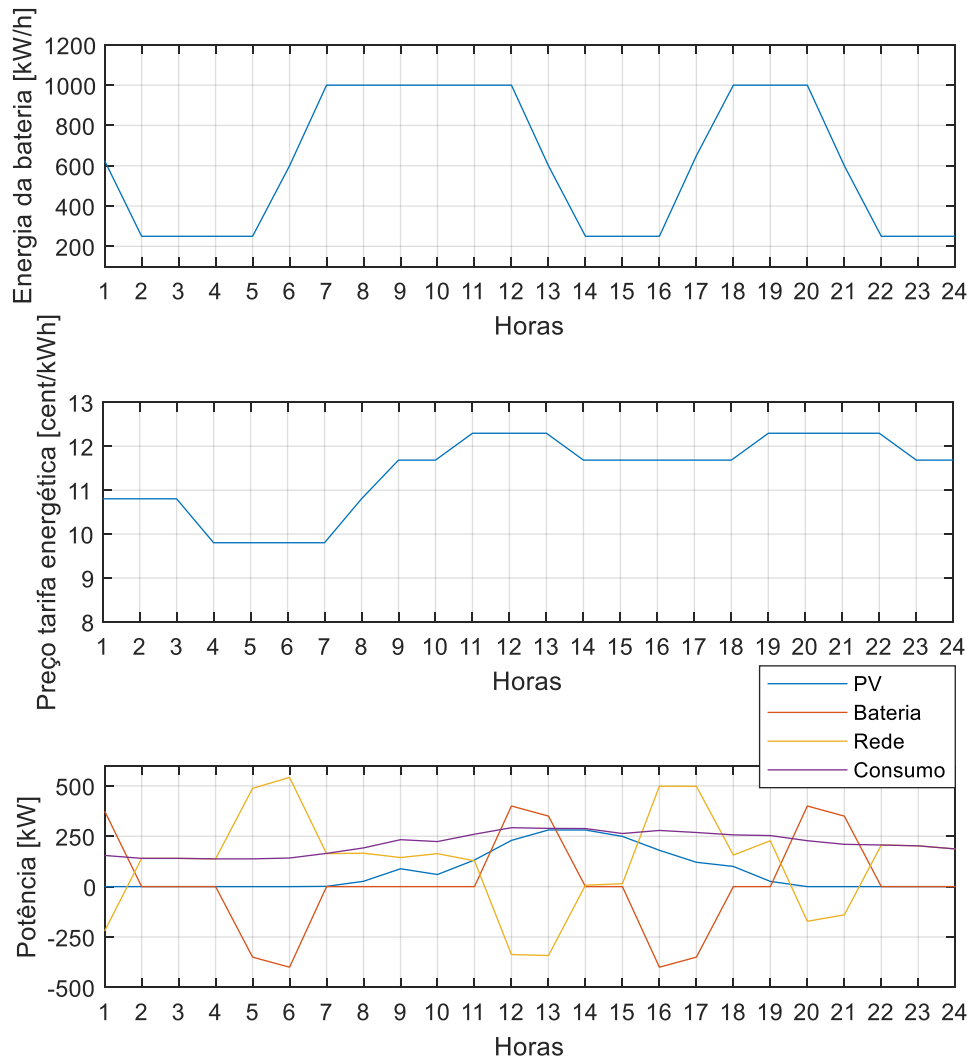


Figura 4.11 - Modelo de otimização – Dados reais (20/4/2021)

Comparando a modelo de otimização retratado na figura 4.9 com o modelo apresentado na figura 4.11, é possível ver que o comportamento da bateria é muito semelhante em ambos os casos durante as 24 horas analisadas. A principal diferença, está localizada entre as 7:00 e as 14:00. Enquanto no modelo apresentado na figura 4.9 o consumo ISEL apresenta um comportamento crescente até as 12:00, o mesmo não acontece na acontece na figura 4.11, existindo uma quebra no consumo do *campus* entre as 9:00 e as 10:00. No que toca à produção solar fotovoltaica, também aqui existem pequenas alterações, enquanto na figura 4.9 a produção solar apresenta um crescimento gradual até às 13:00. Na figura 4.11 é visível um pico de produção às 9:00 seguido de quebra na produção às 10:00, voltando de seguida a aumentar até às 13:00. Outra diferença que pode ser assinalada é o facto de existir um momento entre as 13:00 e as 14:00, em que a produção solar é superior ao consumo do ISEL, visível na figura 4.9.

Já na figura 4.11 a produção solar não chega a superar a curva de consumo do *campus* nesse mesmo instante. Estas diferenças estão evidenciadas na figura 4.12.




Figura 4.12 – Diferenças entre figuras 4.9 e 4.11 (20/4/21)

Também foi efetuada uma análise aos custos para o caso em que o sistema de otimização estivesse a utilizar valores de previsão com erro nulo. Assim sendo, utilizando as mesmas considerações que permitiram criar a figura 4.10, foi obtida a figura 4.13.





Figura 4.13 - Custo de utilização da rede – Dados reais (20/4/2021)

As diferenças identificadas anteriormente, também se refletem na figura 4.13, sendo possível identificar diferenças entre as 7:00 e as 14:00. Outra diferença, que é realçada ao comparar as figuras 4.10 e 4.13, está situada entre as 22:00 e as 24:00. Durante este período, a tarifa energética apresentar um preço elevado, e ao comparar a figura 4.9 com a figura 4.11 é identificado que o consumo proveniente da rede é superior no sistema de otimização contruído com os valores previstos, comparativamente com o modelo de otimização construído com os valores reais. Esta diferença está identificada na figura 4.14.

Modelo de otimização – Dados previstos



Modelo de otimização – Dados reais




Figura 4.14 – Diferenças entre figuras 4.9 e 4.11 (20/4/21)

Devido a esta diferença nos últimos períodos do dia, em que o preço da energia é bastante elevado, o valor do custo calculado para o sistema de otimização baseado nos dados que representam um sistema de previsão perfeito, foi inferior, obtendo um valor de -432.22 euros.

Na tabela 4.2 estão indicados os valores de custo para os dois casos, comparando um sistema com base em valores obtidos pela RNA do capítulo 3, com um que apresenta um modelo de previsão com erro nulo.

Tabela 4.2 – Comparação de custos – valores previstos versus reais

	Valores previstos	Valores reais
Custo da energia consumida da rede [€]	471.13	468.57
Receita da energia vendida à rede [€]	35.50	36.35
Lucro [€]	-435.63	-432.22

Ao analisar a tabela 4.2 é possível verificar a proximidade entre os valores previstos e os valores reais, evidenciada pela diferença de custos entre os dois exemplos, mais precisamente 3.41 euros. No capítulo 3 já tinha sido verificada a boa aderência do modelo de previsão, contudo através desta simulação foi possível reforçar a robustez do modelo de previsão, tanto do modelo de consumo como do modelo de produção solar fotovoltaica.

A partir deste pressuposto, nas simulações apresentadas nos seguintes pontos, serão utilizados os dados previstos obtidos através da RNA desenvolvida anteriormente.

- **Simulação – Alterando a capacidade da bateria para 2500 kWh**

Neste ponto as condições de simulação encontram-se descritas na tabela 4.3, retratando o caso em que a bateria apresente uma capacidade máxima de 2500 kWh.

Tabela 4.3 - Parâmetros de entrada do modelo de gestão da bateria

N (período de observação)	24 horas
DT [segundos]	3600
P_{pv} [kW]	Vetor PV prevista/real (20/4/2021)
$P_{Consumo}$ [kW]	Vetor consumo prevista/real (20/4/2021)
CX [cent/kWh]	Vetor tarifa energética ISEL
P_{max} [kW]	400
P_{min} [kW]	400
E_{max} [kWh]	2500
E_{min} [kWh]	500

Com base nestes valores foi obtida a figura 4.15.

