

Previsões num sistema Supervisory Control and Data Acquisition (SCADA) e Advanced Distribution Management System (ADMS)

FRANCISCO MIGUEL AGUIAR MARQUES
Setembro de 2023

POLITÉCNICO DO PORTO
INSTITUTO SUPERIOR DE ENGENHARIA DO PORTO

Previsões num sistema *Supervisory
Control and Data Acquisition
(SCADA)* e *Advanced Distribution
Management System (ADMS)*

Francisco Miguel Aguiar Marques

Mestrado em Engenharia Electrotécnica e de Computadores
Área de Especialização em Automação e Sistemas



DEPARTAMENTO DE ENGENHARIA ELETROTÉCNICA
Instituto Superior de Engenharia do Porto

Setembro, 2023

*Esta dissertação satisfaz, parcialmente, os requisitos que constam da Ficha de
Unidade Curricular de Tese/Dissertação, do 2º ano, do Mestrado em
Engenharia Electrotécnica e de Computadores, Área de Especialização em
Automação e Sistemas.*

Candidato: Francisco Miguel Aguiar Marques, N.º 1180820,
1180820@isep.ipp.pt

Orientação Científica: Eng.ª Teresa Alexandra Nogueira, tan@isep.ipp.pt

Empresa: EFACEC Energia, Máquinas e Equipamentos Elétricos, S.A

Orientador: Eng.ª Dora Costa Cabral, dccabral@efacec.com



DEPARTAMENTO DE ENGENHARIA ELETROTÉCNICA
Instituto Superior de Engenharia do Porto
Rua Dr. António Bernardino de Almeida, 431, 4200-072 Porto

Setembro, 2023

Esta tese é dedicada à minha família que investiu muito na minha educação.

Agradecimentos

Gostaria de agradecer a todos os Engenheiros/as e colegas que me ajudaram a concluir o meu percurso no ensino superior.

Gostaria de agradecer ao Engenheiro Custódio Dias por toda a ajuda que me forneceu na minha licenciatura. Ao Engenheiro Rui Castro que me providenciou o meu primeiro emprego na área de projetos e também à Engenheira e orientadora desta Tese, Engenheira Teresa Nogueira, que me auxiliou em todos os aspetos possíveis, de forma a que eu pudesse obter a melhor tese possível.

Queria ainda agradecer à *Efacec Power Solutions* (EFACEC) e aos seus colaboradores, por me terem dado a oportunidade de fazer o que sempre gostei e do que queria fazer como carreira profissional, um enorme obrigado a todo o apoio e ajuda que a Engenheira Dora Cabral e também orientadora desta tese me concedeu. Um especial obrigado também ao Engenheiro Manuel Silva, pelo o auxílio na Tese em questão.

Um grande obrigado a todos as pessoas que estiveram comigo desde o início, à minha família e também à minha namorada. Sempre me apoiaram em todos os níveis emocionais, mostrando que a minha maior conquista é de os ter ao meu lado.

Resumo

A rede elétrica atual possui uma enorme dificuldade em gerir a variação nas tensões existentes, resultante de vários produtores de energia renováveis independentes.

Neste âmbito foram criados ao longo dos anos vários algoritmos e técnicas de previsões de forma a ser possível obter uma previsão atempada e correta das cargas e da geração e consequentemente poder otimizar a rede elétrica para obter o seu melhor rendimento possível.

Este trabalho pretende contribuir para o estudo e análise do comportamento duma rede elétrica através da implementação do algoritmo escolhido para previsão. A previsão é dividida em várias etapas, utilizando repositórios de informação de meteorologia, informação sobre a rede elétrica e cálculo de erros, para que ocorra com os mínimos problemas.

A arquitetura geral da solução é de complexidade acrescida com integração de vários sistemas e tecnologias atuais que comunicam entre si, de forma continua a fim de, receber e transmitir os valores mais recentes.

A execução da previsão ocorreu numa zona restrita da rede elétrica existente, fazendo ajustes necessários por forma a não existir complicações com esta redução, devido a existir diferenças entre a rede atual e a rede em estudo.

Foi elaborada uma página *web* de forma, a verificar os resultados da previsão e de otimização da rede elétrica que utiliza os valores da previsão. Este estudo identificou diferenças entre as previsões com a realidade, o que levou a uma análise posterior dos resultados da previsão onde, verificou-se que os erros da previsão da potência ativa foram menores que os erros da previsão da potência reativa e a previsão da produção teve erro maior que os erros da previsão das cargas.

Palavras-Chave: Rede elétrica, Algoritmos, Previsão de Cargas, Previsão de Geração, Otimização.

Abstract

The current electrical grid has enormous difficulty in managing the variation in existing voltages, resulting from several independent renewable energy producers.

In this context, several algorithms and forecasting techniques have been created over the years in order to obtain a timely and correct forecast of loads and generation and consequently be able to optimize the electrical network to obtain its best possible performance.

This work aims to contribute to the study and analysis of the behavior of an electrical network through the implementation of the algorithm chosen for prediction. The forecast is divided into several stages, using repositories of meteorological information, information about the electrical network and error calculation, so that it occurs with minimal problems.

The general architecture of the solution is of increased complexity with the integration of several current systems and technologies that communicate with each other continuously in order to receive and transmit the most recent values.

The execution of the forecast took place in a restricted area of the existing electrical network, making necessary adjustments so as to avoid complications with this reduction, due to differences between the current network and the network under study.

A web page was created in order to verify the results of the forecast and optimization of the electrical network using the forecast values. This study identified differences between the forecasts and reality, which led to a subsequent analysis of the forecast results where it was found that the errors in the active power forecast were smaller than the errors in the reactive power forecast and the production forecast had a greater error than the load forecast errors.

Keywords: Electrical network, Algorithms, Load Forecast, Generation Forecast, Optimization.

Índice

Lista de Figuras	vii
Lista de Tabelas	ix
Lista de Acrónimos	xi
Lista de Símbolos	xv
1 Introdução	1
1.1 Contextualização	2
1.2 Definição do Problema	2
1.2.1 Objetivos	2
1.2.2 Resultados esperados	3
1.3 Plano de Trabalho	3
1.4 Organização da Dissertação	3
2 Algoritmos de Previsão	5
2.1 Previsão	5
2.1.1 Algoritmos existentes	9
2.1.2 Técnicas de previsão	21
2.2 Síntese analítica dos Algoritmos	23
3 Caracterização do caso de estudo	25
3.1 Ferramentas Utilizadas	26
3.1.1 Produto <i>Sistema SCADA/ADMS (SCATEX)</i>	26
3.1.2 Tecnologias Utilizadas	28
3.2 Rede elétrica de estudo	29
3.3 Caracterização da Rede Elétrica	35
3.4 Módulos da previsão	42
3.5 Arquitetura geral da solução	49
3.5.1 Kafka	50
3.5.2 Plataforma de Previsão	53
3.6 Criação do pólo funcional	58
3.7 Análise sumativa	59

4	Desenvolvimento gráfico e Explicação do Algoritmo de Previsão	61
4.1	Desenvolvimento gráfico	61
4.2	Algoritmo de previsão	67
4.3	Síntese analítica	74
5	Análise e interpretação de resultados	75
5.1	Análise de Resultados	75
5.2	Sumário da Análise de Resultados	79
6	Conclusão	81
6.1	Análise Conclusiva	81
6.2	Perspetivas futuras	83
	Referências	84
	Anexo A <i>Scatex</i>	89

Lista de Figuras

2.1	<i>Flowchart</i> de desenvolvimento de um modelo de previsão [6]	6
2.2	Método de classificação de modelos de previsão [8]	8
2.3	<i>Flowchart</i> do processo <i>Genetic Algorithms (GA)</i> [7]	11
2.4	Processo do algoritmo <i>Improved Empirical Mode Decomposition (IEMD)</i> [11]	12
2.5	Processo do algoritmo <i>Adaptive Neuro-Fuzzy Inference System (ANFIS)</i> [9]	16
2.6	Processo de <i>if's</i> do algoritmo <i>ANFIS</i> [9]	17
2.7	Processo de <i>Gradient Boosting (GB)</i> [24]	18
2.8	Iterações do algoritmo <i>Gradient Boosting (GB)</i> [25]	19
3.1	Mapa Geográfico da Zona Centro Litoral Portugal	30
3.2	Mapa Geográfico da Rede em Alta Tensão (AT)	31
3.3	Esquemático da Rede Elétrica em Alta Tensão (AT)	32
3.4	Mapa Geográfico da Rede em Média Tensão (MT)	32
3.5	Mapa Geográfico mais detalhado da Rede em Média Tensão (MT)	33
3.6	Subestação Injetora	33
3.7	Filtro da rede elétrica estudada	34
3.8	Filtro na subestação	34
3.9	Trânsito de Potências	35
3.10	Detalhe do Transformador	36
3.11	Produtor Independente	37
3.12	Detalhe da Instalação de Produtor em Regime Especial (PRE)	38
3.13	Detalhes de Energia de um Produtor em Regime Especial (PRE)	38
3.14	<i>Trace</i> da interligação Produtor Independente	39
3.15	<i>Trace</i> da interligação Produtor Independente para a Subestação	40
3.16	<i>Trace</i> da interligação Subestação	40
3.17	Número e Tipo de Produtores Independentes	41
3.18	Injeção de um Produtor em Regime Especial (PRE)	41
3.19	Injeção de um Produtor em Regime Especial (PRE) na Rede	42
3.20	Cobertura Espacial da Zona das Malhas	46
3.21	Arquitetura geral da solução	49
3.22	Arquitetura de integração com Plataforma de Previsão	53

3.23	Arquitetura de integração com módulos	55
3.24	Arquitetura de integração com módulos em <i>Open-source Distributed Event Streaming Platform (Kafka)</i>	56
3.25	Arquitetura de execução da plataforma de previsão	57
4.1	<i>Graphical User Interface (GUI)</i> elaborado para visualização dos resultados da previsão e da otimização	62
4.2	Página <i>web</i> com índice horário escolhido	62
4.3	Página <i>web</i> - <i>Tab Changed Equipments</i>	63
4.4	Página <i>web</i> - <i>Tab Islands</i>	63
4.5	Página <i>web</i> - <i>Tab Loads</i>	64
4.6	Página <i>web</i> - <i>Tab Generators</i>	64
4.7	Página <i>web</i> - <i>Tab Busbar</i>	65
4.8	Página <i>web</i> - <i>Tab Lines</i>	65
4.9	Página <i>web</i> - <i>Tab Transformers</i>	66
4.10	Página <i>web</i> - <i>Tab Storages</i>	66
4.11	Execução do algoritmo <i>Gradient Boosting (GB)</i> [36]	68
5.1	Resultados da previsão de carga	77
5.2	Resultados da previsão de energia renovável	78
5.3	Número de máquinas e tempo de execução (s)	79

Lista de Tabelas

2.1	Número de soluções utilizando <i>Genetic Algorithms (GA)</i> e <i>Regression Method (RM)</i> e respetivo resultado de <i>Mean Relative Error (MRE)</i> [7]	21
5.1	Resultado de Previsão de Cargas	76
5.2	Resultado de Previsão de Geração das Energias Renováveis	76
5.3	Esforço Computacional na Previsão	78

Lista de Acrónimos

ACO	<i>Ant Colony Optimization</i>
ADMS	<i>Advanced Distribution Management System</i>
ANFIS	<i>Adaptive Neuro-Fuzzy Inference System</i>
ANN	<i>Artificial Neural Network</i>
API	<i>Application Programming Interface</i>
ARIMA	<i>Auto Regressive Integrated Moving Average</i>
AT	Alta Tensão
BT	Baixa Tensão
CIRED	<i>International Conference on Electricity Distribution</i>
CRPS	<i>Continuous Ranked Probability Score</i>
DMS	<i>Distribution Management System</i>
EDP	<i>Energias de Portugal</i>
EFACEC	<i>Efacec Power Solutions</i>
EMD	<i>Empirical Mode Decomposition</i>
FOA	<i>Fruit Fly Optimization Algorithm</i>
GA	<i>Genetic Algorithms</i>
GB	<i>Gradient Boosting</i>
GPDER	<i>Grid's Predictive Management Considering Distributed Energy Resources</i>
GUI	<i>Graphical User Interface</i>
HTTP	<i>Hypertext Transfer Protocol</i>
IDE	<i>Integrated Development Environment</i>

IEMD	<i>Improved Empirical Mode Decomposition</i>
IMF	<i>Intrinsic Mode Function</i>
Kafka	<i>Open-source Distributed Event Streaming Platform</i>
KPI	<i>Key Performance Indicator</i>
MAE	<i>Mean Absolute Error</i>
MEEC	Mestrado em Engenharia Electrotécnica e Computadores
MOPF	<i>Multi-Period Optimal Power Flow</i>
MRE	<i>Mean Relative Error</i>
MT	Média Tensão
NMAE	<i>Normal Mean Absolute Error</i>
NN	<i>Neural Network</i>
NRMSE	<i>Normal Root Mean Squared Error</i>
OMS	<i>Outage Management System</i>
PRE	Produtor em Regime Especial
PT	Posto de Transformação
QR	<i>Quantile Regression</i>
RBF	<i>Radial Basis Function</i>
REST	<i>Representational State Transfer</i>
RM	<i>Regression Method</i>
RMSE	<i>Root Mean Squared Error</i>
RTU	Unidade Terminal Remota
SCADA	<i>Supervisory Control and Data Acquisition</i>
SCATEX	Sistema SCADA/ADMS
SQL Developer	<i>Integrated Development Environment with SQL and Oracle Database</i>
STLF	<i>Short-Term Load Forecasting</i>
UTC	<i>Coordinated Universal Time</i>