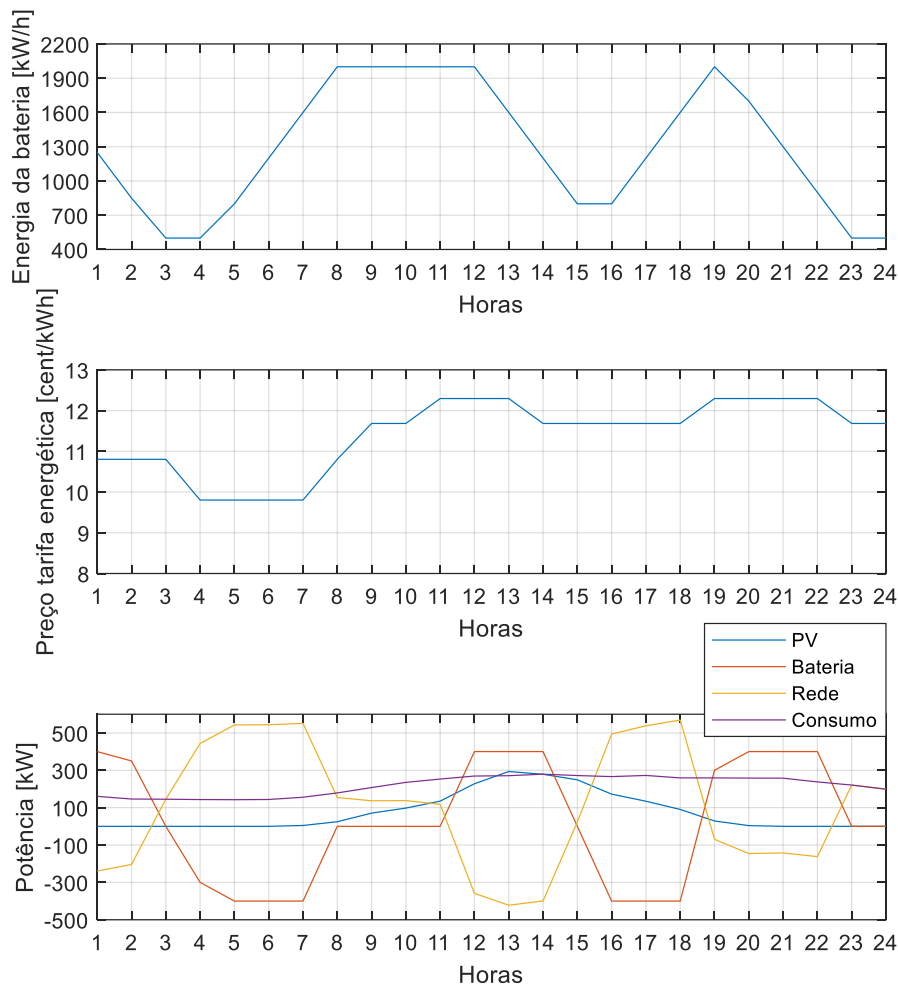


Figura 4.15 - Modelo de otimização – Dados previstos (20/4/2021)

Observando a figura 4.15, é possível concluir que aumentando a capacidade da bateria o primeiro gráfico, associado à energia da bateria, sofre uma deslocação de uma hora. Esta alteração deve-se ao facto de o modelo ter de gerir uma capacidade superior de energia no mesmo espaço de tempo, sem ser alterada a potência do conversor. Analisando o gráfico da potência, é visível que os períodos de funcionamento estão alargados, onde este aumento da energia da bateria culmina num aumento do tempo de carga e descarga da bateria. O comportamento do sistema de otimização da figura 4.15 segue em linha do comportamento descrito para o caso da bateria de 1250 kWh. O modelo de gestão tenta carregar a bateria nos períodos em que a tarifa energética é mais barata e descarrega nas horas em que o preço da energia é mais elevado.

De forma a complementar a análise da figura 4.15, a figura 4.16 apresenta, os custos associados às horas de consumo e venda de energia da rede.




Figura 4.16 - Custo de utilização da rede – Dados previstos (20/4/2021)

Analisando a figura 4.16 e a figura 4.10 é visível que uma bateria com uma capacidade maior, aumenta o consumo de energia da rede, e consequentemente o custo associado, uma vez que a produção solar não é suficiente para apoiar o processo de carregamento. Na tabela 4.4 estão indicados os valores de custo para os dois casos, comparando uma bateria com uma capacidade de 1250 kWh com uma bateria de 2500kWh.

Tabela 4.4 – Comparação de custos para diferentes capacidades

	Capacidade 1250 kWh (figura 4.10)	Capacidade 2500 kWh (figura 4.16)
Custo da energia consumida da rede [€]	471.13	529.82
Receita da energia vendida à rede [€]	35.50	64.31
Lucro [€]	-435.63	-465.51

Com base nos resultados apresentados na tabela 4.4, é visível que um aumento da capacidade da bateria por si só não é a resposta para uma redução nos custos do consumo da energia proveniente da rede.

Com intuito de entender qual o impacto das variáveis P_{max} e P_{min} , a próxima simulação irá envolver a diminuição da potência de conversão de 400 kW para 100 kW, escolhendo uma bateria com uma capacidade de 1250 kWh.

- **Simulação – Alterando a potência do conversor para 100 kW**

As condições escolhidas para o caso apresentado neste ponto estão descritas na tabela 4.5.

Tabela 4.5 - Parâmetros de entrada do modelo de gestão da bateria

N (período de observação)	24 horas
DT [segundos]	3600
P_{pv} [kW]	Vetor PV prevista/real (20/4/2021)
$P_{Consumo}$ [kW]	Vetor consumo prevista/real (20/4/2021)
CX [cent/kWh]	Vetor tarifa energética ISEL
P_{max} [kW]	100
P_{min} [kW]	100
E_{max} [kWh]	1250
E_{min} [kWh]	250

A partir destes dados foi gerada a figura 4.17.

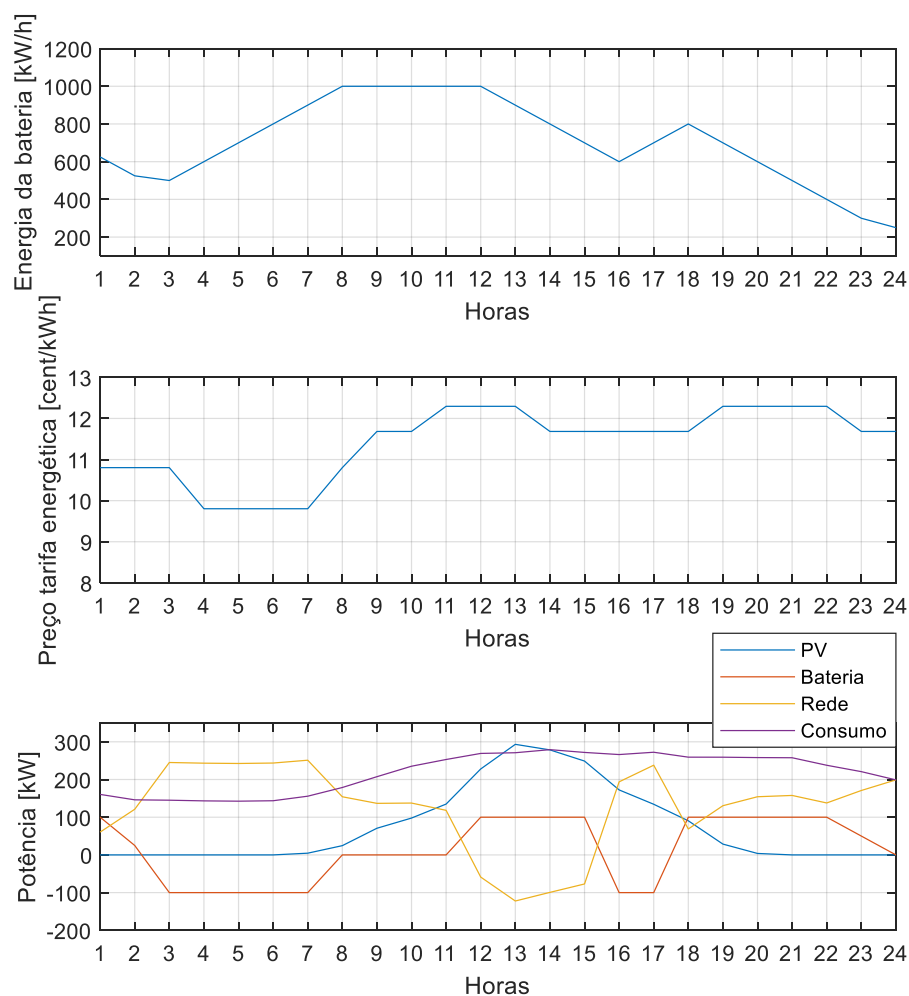


Figura 4.17 - Modelo de otimização – Dados previstos (20/4/2021)