WA	<i>Wavelet Analysis</i>
WNN	<i>Wavelet Neural Network</i>
WRF	<i>Weather Research and Forecasting</i>

Lista de Símbolos

Símbolo	Descrição	Unidades
α	Ângulo	α
FP	Fator Potência	
I	Corrente	A
m/s	Metros por segundo	m/s
P	Potência Ativa	W
Q	Potência Reativa	VAr
S	Potência Aparente	VA
s	Unidade de Tempo	segundo
V	Tensão	V
Φ	Relação entre Potência Ativa com Potência Reativa	$\langle \alpha$

Capítulo 1

Introdução

Atualmente é possível verificar que existe uma enorme adoção de tecnologias renováveis por toda a população assim como o uso dos veículos elétricos. Isto provém de novas normas jurídicas onde novas habitações precisam de obter algum tipo de certificado de utilização de energias renováveis e também número mínimo de postos de carregamento de veículos elétricos nas garagens de edifícios habitacionais, mas também é muito comum serem motivados por consciência ambiental. Consequentemente é necessário que as redes elétricas existentes consigam acompanhar toda esta evolução, a fim desta não ficar congestionada devido à variação das tensões que estes equipamentos geradores e consumidores causam na rede elétrica.

As redes elétricas atuais foram desenhadas apenas entre cargas e produtores, idealizando um único sentido, sendo que o constante aumento de cargas geradoras perfaz com que exista um duplo sentido na rede elétrica, mostrando assim uma versatilidade e complexidade em adaptar todas estas ligações com a rede elétrica.

Com este novo funcionamento da rede surge um desafio para os algoritmos matemáticos de cálculo poderem simular o comportamento atual na rede, de modo a auxiliarem os detentores das redes elétricas a tomarem boas decisões nas operações e manutenções das mesmas.

1.1 Contextualização

O projeto em causa foi um projeto envolvente com várias empresas, financiado pelo Fundo Europeu de Desenvolvimento Regional.

A proposta presente nesta Tese está em conformidade com os parâmetros do projeto *Grid's Predictive Management Considering Distributed Energy Resources (GPDER)* que deu direito a um *paper* [1] que foi apresentado no congresso *International Conference on Electricity Distribution (CIRED)* [2] em Roma em 2023.

Uma das empresas que visa participar neste projeto é a *Efacec Power Solutions (EFACEC)* onde toda esta Tese foi elaborada.

O algoritmo escolhido e arquitetura da solução geral da previsão foi discutido com todas as empresas parceiras a fim de, escolher os que mais se adequam ao projeto envolvente.

1.2 Definição do Problema

Com o constante aumento de constrangimentos e de situações abruptas e repentinas na rede elétrica é necessário utilizar métodos que possibilitam uma rápida e eficaz previsão das cargas e da geração de energia, a fim de ser possível fazer mudanças atempadas na gestão de rede elétrica de forma a mitigar os riscos envolventes.

Além de todas estas novas e repentinas mudanças nos níveis energéticos existe cada vez mais, uma pressão sobre a qualidade de serviço imposta. Um serviço que procura um coeficiente de uso muito próximo de "1", isto é, que não existe nenhuma ou muito próximo de nenhuma paragem do serviço de distribuição elétrica.

1.2.1 Objetivos

Os principais objetivos do projeto vão de acordo com a diretiva do projeto *Grid's Predictive Management Considering Distributed Energy Resources (GPDER)* e no qual se reflete em:

- Disposição de um pólo *Supervisory Control and Data Acquisition (SCADA)*;
- Configuração da rede em termos de características elétricas para permitir execução de aplicações de energia;
- Validação do algoritmo de previsão;
- Desenvolvimento de uma plataforma *web* para visualização dos resultados da previsão e de otimização.

1.2.2 Resultados esperados

Os resultados esperados são o de estabelecer ações preditivas com base em previsões solicitadas pelo operador ou de natureza cíclica da rede elétrica, de forma a ser viável prever potenciais congestionamentos que ocorram e resolver-los o mais atempadamente possível e consequentemente:

- Conseguir reduzir as perdas na rede em Alta Tensão (AT) e Média Tensão (MT);
- Construção de uma rede elétrica personalizada, de modo a mitigar o risco em coordenações de ações de manutenções programadas;
- Obter resultados de previsão que estejam em concordância com o esperado, através do uso do algoritmo de previsão de cargas e de geração;
- Os resultados da previsão serem usados como base na otimização da rede utilizando *Multi-Period Optimal Power Flow (MOPF)*.

1.3 Plano de Trabalho

De forma a ser possível atingir o trabalho esperado no projeto foi dividido algumas tarefas, onde a responsabilidade do autor do trabalho foi:

- Configuração do pólo *SCADA*, assim como o ajuste da rede elétrica existente de forma a moldar-la para o projeto envolvente;
- Criação de uma plataforma *web* para visualização dos resultados da previsão e da otimização;
- Análise e validação da previsão.

1.4 Organização da Dissertação

Na elaboração da atual Tese de Mestrado, foi seguido uma estrutura, que no qual permitisse ao leitor perceber todas as funcionalidades e particularidades do projeto envolvente:

- Introdução, no Capítulo presente, onde é apresentado o tema da Tese Mestrado em Engenharia Electrotécnica e Computadores (MEEC) e o que levou a ser criado este projeto;
- Algoritmos de previsão, referenciado no Capítulo 2, onde é demonstrado algumas soluções algorítmicas existentes e comparações entre elas;

- Caracterização do caso de estudo, Capítulo 3 onde, representa as características da rede elétrica estudada, o sistema e as tecnologias utilizadas que auxiliaram o projeto, o processo e arquitetura da solução assim como a criação do pólo funcional;
- Desenvolvimentos, no Capítulo 4, que apresenta a explicação da página *web* desenvolvida e do algoritmo de previsão;
- Análise e interpretação de resultados, referenciado no Capítulo 5, onde é discutido os resultados de todo este trabalho de previsão;
- Por fim, é elaborada uma Conclusão no Capítulo 6, de forma a concluir o trabalho referente à previsão de cargas e de geração de energia elétrica e também perspectivas futuras do projeto *Grid's Predictive Management Considering Distributed Energy Resources (GPDER)*.

Capítulo 2

Algoritmos de Previsão

No estado da arte será abordado vários algoritmos de previsão e técnicas de previsão existentes no amplo mercado energético.

A previsão de cargas e de geração assim como as técnicas de previsão são fulcrais para o funcionamento dos sistemas de energia. Os produtores conseguem desta forma obter uma melhor gestão dos equipamentos de potência reduzindo assim o custo de operação levando a um aumento dos lucros.