Comparando a figura 4.17 com a figura 4.9, em ambas as simulações, as baterias apresentam uma capacidade de 1250 kWh, a diferença entre os resultados, está relacionada com a rapidez com que a bateria consegue carregar/descarregar. Enquanto no exemplo apresentado na figura 4.9, a bateria consegue estar a ser carregada/descarregada a uma potência de 400 kW, no modelo retratado na figura 4.17, o sistema só permite que a bateria seja carregada/descarregada a uma potência de 100 kW.

Esta alteração permite observar, que ao diminuir a potência de conversão, o primeiro gráfico e o terceiro gráfico apresentam um aumento nos tempos de carga/descarga. Novamente o sistema de otimização irá tentar gerir a bateria para carregar durante o período horário em que preço da energia é mais baixo, com o objetivo de vender a energia armazenada no período em que a tarifa apresenta um valor mais elevado. Na figura 4.17 a bateria fica carregada às 8:00, iniciando a descarga às 12:00, momento em que a tarifa apresenta um valor elevado. Contudo devido ao sistema estar limitado a uma

potência de descarga de 100 kW por hora, não vai ser possível descarregar a bateria na sua totalidade antes do preço da tarifa voltar a diminuir. Desta forma, o sistema irá tentar aproveitar o preço da energia que é praticado entre as 14:00 e as 18:00 para carregar a bateria.

Dada a limitação de 100 kW imposta pelo conversor, no momento que o sistema atinge as 18:00, a bateria não vai estar na sua carga máxima. Devido à tarifa voltar a aumentar a partir das 18:00, a bateria irá inverter o seu modo de funcionamento, passando assim a descarregar. Esta mudança acontece devido ao sistema ter como objetivo rentabilizar a tarifa máxima praticada entre as 19:00 e as 22:00, garantindo também, que a bateria descarrega toda a sua carga durante um período em que é rentável.

A figura 4.18 apresenta os custos horários de compra e venda de energia à rede




Figura 4.18 - Custo de utilização da rede – Dados previstos (20/4/2021)

Uma vez que o ciclo de carregamento/descarregamento da bateria está limitado pela potência do conversor, 100 kW, é possível verificar o impacto desta redução no custo de energia, figura 4.18. A potência do conversor só permite que a bateria seja carregada na sua totalidade uma vez no decorrer das 24 horas. Esta alteração, irá reduzir a energia consumida da rede, reduzindo por sua vez o custo da energia.

Comparando com a figura 4.10, é verificado que o custo da energia consumida é superior devido a existirem dois períodos em que a bateria é carregada na sua totalidade, no qual durante um destes períodos a tarifa energética é elevada, entre as 15:00 e as 18:00. Este comportamento irá aumentar o custo da energia consumida da rede, visto que a bateria carrega através da rede elétrica. Analisando a figura 4.10, o valor máximo do custo de energia consumida da rede atinge os 58 euros, enquanto na figura 4.18 o valor máximo do custo de energia consumida da rede é aproximadamente 28 euros.

No caso apresentado na figura 4.18 o período em que a energia apresenta o valor mais elevado corresponde ao momento em que o sistema tenta carregar novamente a bateria de forma a conseguir rentabilizar a tarifa energética praticada a entre as 16:00 e as 18:00, contudo devido à potência do conversor ser inferior, a bateria não consegue atingir a capacidade máxima.

Na tabela 4.6 estão indicados os valores de custo para os dois casos, ambas as baterias apresentam uma capacidade de 1250 kWh, não obstante um sistema apresenta um conversor de 100 kW e o outro sistema um conversor de 400 kW.

Tabela 4.6 - Comparação de custos entre figura 4.10 e 4.18

	Potência 400 kW (figura 4.10)	Potência 100 kW (figura 4.18)
Custo da energia usada da rede [€]	471.13	378.49
Receita da energia vendida à rede [€]	35.50	10.72
Lucro [€]	-435.63	-367.77

Apesar do sistema que inclui o conversor de 400 kW, ter capacidade para entregar mais energia à rede, a potência que este despende para carregar a bateria acaba por causar um maior impacto na energia que o ISEL consome da rede, não tirando proveito da rapidez de carregamento.

Utilizando um conversor de 100 kW numa bateria de 2500 kWh, é possível verificar que o sistema de otimização aplica a mesma estratégia, distribuindo o carregamento da bateria pelas horas em que o preço está mais baixo. Assim que o valor da tarifa atinge o máximo, a partir das 11:00, a bateria irá descarregar até ao final do dia. O fato da potência do conversor ser mais baixa, também contribui para diminuição do

consumo do ISEL proveniente da rede. O único momento em que a bateria irá carregar, é o momento em que a tarifa apresenta o valor mais baixo durante o intervalo das 24 horas, algo que não se verifica no caso onde é utilizado um conversor de 400 kW, sendo a bateria carregada em dois períodos.

No entanto, devido a estar limitada pelo conversor, a bateria não irá conseguir descarregar toda a energia que armazenou durante o período em que a tarifa é mais rentável. A informação descrita pode ser analisada na figura 4.19.

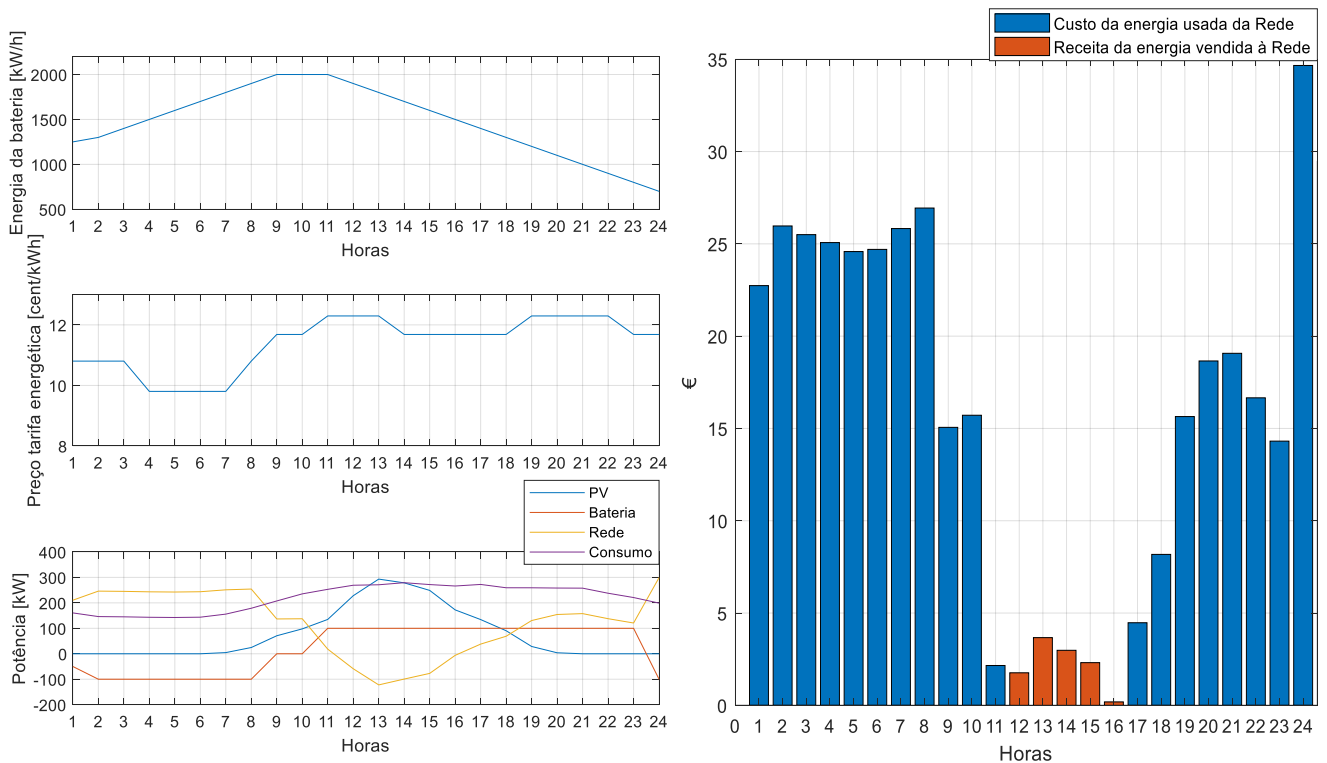


Figura 4.19 - Modelo de otimização (à esquerda) e Custo de utilização da rede (à direita) - Dados previstos

Na tabela 4.7 estão indicados os valores de custo para os dois casos, ambas as baterias apresentam uma capacidade de 2500 kWh, contudo um sistema apresenta um conversor de 100 kW e o outro sistema um conversor de 400 kW.

Tabela 4.7 - Comparação de custos entre figura 4.16 e 4.19

	Potência 400 kW (figura 4.16)	Potência 100 kW (figura 4.19)
Custo da energia usada da rede [€]	529.82	365.91
Receita da energia vendida à rede [€]	64.31	18.19
Lucro [€]	-465.51	-347.72

Para ter noção do impacto do sistema de otimização, foi escolhido realizar uma última simulação, considerando o sistema sem a bateria. O propósito deste ensaio é verificar qual a diferença de custo entre os sistemas de otimização descritos nos pontos anteriores em relação a uma solução sem bateria. Simulando o sistema sem SAE foi possível obter a figura 4.20

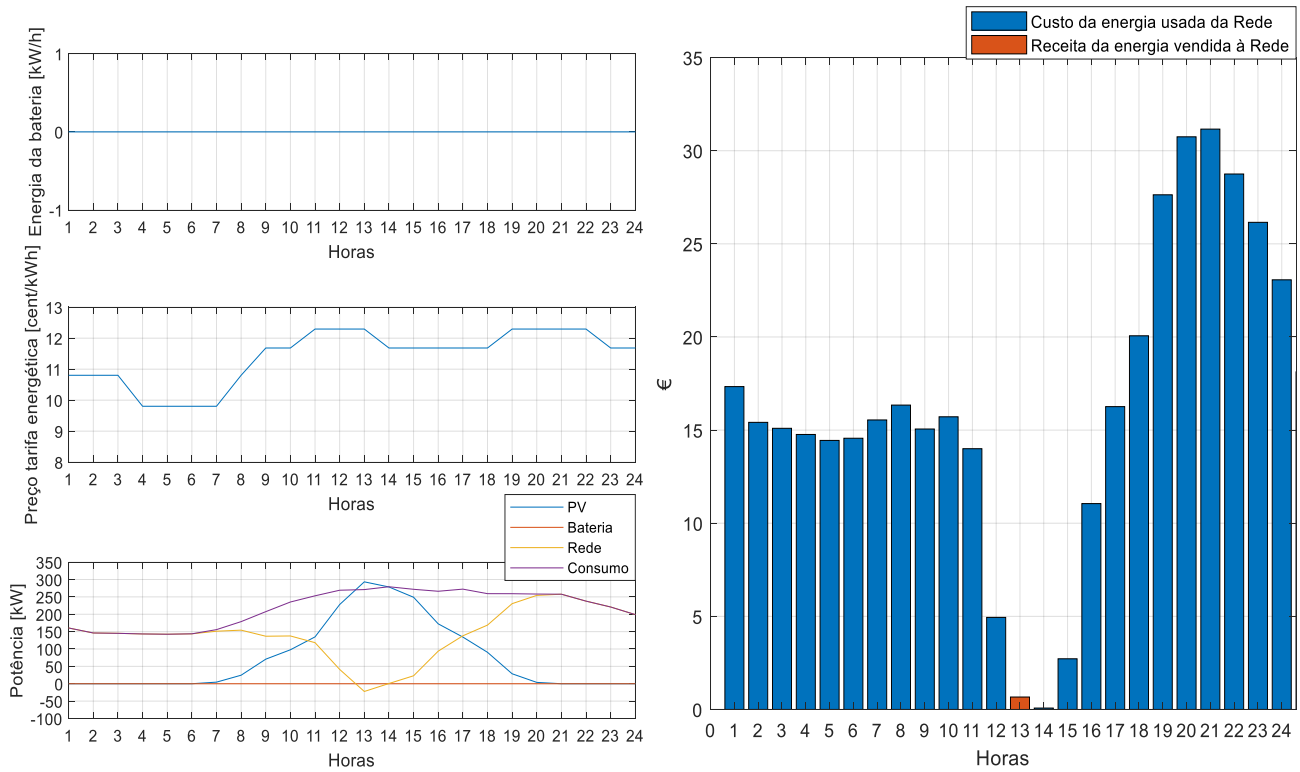


Figura 4.20 - Modelo s/ SAE (à esquerda) e Custo de utilização da rede (à direita) - Dados previstos

Comparando os cenários entre as figuras 4.19 e 4.20, é possível construir tabela 4.8.

Tabela 4.8 - Comparação de custos entre figura 4.19 e 4.20

	Capacidade 2500 kWh / Potência 100 kW (figura 4.19)	Simulação s/ SAE (figura 4.20)
Custo da energia usada da rede [€]	365.91	390.92
Receita da energia vendida à rede [€]	18.19	0.66
Lucro [€]	-347.72	-390.26

Analisando a tabela 4.8 é possível concluir que com a combinação certa entre a capacidade da bateria e a potência do conversor, o sistema de armazenamento consegue diminuir o custo da energia proveniente da rede.

Das várias simulações realizadas verificou-se, que a escolha de um conversor com uma potência elevada não representa uma mais-valia para o sistema. Esta conclusão deve-se ao facto de nas figuras 4.9, 4.11 e 4.15, a potência do conversor contribuir para que a bateria consiga ser carregada em dois períodos, entre as 5:00 e as 7:00 e entre as 16:00 e as 18:00.

O segundo ciclo (16:00 – 18:00) de carregamento tem um maior impacto sobre o custo da energia proveniente da rede, uma vez que a tarifa energética é bastante superior à tarifa praticada entre as 5:00 e as 7:00. De certa forma o carregamento no segundo período não compensa, visto que o preço a que a energia é vendida, apresenta valores inferiores comparativamente com o preço da energia que é consumida da rede.

A simulação com resultados mais satisfatórios, está associada ao caso em foi diminuída a potência do conversor. Esta alteração irá limitar a taxa de carga/descarga da bateria, não permitindo que esta consiga iniciar estes ciclos com tanta rapidez. Com base nesta limitação a bateria só carrega num período, e o sistema de otimização coloca a bateria a carregar durante o período em que a energia é mais barata. No que toca ao descarregamento, assim que o preço da energia atinge o valor máximo da tarifa, a bateria descarrega.

Uma última análise, passa por recriar os dados apresentados na tabela 4.8, utilizando o conjunto de dados associados a um modelo de previsão com erro nulo. Assim sendo foi escolhido o exemplo em que a bateria tem uma capacidade 2500 kWh e o conversor uma potência de 100kW. Com base nestes dados foi criada a figura 4.21.