Os escolhidos e falados nesta Tese foram abordados pelo o projeto Grid's Predictive Management Considering Distributed Energy Resources (GPDER) e os que são mais usados nas áreas dos sistemas de energia, assim como os que têm mais suporte teórico a nível de paper científico, de forma a ser perpetuamente exemplificados com casos de estudo.

2.1 Previsão

O estudo de previsão de cargas e de geração é um estudo que leva à implementação de cada vez mais métodos, de forma a ser possível obter uma previsão cada mais realista e rápida acerca das mudanças existentes no mundo atual. Conseguindo fazer uma boa previsão, as decisões económicas são mais viáveis e tendem a ser mais realistas de maneira a minimizar o custo de operação para as empresas de energia. Ao providenciar uma maior vida útil aos equipamentos de potência estes não necessitam de produzir em excesso que se traduz numa diminuição das perdas, o que pode levar a mais lucros [3].

O resultado da previsão com baixo nível de *Mean Relative Error (MRE)* significa que obteve uma pequena diferença com o seu valor real, o que mostra que se fez uma boa previsão mas, devido ao comportamento das redes elétricas não serem lineares e esporádicas a sua previsão é difícil [3].

Com o aumento de *smart grids* (redes inteligentes) o esforço de controlo e otimização da rede tende a acompanhar este aumento [4].

Entre os vários fatores existentes para que ocorra um estudo de previsão, estas são algumas das mais importantes [5]:

- **Estratégico** - De forma a ser possível fazer melhores decisões para os dias seguintes;
- **Financeiros** - Obter uma melhor gestão dos custos envolventes;
- **Marketing** - Conseguir fazer alterações no preço ou até ser possível lançar novos produtos e/ou serviços;
- **Produção e Operação** - Gestão dos equipamentos de potência e da rede elétrica para minimização de perdas.

De maneira a executar o melhor modelo de previsão, é necessário verificar as várias etapas, descritas na Figura 2.1.




Figura 2.1: *Flowchart* de desenvolvimento de um modelo de previsão [6]

Na Figura 2.1 pode-se verificar as várias fases no desenvolvimento de um modelo de previsão, sendo que é iniciado este processo com a recolha dos dados históricos das cargas/produções, isto é, verifica-se o que já aconteceu de forma a ser possível prever o que pode acontecer no futuro.

São preparados os dados das cargas/produções assim como a recolha dos dados históricos de meteorologia e de eventos que possam ter acontecido (feriados ou festas populares).

Depois de uma análise posterior de toda esta informação recolhida é preparado os *inputs* (entradas) com a respetiva verificação da integridade dos dados que irão ser introduzidas no modelo.

Na etapa seguinte é possível existir uma bifurcação na escolha do caminho. A seleção do modelo pode recair para duas opções: selecionar o melhor modelo de implementação para o caso, com base em casos de estudo anteriores ou seleção de um modelo novo.

Depois de escolhido o modelo e executar-lo poderá ser necessário fazer pequenas melhorias devido a novos *inputs* ou até mudanças no paradigma do modelo, de forma a que se aproxime o mais próximo da realidade e que seja eficaz a sua previsão.

Para o desenvolvimento de um modelo de previsão é preciso ter atenção a alguns aspetos sobre os quais, os seguintes são requeridos com mais atenção [6]:

- **Fator tempo** - As subestações referenciam o dia da semana, mês e ano onde foi monitorizado os valores das cargas/produções. Tal implicação afirma que é necessário contabilizar os dados de dias anteriores, de forma a obter uma maior precisão de deteção. Os eventos calendarizados são também um fator de extrema importância pois, poderá implicar uma mudança no padrão quer de consumo quer de produção e por isso, uma monitorização calendarizada é necessária para não existir alterações significativas;
- **Fator meteorologia** - Este fator pode muitas vezes ter o maior impacto na previsão, pois consoante o clima a que os utilizadores da rede elétrica são sujeitos, o consumo de energia elétrica poderá aumentar de forma a poder satisfazer a população, como por exemplo, aquecimento de casas no inverno, assim como arrefecimento das casas no verão. A relação existente no fator de meteorologia também acontece no campo de produção de energia, como exemplo o caso da energia eólica pois se a meteorologia não possuir informação atempada e correta acerca da previsão de vento, este poderá ter impacto na previsão da geração. Esta terá de ser produzida por outros métodos de forma a ser compensado ou até não ter sido prevista produção de energia eólica e tiver existido uma mudança repentina no âmbito de meteorologia, e por isso existir um excesso de energia que não estava previsto e mudar por completo o paradigma do conceito seguinte;

- **Fator económicos** - Este aspeto tem muitos conceitos que são geolocalizados onde, mudam significativamente de região para região. O preço e a industrialização presente na área são tópicos que alteram o consumo e a geração. Como referenciado no ponto anterior, quando existe um excedente ou um défice da produção de energia elétrica é necessário fazer regulações nos dados económicos previstos pois, poderá ser necessário ter de existir exportação o que leva a ser algo positivo mas poderá não ser muito vantajoso se for uma exportação simples e de custo reduzido da energia acumulada ou ter de fazer importações o que leva a um acréscimo nas despesas mas poderá ser mais vantajoso porque, países vizinhos poderão vender a energia elétrica com um valor mais reduzido quando comparada com o custo de produção no país atual.

Na previsão é utilizada maioritariamente o método *Regression Method (RM)*, que por sua vez possui amplas suposições mas resulta numa única solução. Um outro método é a utilização de *Genetic Algorithms (GA)* que possibilita a previsão de múltiplas soluções [7].

Uma das metodologias que é utilizada é a separação de previsão em três conjuntos, conforme é possível verificar na Figura 2.2.




Figura 2.2: Método de classificação de modelos de previsão [8]

Como se pode comprovar esta metodologia subdivide-se em três partes:

Game Theory models, *Time Series Models* e *Simulation Models*.

- ***Game Theory Models*** - Um dos seus objetivos é ser possível conseguir modelar o mercado de forma a alcançar soluções ótimas. O nome *Game Theory* é devido às empresas de fornecimento de energia elétrica tenderem a encontrar a melhor forma de conseguirem maximizar o lucro, manipulando assim a sua oferta em prol dos custos que possuem [8];

- ***Time Series Models*** - Um método que necessita de dados históricos, de forma a ser possível analisar variáveis. Muitos dos algoritmos falados na Tese presente têm a sua ideologia fortemente evidenciada neste ponto, assim como é o caso de *Auto Regressive Integrated Moving Average* (ARIMA), *Regression Method* (RM), *Artificial Neural Network* (ANN), entre outros [8].