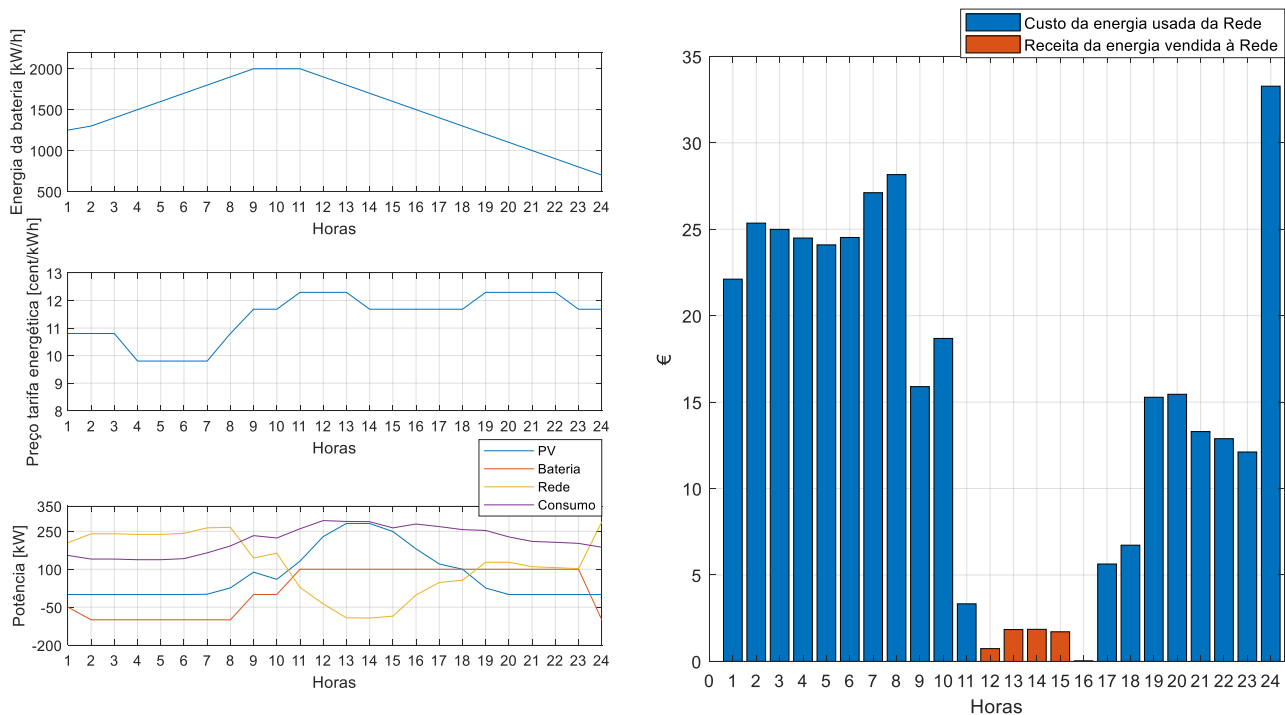


Figura 4.21 - Modelo de otimização (à esquerda) e Custo de utilização da rede (à direita) - Dados reais

Na figura 4.22 estão apresentados os valores para o caso em que não foi implementado um SAE, considerando um modelo de previsão com erro nulo.

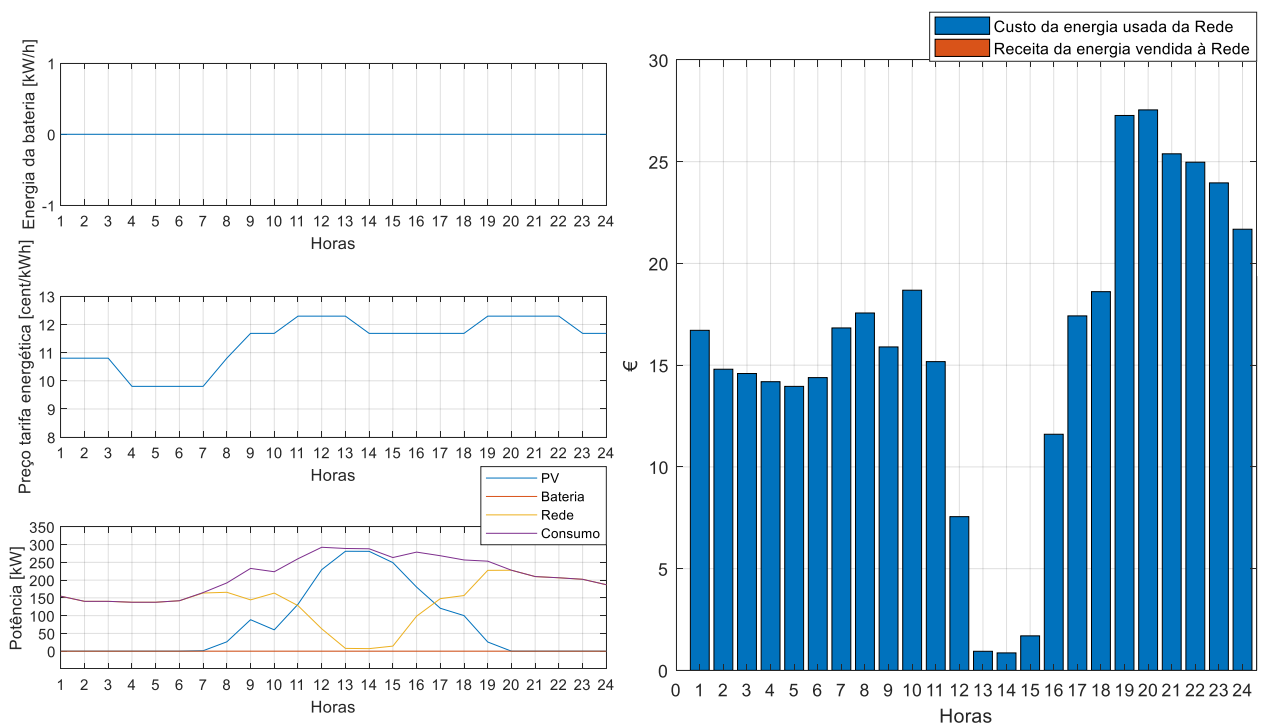


Figura 4.22 - Modelo s/ SAE (à esquerda) e Custo de utilização da rede (à direita) - Dados reais

Comparando os cenários entre as figuras 4.21 e 4.22, é possível construir tabela 4.9.

Tabela 4.9 - Comparação de custos entre figura 4.21 e 4.22

	Capacidade 2500 kWh /Potência 100kW (figura 4.21)	Simulação s/ SAE (figura 4.22)
Custo da energia usada da rede [€]	353.41	382.29
Receita da energia vendida à rede [€]	6.18	0.00
Lucro [€]	-347.23	-382.29

Como constatado anteriormente, comparando a tabela 4.8 com a tabela 4.9, verifica-se a proximidade entre os valores previstos e os valores reais. A diferença entre os dois exemplos já foi analisada no primeiro caso apresentado no ponto 4.3.3. Apesar do modelo de previsão da produção solar apresentar um valor ligeiramente superior ao modelo com erro nulo, o modelo de previsão do consumo também apresenta um valor de consumo ligeiramente superior, evidenciado no período em que o custo da energia apresenta a tarifa mais elevada. Desta forma é possível verificar que a apesar de o modelo de previsão permitir que seja vendida mais energia à rede, o facto de existir mais consumo nas horas de ponta, contribui para o aumento da energia consumida da rede. O modelo de previsão com erro nulo, apesar de apresentar um valor inferior de energia vendida à rede, a energia consumida no período de ponta também é inferior. Isto resulta num custo de energia consumida da rede inferior ao modelo de previsão desenvolvido no capítulo 3. Assim sendo, relativamente ao custo final da energia consumida da rede, a diferença entre os dois modelos é 0.49 euros, como mostra a tabela 4.10

Tabela 4.10 – Comparação de lucro entre modelo de previsão construído e modelo de previsão com erro nulo (SAE implementado)

Lucro c/ modelo de previsão desenvolvido [€]	-347.72
Lucro c/ modelo de previso com erro nulo [€]	-347.23
Diferença de lucro [€]	0.49

A mesma análise foi estendida para o caso em que não existe um SAE, onde as diferenças explicadas anteriormente, também são evidências no caso em que não foi implementada um sistema com baterias. Na tabela 4.11 está apresentado o custo final da energia consumida da rede, para o caso em que foi utilizada a RNA e para o caso em que foi considerado um modelo de previsão com erro nulo.

Tabela 4.11 - Comparação de lucro entre modelo de previsão construído e modelo de previsão com erro nulo (Sem SAE)

Lucro c/ modelo de previsão desenvolvido [€]	-390.26
Lucro c/ modelo de previsão com erro nulo [€]	-382.29
Diferença de lucro [€]	7.97

A diferença entre os valores apresentados na tabela 4.11 deve-se ao facto de o modelo de previsão desenvolvido no capítulo 3, apresentar um valor de consumo ligeiramente superior ao modelo de previsão com erro nulo no período em que a tarifa energética é máxima.

No seguimento da análise anterior, a escala temporal dos dados observados será estendida à totalidade dos dados que compõem o conjunto de previsão, 265 dias do ano de 2021. Serão comparados os resultados para um caso em que é implementado um SAE, com as seguintes características, bateria com uma capacidade de 2500 kWh e um conversor com uma potência de 100kW, e outro caso em que não existe um SAE.

Na tabela 4.12 estão indicados os valores de custo para os dois casos.

Tabela 4.12 - Comparação de custos entre sistema com SAE e sem SAE (modelo de previsão desenvolvido)

	Capacidade 2500 kWh /Potência 100kW	Simulação s/ SAE
Custo da energia usada da rede [€]	119 210	113 720
Receita da energia vendida à rede [€]	10 237	3 522
Lucro [€]	-108 973	-110 198
Diferença entre Lucro [€]	1 225	

Analisando a tabela 4.12 constata-se que o modelo com um SAE permite diminuir o custo do consumo da rede em 1225 euros comparativamente ao modelo em que não é instalado um SAE, durante entre 9 de janeiro e 30 de setembro de 2021.

Como complemento à análise elaborada na tabela 4.12, o mesmo estudo será realizado considerando um modelo de previsão com erro nulo. A comparação dos custos entre um sistema com SAE e um sistema sem SAE, recorrendo a um modelo de previsão com erro nulo estão apresentados na tabela 4.13.

Tabela 4.13 - Comparação de custos entre sistema com SAE e sem SAE (modelo de previsão com erro nulo)

	Capacidade 2500 kWh /Potência 100kW	Simulação s/ SAE
Custo da energia usada da rede [€]	121 080	116 070
Receita da energia vendida à rede [€]	113 88	45 22
Lucro [€]	-109 692	-111 548
Diferença entre Lucro [€]	1856	

Comparando a tabela 4.12 com a tabela 4.13 é possível verificar a proximidade entre os resultados do modelo com dados previstos e com dados reais, reforçando a aderência do modelo de previsão desenvolvido neste estudo. Nos dois exemplos é verificado que a utilização de um SAE consegue atenuar o consumo da rede, apresentando um custo de consumo da rede inferior relativamente aos modelos em que não é implementado um SAE.

Capítulo V

Conclusões

Resumo:

Neste capítulo são apresentadas as conclusões referentes ao estudo apresentado. O objetivo é verificar de que forma foram alcançados os objetivos propostos. Apresentando no final um conjunto de pontos que podem servir de base para uma melhoria dos modelos desenvolvidos ao longo desta dissertação

5 Conclusões

Neste estudo a primeira etapa passou por analisar o padrão de consumo do *campus* bem como o padrão da produção solar fotovoltaica. Este conjunto de dados não permitia entender qual o consumo real das instalações, visto que não ser possível determinar qual a produção real fotovoltaica. Considerando que não houve alterações significativas nos padrões de consumo do ISEL tomou-se como valores de referência de consumo para 2020 os valores de 2019. Foram utilizados dos consumos de 2019 porque nesse período ainda não havia produção solar. Esta aproximação permitiu construir um novo conjunto de dados, permitindo definir o excesso proveniente da produção solar.

Com o conjunto de dados definido, foi desenvolvida uma RNA. Numa primeira fase foi necessário estabelecer as variáveis de entrada e variáveis de saída do modelo a desenvolver. O conjunto de dados, dividia-se em dois conjuntos, consumo e produção solar fotovoltaica, desta forma foi necessário desenvolver dois modelos de previsão. Tendo as variáveis definidas, foram simuladas três arquiteturas, onde cada uma delas foi alterado o número de elementos da camada escondida. Entre estas simulações foi comparado o MSE, tendo sido escolhida a arquitetura com menos elementos da camada escondida. Outra aproximação que permitiu melhorar a qualidade de previsão da RNA desenvolvida, passou por simular 15 redes e calcular a média aritmética entre os respetivos resultados. O objetivo desta técnica é criar resultados suficientemente genéricos e que se adaptem a qualquer conjunto dos dados fornecidos.

Como complemento ao modelo de previsão desenvolvido foi construído um modelo de otimização com o objetivo de minimizar o custo da energia consumida da rede. Neste modelo de otimização foi incorporado um SAE, com o propósito de contribuir para esta redução do custo. Foi idealizado um sistema que tenta minimizar o custo da energia consumida em função da capacidade da bateria, da potência do conversor e a potência proveniente da rede. Sendo um problema com funções lineares optou-se por um algoritmo de programação linear. Verificou-se que sempre que possível a bateria carregava durante períodos em que a tarifa energética era mais baixa, para descarregar nos momentos em que a tarifa energética apresentava valores mais elevados, horas de ponta. Conclui-se que a bateria não carregava através da produção solar fotovoltaica, mas sim através da rede. Assim o papel do sistema solar fotovoltaica foi apenas diminuir o valor da potência

consumida da rede, uma vez que o excedente da produção solar não era suficientemente elevado para ser considerado no carregamento da bateria.

Estando definindo o sistema de otimização, foram criados diferentes casos de estudo, variando a capacidade da bateria e a potência do conversor. Para testar a viabilidade do modelo de previsão desenvolvido neste estudo, foram criados casos em que o sistema de otimização utiliza os dados da RNA criada no capítulo 3 e casos em que o modelo de otimização utiliza o conjunto de dados reais, sendo este último considerado como um modelo de previsão com erro nulo. Dos casos analisados conclui-se, que os resultados finais são fortemente dependentes da potência do conversor. Num caso em que o sistema tenha um conversor desajustado, a bateria pode não ter tempo de descarregar/carregar a quantidade ótima de energia durante um período em que o custo seja favorável. No caso estudado, a bateria deveria carregar preferencialmente entre as 1:00 e as 9:00, período em que a tarifa energética apresenta o seu valor mais baixo e descarregar entre as 10:00 e as 24:00, aproveitando os períodos em que a tarifa é mais elevada. O sistema de otimização foi inicialmente aplicado a um dia do conjunto de dados, 20 de abril de 2021, composto por valores médios horários. Para este dia, com o objetivo de validar a robustez da RNA desenvolvida, também foi simulado o sistema de otimização com os dados de um modelo de previsão com erro nulo. Desta análise de 24 horas conclui-se que a melhor configuração é aquela em que a bateria apresenta uma capacidade de 2500 kWh e um conversor de 100 kW. Esta análise vai ao encontro da ideia mencionada anteriormente, evitar que a bateria carregue durante o período em que a tarifa energética é mais elevada.

De forma a compreender melhor o impacto do sistema de otimização, foi expandida a janela temporal dos dados, englobando os 265 dias presentes no conjunto de dados previstos.