O tópico é dividido em três partes e dependendo do tipo de situação de previsão, uma parte é preferível às outras:

- *Parsimonious Stochastic Models* - Um dos métodos que utiliza este tipo de ideologia é o *Auto Regressive Integrated Moving Average* (ARIMA) onde, são utilizados processos estacionários e não estacionários [8],
 - *Artificial Intelligence based models* - É utilizado devido à sua fácil compreensão de problemas complexos e de relações não lineares, podendo ser dividido em dois sub-conjuntos, conforme o que seja mais indicado na situação de previsão [8]:
 - * *Neural Network Based Models* - Utiliza *Artificial Neural Network* (ANN) onde, estrutura a série temporal independentemente se o que o regula seja de natureza complexa;
 - * *Data-Mining Models* - Relaciona-se com os métodos de *Genetic Algorithms* (GA).
 - *Regression or Causal Models* - Relaciona-se com relações teóricas entre as variáveis dependentes, como o preço da eletricidade, com as variáveis independentes onde estas podem ser estimadas [8].
- ***Simulation models*** - De forma a ser possível delinear uma solução ótima são feitos modelos a partir da rede elétrica existente, de maneira a ser possível fazer simulações o mais próximo da realidade [8].

2.1.1 Algoritmos existentes

Vários dos algoritmos falados neste subcapítulo precisam de treinamento e de *inputs* que são dependentes do fator humano, o que pode levar a alguns resultados insatisfatórios de previsão tendo em conta que a informação proveniente do operador poderá estar incompleta ou insuficiente [9].

Não existe evidência que um modelo de algoritmo consiga ter melhor eficiência e eficácia que outro constantemente, querendo dizer que não existe um único algoritmo que resolva todos os problemas, mas sim vários algoritmos que resolvem problemas diferentes [8].

- ***Regression Method (RM)***

É um modelo preditivo que possui a capacidade de analisar relações entre os valores reais e as suas variáveis, dentro de um conjunto de informações. Existem vários tipos de *RM*, sendo que vai desde um número pequeno de variáveis até grandes quantidades de variáveis, consoante a complexidade do problema [10].

O caso de uso deste algoritmo foi a previsão para os dias de feriado, utilizando dados históricos que tenham uma aproximação similar, com mesmo formato de feriados de à três anos passados, e obteve-se uma taxa de erro *Mean Relative Error (MRE)* de cerca de 3,57 % [3].

É um algoritmo onde é limitado a várias restrições e fornece apenas uma solução ótima que precisa de bastante tempo para ser calculada e não existe forma de verificar se é uma solução global [7].

- ***Genetic Algorithms (GA)***

Ao contrário do algoritmo falado anteriormente, este consegue se diferenciar através de providenciar múltiplas soluções ótimas. Pode ser também utilizado como uma ferramenta de teste de redes neuronais, de forma a ser possível otimizar as mesmas [7].

O *Flowchart* da Figura 2.3 providencia o processo de *Genetic Algorithms (GA)*, com a sua explicação.




Figura 2.3: *Flowchart* do processo *Genetic Algorithms (GA)* [7]

- 1 - É inicializado com uma população inicial de estudo aleatório;
- 2 - Utiliza-se esforço computacional de forma a completar o objetivo proposto;
- 3 - É selecionada a próxima geração da população resultante;
- 4 - Existe a reprodução, sendo que pode ser entre gerações ou acontecer mutações;
- 5 - De igual modo ao segundo ponto, é utilizado esforço computacional de forma a completar o objetivo proposto com esta nova população;
- 6 - É refletido se foi completado o objetivo proposto. O objetivo só se encontra atingido quando o erro do esforço computacional dos pontos 2 e 5 obterem um *MRE* menor que 5% entre os dois resultados;
- 7 - Caso o passo 6 conclua que não foi atingido o objetivo, é procedido a uma reversão, indo para o ponto 2, mas com a geração existente. Caso o

passo 6 conclua que foi atingido o objetivo, reflete que foi encontrado os melhores parâmetros.

- **Improved Empirical Mode Decomposition (IEMD)**

O processo de *Empirical Mode Decomposition (EMD)* é a decomposição de sinais não estacionários. Estes componentes decompostos têm propriedades denominadas de *Intrinsic Mode Function (IMF)*. Diferentes frequências de *IMF* possibilitam variâncias no tamanho da filtragem mediana. Quando comparado com o algoritmo de *Empirical Mode Decomposition (EMD)* o algoritmo *Improved Empirical Mode Decomposition (IEMD)* consegue atenuar o efeito de ruído proporcionado pelo o impulso estudado [11].

Na Figura 2.4 é possível verificar os passos que todo o algoritmo *Improved Empirical Mode Decomposition (IEMD)* percorre:




Figura 2.4: Processo do algoritmo *Improved Empirical Mode Decomposition (IEMD)* [11]

- 1 - É aplicado ao sinal original $x(t)$ o algoritmo *Empirical Mode Decomposition (EMD)*, de forma a conseguir obter a componente *Intrinsic Mode Function (IMF)*. Na função $c_k(t)$ o valor de k é o número total de componentes extraídas;

- 2 - É utilizada uma filtragem mediana, que só é possibilitada através do uso das componentes *IMF*. Na função $d_k(t)$ o valor de k é o número total de *IMF* após a filtragem;
- 3 - As várias agregações dos componentes de filtragem *IMF* origina um novo sinal filtrado $y(t)$;
- 4 - Utiliza-se posteriormente o algoritmo *EMD* nos sinais *IMF* extraídos do sinal filtrado $y(t)$. Para obter sinais melhorados de *IMF* onde, na função $e_m(t)$ a variável m é o número destes componentes e onde o tamanho da janela de filtragem é diretamente proporcional ao número de *IMF*.

Como é verificado na Figura 2.4, um dos últimos passos do processo é a filtragem dos sinais melhorados de *IMF* e não do sinal de entrada. O nome *Improved Empirical Mode Decomposition (IEMD)* deriva deste propósito de fazer filtragem somente nos sinais melhorados de *IMF*, de forma a ser possível atenuar o efeito de ruído do sinal de entrada.

- ***Auto Regressive Integrated Moving Average (ARIMA)***

Auto Regressive Integrated Moving Average (ARIMA) é algoritmo que possui algumas particularidades, como poucas premissas e de ser de natureza muito flexível [12].

Uma das principais desvantagens do uso deste modelo é a dificuldade de obtenção de um padrão não linear resultante do uso deste algoritmo, devido a este ser um modelo com uma estrutura linear por natureza. Nem todos os problemas resultantes do mundo real são de padrão linear como é o caso da meteorologia, o que dificulta a utilização deste método sozinho por isso, como é referido no Subcapítulo 2.1.2, é utilizado em conjunto com outros algoritmos [13, 14].

- **Wavelet Neural Network (WNN)**

É uma rede que surge da combinação de duas redes neuronais: *Wavelet Analysis* (WA) e *Neural Network* (NN) [15]:

- **Wavelet Analysis (WA)**

A WA é utilizado em múltiplas aplicações, desde a processamento e compressão de sinal/imagem a decomposição em tempo real. A desvantagem de tal ferramenta é a limitação do número de *inputs* pois, o esforço computacional e consequentemente o seu custo irão ser diretamente proporcionais ao número da dimensão do vetor de entrada [15].