Nesta análise final foi observado o impacto do SAE no custo da energia consumida da rede. Utilizando o sistema de otimização em conjunto com o modelo de previsão criado, o custo da energia consumida da rede do ISEL é 108973 euros, enquanto um sistema sem SAE com os dados de previsão obtidos através da RNA, o custo de energia consumida da rede do ISEL é 110198 euros. Recorrendo a um sistema de otimização com um SAE, foi possível obter uma redução de 1.1 %.

No caso em que foi considerado um modelo de previsão com erro nulo, no caso em que é utilizado um sistema de otimização o custo da energia consumida da rede é 109692 euros. Ao não considerar um SAE o custo de energia consumida da rede é 111548 euros. Considerando um modelo de previsão com erro nulo, a utilização de um sistema de otimização com um SAE permite uma redução no custo de 1.6 %.

Com base nestes dois casos é possível verificar que a utilização de um sistema de otimização poderá permitir reduzir o custo da energia consumida da rede. Também é possível verificar a proximidade entre o modelo de previsão desenvolvido e um modelo de previsão sem erro, existindo uma diferença de 0.5% entre os dois modelos.

5.1 Sugestões de trabalho futuro

Com intuito de melhorar o modelo de previsão recorrendo a uma RNA, este poderia beneficiar de um conjunto de dados maior, uma vez que neste estudo foi considerado o ano de 2020 e parte do no de 2021, mais precisamente até ao dia 30 de setembro de 2021. Este incremento no número de dados, permite alargar o conjunto de treino, dando a oportunidade à rede de melhorar a sua aprendizagem e compreender os pormenores que existem no consumo do ISEL. O modelo de previsão que poderá beneficiar deste aumento dos dados, será principalmente o modelo associado ao consumo do ISEL.

Outro ponto a estudar no desenvolvimento da RNA, será o ajuste ligeiro do enviesamento dos resultados.

No que toca ao modelo de otimização, este poderia ser melhorado ao adicionar à função objetivo do problema de otimização o custo de venda de energia, criando assim um modelo de programação linear multiobjectivo.

Referências Bibliográficas

- [1] V. Prema, M. S. Bhaskar, D. Almakhles, N. Gowtham, and K. U. Rao, “Critical Review of Data, Models and Performance Metrics for Wind and Solar Power Forecast,” *IEEE Access*, vol. 10. Institute of Electrical and Electronics Engineers Inc., pp. 667–688, 2022. doi: 10.1109/ACCESS.2021.3137419.
- [2] E. Lorenz, J. Hurka, G. Karampela, D. Heinemann, H. G. Beyer, and M. Schneider°, “QUALIFIED FORECAST OF ENSEMBLE POWER PRODUCTION BY SPATIALLY DISPERSED GRID-CONNECTED PV SYSTEMS.”
- [3] H. R. Glahn and D. A. Lowry, “The use of model output statistics (MOS) in objective weather forecasting,” *J. Appl. Meteorol.*, vol. 11, no. 8, pp. 1203 - 1211, Dec. 1972”.
- [4] B. Abraham and J. Ledolter, “B. Abraham and J. Ledolter, *Statistical Methods for Forecasting*, vol. 234. Hoboken, NJ, USA: Wiley, 2009.”.
- [5] T. Fang and R. Lahdelma, “Evaluation of a multiple linear regression model and SARIMA model in forecasting heat demand for district heating system,” *Appl Energy*, vol. 179, pp. 544–552, Oct. 2016, doi: 10.1016/j.apenergy.2016.06.133.
- [6] G. Notton and C. Voyant, “Forecasting of Intermittent Solar Energy Resource,” in *Advances in Renewable Energies and Power Technologies*, Elsevier, 2018, pp. 77–114. doi: 10.1016/B978-0-12-812959-3.00003-4.
- [7] † A Sfetsos and A. H. Coonick, “UNIVARIATE AND MULTIVARIATE FORECASTING OF HOURLY SOLAR RADIATION WITH ARTIFICIAL INTELLIGENCE TECHNIQUES,” 2000. [Online]. Available: www.elsevier.com/locate/solener
- [8] N. Tripathy, “International Journal of Economics and Financial Issues Forecasting Gold Price with Auto Regressive Integrated Moving Average Model,” *International Journal of Economics and Financial Issues*, vol. 7, no. 4, pp. 324–329, 2017, [Online]. Available: <http://www.econjournals.com>
- [9] R. J. Hyndman and G. Athanasopoulos, “Forecasting: Principles and Practice,” 2018.
- [10] W. M. Walsh, Z. Dong, D. Yang, T. Reindl, and A. Aberle, “High Resolution Intraday Solar Irradiance Forecasting Using Exponential Smoothing State Space Model Solar irradiance forecasting for electricity grid integration of high penetration PV View project AST/RO-submm radioastronomy at the South Pole View project Short-term Solar Irradiance Forecasting Using Exponential Smoothing State Space Model,” 2013. [Online]. Available: <https://www.researchgate.net/publication/237209521>





- [11] J.-F. Chen, W.-M. Wang, and C.-M. Huang, “Analysis of an adaptive time-series autoregressive moving-average (ARMA) model for short-term load forecasting,” 1995.
- [12] R. Nochai and T. Nochai, “ARIMA MODEL FOR FORECASTING OIL PALM PRICE.”
- [13] M. A. Shoorehdeli, M. Teshnehlab, A. K. Sedigh, and M. A. Khanesar, “Identification using ANFIS with intelligent hybrid stable learning algorithm approaches and stability analysis of training methods,” *Applied Soft Computing Journal*, vol. 9, no. 2, pp. 833–850, Mar. 2009, doi: 10.1016/j.asoc.2008.11.001.
- [14] G. J. Osório, J. C. O. Matias, and J. P. S. Catalão, “Short-term wind power forecasting using adaptive neuro-fuzzy inference system combined with evolutionary particle swarm optimization, wavelet transform and mutual information,” *Renew Energy*, vol. 75, pp. 301–307, Mar. 2015, doi: 10.1016/j.renene.2014.09.058.
- [15] P. M. Neves and D. Fonte, “Advanced forecast and scheduling of power systems with highly variable sources PhD Program in Sustainable Energy Systems,” 2015.
- [16] E. A. Feinberg and D. Genethliou, “Feinberg, E. A., & Genethliou, D. (n.d.). Load Forecasting. Applied Mathematics for Restructured Electric Power Systems, 269–285,” 2005.
- [17] G. Disciplinar De Máquinas and E. Sistemas De Armazenamento De Energia, “ÁREA DEPARTAMENTAL DE ENGENHARIA ELETROTÉCNICA ENERGIA E AUTOMAÇÃO - ‘Uma visão geral sobre o armazenamento da energia elétrica,’” 2019.
- [18] F. Rodrigo, “Dissertação 2018 Sistema Inteligente de Gestão de Armazenamento de Energia”.
- [19] Institute of Electrical and Electronics Engineers., *2012 IEEE Electrical Power and Energy Conference : took place 10-12 October 2012 in London, Canada*. IEEE, 2012.
- [20] A. Couto, “Integração de um sistema de armazenamento de energia em consumidores de baixa tensão,” 2014.
- [21] C.W. Gellings and W. M. Smith., “Integrating demand-side management into utility planning,” 1989.
- [22] Delhi Technological University, Delhi Technological University. Department of Electrical Engineering, Institute of Electrical and Electronics Engineers. Delhi Section, Institute of Electrical and Electronics Engineers. Delhi Section. PELS-IES Joint Chapter, Institute of Electrical and Electronics Engineers. Delhi Section. PES-IAS Joint Chapter, and Institute of Electrical and Electronics Engineers, *Load Shifting Technique for Reduction of Peak Generation Capacity Requirement in Smart Grid*. 2016.