- **Neural Network (NN)**

A NN possibilita aproximações não lineares, com pouco conhecimento e premissas sobre o processo da mesma. A desvantagem de tal uso é o vetor de variáveis de entrada serem de natureza aleatória, podendo ser melhoradas com treino excessivo. Uma das desvantagens é o tempo de treino necessário de forma a ser eficiente [15].

É um modelo preditivo de *machine learning* onde o resultado do conjunto usado deste modelo deriva dos dados providenciados para o treino da rede neuronal [16].

Wavelet Neural Network (WNN) foi proposto como alternativa, conseguindo reduzir a sua desvantagem, devido às *wavelets* (ondas) terem possibilidade de fazer compressões altas e poderem utilizar um pequeno número de coeficientes, conseguindo assim aproximar o vetor de variáveis de entrada inicial ao seu mínimo global e reduzir o seu tempo de treino necessário para obter aproximações com bastante precisão [17, 15].

Devido a problemas estruturais não permite otimizar todo o núcleo de um problema complexo [17].

- ***Fruit Fly Optimization Algorithm (FOA)***

O algoritmo presente foi elaborado de forma a fazer uma simulação do que acontece na vida animal, isto é, simula o comportamento de forrageamento na procura de alimento [18] pelas moscas de vinagre/fruta, é utilizado de forma a ser possível otimizar problemas de carácter financeiro ou energético, podendo até ser usado em problemas de inventário e de calendarização com a utilização conjunta com *Artificial Neural Network (ANN)*. O consumo de energia elétrica é influenciado por vários fatores externos, que impactam a resolução da previsão, por esse motivo, a otimização do algoritmo *Fruit Fly Optimization Algorithm (FOA)* foi pensada como um modelo de colmeia inteligente onde, possui complexidade baixa, rápido fator computacional e obtenção de resultados mais abrangentes [19, 20].

As etapas deste algoritmo, que por sua vez consegue obter melhores resultados que *Ant Colony Optimization (ACO)* ou outros algoritmos inteligentes que derivam de ideia de colmeias, são [21]:

- 1 - Necessário introduzir os parâmetros iniciais: Número máximo de gerações, tamanho da população estudada e o centro de localização;
- 2 - Inicia-se como irá proceder, utilizando uma direção de origem aleatória para cada *mosca de fruta* de forma a ser possível demonstrar o comportamento de forrageamento;
- 3 - Calcula-se a concentração do *cheiro* captado pela *mosca de fruta* estimando a sua localização atual com a localização de origem, e posteriormente estes dados são computacionais;
- 4 - É procurado o *cheiro* com o melhor resultado, e com essa informação é encontrada a *mosca de fruta* que originou essa conclusão e desloca-se a colmeia para a localização dessa *mosca de fruta*;
- 5 - Verifica-se se a condição para terminar está satisfeita, isto é, se existir uma melhor *fonte de alimentação* nesta nova posição. Contrariamente se esta condição não for satisfeita, repete-se do passo 2 ao 5.

É um algoritmo onde não é muito comum ser utilizado em otimização de problemas de grandes dimensões [20].

• ***Adaptive Neuro-Fuzzy Inference System (ANFIS)***

Um método difuso permite abranger várias áreas, desde económicas até às sociais onde, um dos grandes propósitos é o de solução de problemas que são incertos ou até mesmo vagos [22].

É um sistema de interferência difusa que consegue incorporar auto aprendizagem de *Artificial Neural Network (ANN)* mas com as características de um método difuso [9].

O uso do algoritmo *ANFIS* é o de poder ajustar os valores da previsão com a informação obtidas pela rede *Radial Basis Function (RBF)*, com esta integração foi possível melhorar a precisão da rede *RBF* [9], com representação gráfica presente na Figura 2.5:




Figura 2.5: Processo do algoritmo *ANFIS* [9]

- 1 - Inserção de variáveis de entrada;
- 2 - Utilização de redes neuronais de forma a proporcionarem o valor de previsão que, irá ser posteriormente juntada como uma entrada de variável com algoritmo *ANFIS*;
- 3 - O algoritmo *ANFIS* é responsável por um sistema de ajuste da previsão, conseguindo assim melhorar a precisão da previsão da rede neuronal.

Os valores de entrada do algoritmo *ANFIS* são divididos em cinco grupos: Muito Baixo, Baixo, Médio, Alto e Muito Alto e os valores das saídas são a mudança da previsão de carga que por sua vez, são divididos também em cinco grupos: Muito Baixo, Baixo, Inalterados, Alto e Muito Alto, onde possuem uma regra, que o número total de iterações difusas que possa existir é de 25 [9].

De forma a ser possível verificar o caminho que o algoritmo percorre, isto é, as séries de *if's*, *and* e *then* que perfaz, averigua-se a Figura 2.6.




Figura 2.6: Processo de *if's* do algoritmo *ANFIS* [9]

Apura-se na figura anterior os vários caminhos que a utilização deste algoritmo possa originar. Um exemplo será: Se (*if*) a variável x_1 que é a previsão for do tipo Normal e (*and*) variação do preço da eletricidade for a variável x_2 então (*then*) o ajustamento de previsão é Baixo [9].

Um dos seus pontos fortes é a de simulações não lineares [5].

- **Gradient Boosting (GB)**

Gradient Boosting (GB) é um dos vários modelos de *machine learning* existentes que consegue através de múltiplas combinações entre dois modelos, minimizar o *Mean Relative Error (MRE)* [23].

O processo deste tipo de algoritmo baseia-se em agregação de modelos, isto é, inicia-se o processo com um modelo inicial com a informação, tendo em paralelo um segundo modelo mais pequeno e mais simples (denominado como *weak learners*), a combinação destes dois modelos, melhora a eficácia do resultado final. É um processo de *boosting* pois, é repetido múltiplas vezes, sendo que cada vez que é repetida, o erro das agregações dos modelos anteriores fica cada vez menor [23, 24, 25].

O algoritmo utiliza combinações de *weak learners*, que são modelos mais pequenos para treinar-los, existem múltiplas iterações entre os *weak learners* e o modelo geral. A combinação destes dois modelos origina um novo modelo, que por sua vez irá gerar novos *weak learners* e assim por diante até conseguir obter o seu critério de paragem ou não conseguir gerar mais *weak learners*. Este modelo permite múltiplas tentativas de forma a minimizar o erro, ao fazer múltiplas iterações [25].

É possível verificar, uma representação de como este algoritmo funciona, na Figura 2.7.




Figura 2.7: Processo de *Gradient Boosting (GB)* [24]

Um das estratégias utilizadas com este tipo de previsão, e que está presente na figura anterior é, o de separar a informação em dois modelos, como mencionado, nos parágrafos anteriores, e posteriormente o algoritmo associa as variáveis existentes destes dois modelos [26].

Uma explicação mais pormenorizada do método de *boosting* é referido a seguir:

- Existe duas divisões do modelo de estudo, as imagens com fundo amarelo e as imagens que obtêm os *classifiers*,
- As imagens com o fundo amarelo são o modelo com a informação e os *classifiers* que são um modelo mais restrito do modelo inicial e têm o nome de *weak learners*;
- A imagem com fundo amarelo é agregado com as imagens dos *classifier-1* e que irá originar um novo modelo (uma nova imagem com fundo amarelo) e este irá produzir um novo modelo de *weak learner* que é o *classifier-2* e irão se agregar produzindo um novo modelo e um novo *weak learner* e assim por diante, conseguindo reduzir o erros de agregações através de sucessivas agregações.

As iterações têm por sua base observar as diferenças entre os seus valores e os valores da previsão gerada e aplica otimizações nos parâmetros e "*aprende*" com os erros feitos nas iterações anteriores. Este processo é percorrido até todos os pontos de treino terem sido executados ou até ao seu número máximo de estimações, na Figura 2.8 é possível verificar que a cada aumento no número de iterações o seu valor erro decresce mas em contrapartida o esforço computacional aumenta [25].




Figura 2.8: Iterações do algoritmo *Gradient Boosting (GB)* [25]

Uma das grandes desvantagens do uso deste método é o da dificuldade computacional se a informação dos modelos for de enorme dimensão, podendo não ser eficiente em questão de tempo e também ter de ser possível existir vários sobre ajustes, caso exista uma grande ramificação nos modelos [24].

- ***Quantile Regression (QR)***

É um método que é utilizado em diversos âmbitos de diferentes naturezas, como por exemplo, âmbito de energia, medicina ou até económica. A sua ideologia assenta em regressões medianas que são suportadas na estimação de *quantil* das variáveis dependentes que são condicionadas nas variáveis de *input* [27].

Um dos casos de uso deste método é o a junção da volatilidades e incertezas da produção de energia como é o caso da geração eólica [28].

- **Comparação de Algoritmos**

Irá ser abordado breves comparações entre alguns dos algoritmos com usos de casos de estudo, de forma a ser possível ao leitor obter uma melhor percepção.

- *Regression Method (RM) vs Auto Regressive Integrated Moving Average (ARIMA)*

Para comparar estes dois algoritmos foi utilizado como exemplo, o consumo de energia elétrica na Província Oriental da Arábia Saudita. Neste estudo, foi concluído que *Regression Method (RM)* consegue obter melhores resultados que *Auto Regressive Integrated Moving Average (ARIMA)* pois, *RM* consegue suportar mudanças sazonais e quebras estruturais que possam ocorrer [29].

- *Regression Method (RM) vs Genetic Algorithms (GA)*

Uma das principais diferenças é o número de soluções ótimas que os algoritmos providenciam. *Regression Method (RM)* só consegue providenciar uma solução ótima, enquanto que *Genetic Algorithms (GA)* providencia múltiplas soluções ótimas onde, estas soluções dotam de melhores resultados em casos de não linearidade e de equações complexas. O método *RM* assume restrições de linearidade, normalidade e de variações de constantes onde, os *GA* não precisam. O caso de uso onde estes dois algoritmos foram colocados em prova foi no rio de *Mississippi* em *St. Louis* onde era verificado os dados de carga e de descarga de sedimentos deste rio, e foi concluído que o método de *Genetic Algorithms (GA)* consegue ter uma melhor performance, em termos de *MRE*, do que o algoritmo *Regression Method (RM)* [7].

Na tabela 2.1, é possível verificar que existem várias soluções ótimas providenciadas por *GA* e apenas uma devido ao *RM*, é também possível notar que *MRE* é menor nas iterações com o uso de *GA*.

Tabela 2.1: Número de soluções utilizando *GA* e *RM* e respetivo resultado de *MRE* [7]

<i>Coefficientes Genéticos</i>	<i>MRE</i>
GA - 1	37
GA - 2	38
GA - 3	33
GA - 4	36
GA - 5	36
GA - 6	37
GA - 7	35
GA - 8	34
GA - 9	34
GA - 10	34
RM	36

Conclui-se com este caso de uso que *Genetic Algorithms (GA)* consegue demonstrar uma solução mais apropriada para o problema de otimização mais rapidamente devido aos cálculos do algoritmo *Regression Method (RM)* precisarem de mais tempo para serem executados e não existir nenhum mecanismo de controlo, de forma a ser possível afirmar que foi encontrada a melhor solução ótima [7].

2.1.2 Técnicas de previsão

– *Artificial Neural Network (ANN)*

Com o avanço da tecnologia computacional, surge cada vez mais motivação de resolver os vários problemas existentes com recurso a *ANN* [30].

No processo de previsão do preço em tempo real, foi desenvolvido várias *ANN* para *Short-Term Load Forecasting (STLF)*. São processos que melhoram bastante a precisão de previsão quando comparados com métodos em série convencionais e de regressão (em termos de aproximações não lineares) mas, é preciso bastante informação de forma a ser treinada, o que leva a ser um processo bastante demorado [9].

– **KNITRO**

É um *solver* que possibilita otimizar problemas não lineares em sistemas de grande escala, utilizando aproximações de *interior-point* e de *active-set* ou até a junção destas duas. Tem a particularidade de ser possível utilizar vários algoritmos de forma a resolver o problema proposto. Uma das grandes dificuldades reportadas na elaboração do *solver* foi, a da eficácia na integração de ferramentas que possibilitam a junção de algoritmos de *interior-point* e de *active-set* no mesmo pacote [31].

Um caso de estudo onde este *solver* foi utilizado, está relacionado com otimizações em tempo real de forma a encontrar soluções cinemáticas ideais de maneira a ser possível por exemplo: Replicar a ação de escalada semelhante à lagarta, para que se consiga implementar em robôs sofisticados de forma a reduzir o perigoso trabalho para os seres humanos [32].

– **Modelo Híbrido**

Fatores naturais como sociais, mostram impacto nas previsões de curto prazo (*Short-Term Load Forecasting (STLF)*) e por isso, foi criado um modelo híbrido de forma a aumentar a precisão. Este modelo tem por base os seguintes algoritmos [21]:

- * *Improved Empirical Mode Decomposition (IEMD)*,
- * *Auto Regressive Integrated Moving Average (ARIMA)*,
- * *Wavelet Neural Network (WNN)* otimizado por *Fruit Fly Optimization Algorithm (FOA)*.