- [23] S. Duryea, S. Islam, and W. Lawrance, “A battery management system for stand-alone photovoltaic energy systems,” 2001.
- [24] Á. Gomes, C. Antunes Henggeler, J. Martinho, and E. Oliveira, “Otimização multiobjetivo com algoritmos evolutivos-uma aplicação no sector elétrico,” 2012.
- [25] Alves P., “Desenvolvimento de um Sistema Ativo de Gestão de Baterias para Aplicações de Mobilidade Elétrica,” 2015.
- [26] Gaspar M., “Dimensionamento de Sistemas de Armazenamento de Energia para Melhoria da Estabilidade de Frequência em Redes Isoladas com Elevada Integração de Energias Renováveis,” 2010.
- [27] Heleno da Rua J., “Baterias de Lítio em Filme Fino: Fabrico e Caracterização de LiCoO₂ Para Utilização no Cátodo,” 2015.
- [28] X. Luo, J. Wang, M. Dooner, and J. Clarke, “Overview of current development in electrical energy storage technologies and the application potential in power system operation,” *Appl Energy*, vol. 137, pp. 511–536, 2015, doi: 10.1016/j.apenergy.2014.09.081.
- [29] V. Fernão Pires, E. Romero-Cadaval, D. Vinnikov, I. Roasto, and J. F. Martins, “Power converter interfaces for electrochemical energy storage systems - A review,” *Energy Convers Manag*, vol. 86, pp. 453–475, 2014, doi: 10.1016/j.enconman.2014.05.003.
- [30] Yuting Tian, Atri Bera, Joydeep Mitra, Babu Chalamala, and Raymond H. Byrne, *Effect of Operating Strategies on the Longevity of Lithium-ion Battery Energy Storage Systems*. 2018.
- [31] Vieira C., “Sistema de Gestão de Baterias de Iões de Li Orientado ao Modelo da Bateria,” 2013.
- [32] P. Fonte, “Introdução às redes neuronais do tipo Perceptrão Multicamada.”
- [33] Haykin S., “Neural Networks. A Comprehensive Foundation,” 1999.
- [34] V. T. Cortez, “APLICAÇÃO DE REDES NEURONAIIS ARTIFICIAIS À DETEÇÃO E ISOLAMENTO DE FALHAS EM PROCESSOS INDUSTRIAIS,” 2015.
- [35] B. Krose and P. van der Smagt, “An Introduction to Neural Networks,” 1996.
- [36] ISEL Eco-Campus, “Sustentabilidade ambiental e social - plano estratégico ISEL 2022 - 2025,” 2022. <https://www.isel.pt/o-isel-apresenta-se/sustentabilidade/ambiente/isel-eco-campus> (accessed Feb. 04, 2023).
- [37] Dehui Solar, “DH-60M Series 295-315W - Manual,” 2020. [Online]. Available: www.dehui-solar.com
- [38] PRESIDÊNCIA DO CONSELHO DE MINISTROS, “Decreto-Lei n.º 162/2019,” Oct. 2019.






- [39] Kishan Bhushan Sahay and M.M. Tripathi, “Day Ahead Hourly Load Forecast of PJM Electricity Market and ISO New England Market by Using Artificial Neural Network,” 2014.
- [40] Material da UC Sistemas Inteligentes, “Previsões com redes neuronais - Aula.” 2020.
- [41] Kishan Bhushan Sahay and M. M Tripathi, *Day Ahead Hourly Load and Price Forecast in ISO New England Market using ANN*. 2013.
- [42] C. S. Tu, W. C. Tsai, C. M. Hong, and W. M. Lin, “Short-Term Solar Power Forecasting via General Regression Neural Network with Grey Wolf Optimization,” *Energies (Basel)*, vol. 15, no. 18, Sep. 2022, doi: 10.3390/en15186624.
- [43] V. H. Wentz, J. N. Maciel, J. J. G. Ledesma, and O. H. A. Junior, “Solar Irradiance Forecasting to Short-Term PV Power: Accuracy Comparison of ANN and LSTM Models,” *Energies (Basel)*, vol. 15, no. 7, Apr. 2022, doi: 10.3390/en15072457.
- [44] X. Liu, P. Wang, and P. C. Loh, “A hybrid AC/DC microgrid and its coordination control,” *IEEE Trans Smart Grid*, vol. 2, no. 2, pp. 278–286, Jun. 2011, doi: 10.1109/TSG.2011.2116162.
- [45] SMART energysystems, “<https://www.smart-energy.ag/en/pv-storage-systems/>,” 2017.
- [46] J. Lesage, “Microgrid Energy Management System Development Using Optimization-based Methods,” 2019. [Online]. Available: <http://www.smart-energy.ag/products/ac-gekoppelte-speicherlosung-smartenergy-ac/?lang=en>

ANEXOS

ANEXO A – Previsões de consumo mensal 2021







Anexo A 1 – Consumo previsto vs real (janeiro – abril 2021)








Anexo A 2 - Consumo previsto vs real (maio – setembro 2021)

ANEXO B – Previsões de produção solar mensal 2021





Anexo B 1 – Produção solar previsto vs real (janeiro – abril 2021)

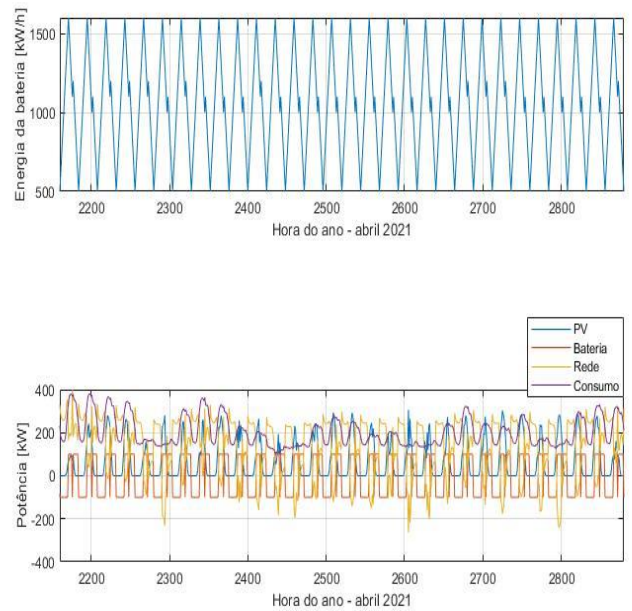
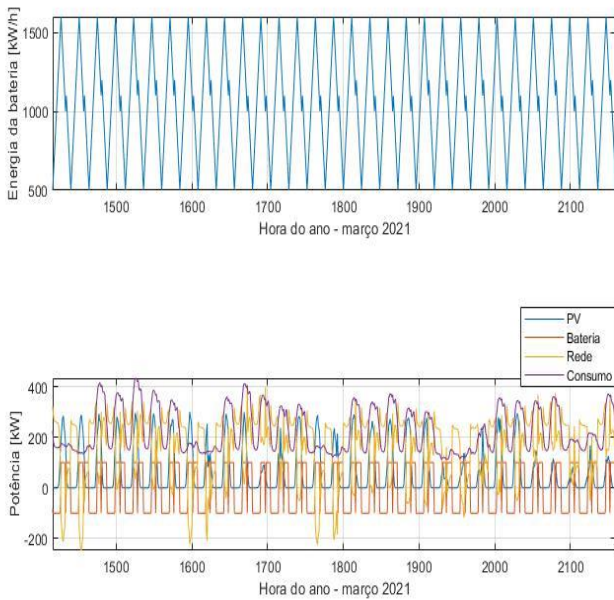


Anexo B 2 – Produção solar previsto vs real (maio – setembro 2021)





ANEXO C – Modelo de otimização SAE 2021 (capacidade 2500 kWh e conversor 100 kW)







Anexo C 1 – Modelo de otimização janeiro e fevereiro (dados previstos)



Anexo C 2 – Modelo de otimização março e abril 2021 (dados previstos)



Anexo C3 - Modelo de otimização junho e julho 2021 (dados previstos)



Anexo C 4 - Modelo de otimização agosto e setembro 2021 (dados previstos)