Devido, a ser um modelo que agrega bastantes algoritmos onde cada algoritmo possui um resultado específico, a conclusão será que o resultado final será fruto dos resultados individuais de cada algoritmo [21]:

- O algoritmo *Improved Empirical Mode Decomposition (IEMD)* permite extrair com maior precisão a componente linear da previsão de carga,
- O modelo *Auto Regressive Integrated Moving Average (ARIMA)* consegue ajustar à componente extraída pelo o algoritmo utilizado anteriormente,
- O algoritmo *Wavelet Neural Network (WNN)*, otimizado por *Fruit Fly Optimization Algorithm (FOA)*, preenche a componente linear extraída com a componente não linear em falta.

2.2 Síntese analítica dos Algoritmos

Neste capítulo foi referido os vários tipos de algoritmos existentes no mundo complexo de previsões, assim como algumas comparações entre eles.

É possível verificar que não existe um algoritmo ou técnica de previsão que se sobrepõe aos outros, mas sim algoritmos ou técnicas de previsão que poderão se adequar melhor às particularidades dos problemas existentes melhores que outros.

É possível que muitos algoritmos se estejam a desenvolver à medida que esta Tese é escrita.

Capítulo 3

Caracterização do caso de estudo

Neste capítulo irá ser demonstrado algumas das ferramentas e produtos necessários, assim como algumas particularidades que o projeto Grid's Predictive Management Considering Distributed Energy Resources (GPDER) consegue fornecer. Serão também apresentadas breves características sobre o que é o produto Sistema SCADA/ADMS (SCATEX) e algumas tecnologias utilizadas, sendo que foram adquiridos conhecimentos com estas novas tecnologias.

Na caracterização da rede elétrica de estudo irá ser referido que sistemas foram usados, nas mudanças que foram feitas e em especificidades existentes para ser uma rede que possa ser usada no projeto.

Vai ser sintetizado a teoria de todo o processo da previsão e referido a sua arquitetura geral da solução encontrada e executada no projeto.

Verificação dos componentes a usar para ser possível obter um pólo funcional.

3.1 Ferramentas Utilizadas

Para o projeto presente foi necessário recorrer a ferramentas específicas e também aos produtos que a *Efacec Power Solutions (EFACEC)* comercializa.

3.1.1 Produto *SCATEX*

O produto *SCATEX*, é um produto *EFACEC*, onde é o resultado de cerca de 30 anos de experiência em automação de rede.

Este produto foi pensado de forma a combinar o produto *SCADA*, *Distribution Management System (DMS)* e *Outage Management System (OMS)*, numa única plataforma. Pode ainda ser um produto modular, isto é, poder só executar uma única *SCADA*, uma única *DMS*, uma única *OMS* ou então, uma *Advanced Distribution Management System (ADMS)* de forma a conjugar estes todos produtos.

A estrutura *SCATEX* foi elaborada com toda a segurança informática em mente, podendo assim, transmitir confiança aos utilizadores.

É um produto versátil a nível de escala de clientes, isto é, consegue demonstrar flexibilidade, expansibilidade e performance quer para grandes níveis de redes assim como pequenos níveis de rede, desse modo consegue-se adaptar às necessidades que cada cliente possui.

É possível verificar todas as funcionalidades deste sistema no anexo A.

- ***Supervisory Control and Data Acquisition (SCADA)***

O produto *SCADA* é um produto flexível pois, consegue operar em diferentes redes. Opera em redes elétricas, redes de petróleo, redes de gás e redes de água, fazendo assim a gestão de múltiplas infraestruturas.

É uma plataforma que possui monitorização e sistema de alertas para os utilizadores 24/7, isto é, a estrutura *SCADA* demonstra confiança para usuários caso aconteça alguma anormalidade.

As funções principais do produto *SCADA* são monitorizar em tempo real as medidas e o estado da rede, processando mudanças e gerando alarmes para situações anómalas, operar/controlar a rede (envio de comandos de abertura ou de fecho de equipamentos) e tudo isto devido a receber comunicações através *Unidade Terminal Remota (RTU)*.

- ***Distribution Management System (DMS)***

A *DMS* é um produto que providência execuções de aplicações de energia e caracterizações da rede elétrica, isto é, informações dos equipamentos que compõem, conseguindo assim fazer um desenho geral da rede.

Algumas funções que uma *DMS* permite são, topologia da rede, fluxos de potência, estimador de estados, análises de curto circuitos, configurações de redes e coloração da rede em tempo real de acordo com a informação proveniente do *SCADA*.

- ***Outage Management System (OMS)***

A *OMS* tem o seu núcleo na resolução dos *outages* que possam ocorrer na rede através das informações que podem prover do sistema *SCADA* e/ou por reclamação dos clientes.

Com a integração de *OMS* é possível obter uma gestão dos incidentes ativos, assim como o planeamento das equipas de resolução com a inclusão de *dashboards* para fácil percepção.

- ***Advanced Distribution Management System (ADMS)***

Um dos principais focos de uma *ADMS* é integração, isto é, ser possível ser flexível ao adotar funções modulares. É também um sistema aberto a terceiros, isto é, aceita conexões de outros sistemas *standard* e permite obter acesso *web*.

Consegue ser um agregado dos sistemas falados anteriormente, com isto significa, ter em sua presença um sistema *SCADA*, *DMS* e *OMS*. Obtém uma gestão de energia mais pormenorizado de localização de defeitos, ações previstas na rede e integrações de micro-redes, conseguindo assistir o operador nas tomadas de decisão.

É também possível verificar a topologia da rede com o auxílio de coloração, permitindo comprovar se a rede está energizada e como está as suas ligações (qual o seu ponto injetor, qual a saída da subestação, entre outros) mostrando uma enorme vantagem para a gestão da rede.

Possibilidade de obter um ambiente de estudo, a fim de treinar os operadores para vários cenários que possam ocorrer. Criação de *dashboards* em tempo real, assim como, o seu histórico.

Uma *ADMS* possibilita a combinação da informação proveniente do *SCADA* com informação da rede e módulos de cálculo de uma *DMS* e gestão de incidentes e da rede em Baixa Tensão (BT) de uma *OMS* conseguindo com isso, a obtenção de arquivos em tempo real, esquemáticos automáticos da rede, possibilidade de fazer *traces* e também colorações das redes de transporte, integrações de geográficos de forma a ser possível uma melhor visualização dos conteúdos e mesmo com a adição de todos estes componentes mantém uma boa performance quando comparado com um sistema simples, fazendo com isto um sistema completo e mais avançado ao agregar todos estes sistemas singulares.

3.1.2 Tecnologias Utilizadas

Ao longo da Tese presente foram necessárias tecnológicas de ambiente informático, de forma a conseguir fazer comunicação com a telemetria providenciada pelas *RTU*, fazer gestão da informação da rede elétrica e desenvolvimento do ambiente *web*. As ferramentas são utilizadas no dia a dia empresarial da *EFACEC*, o que possibilitou uma abordagem mais realista de como era feito o desenvolvimento na empresa:

- ***Integrated Development Environment with SQL and Oracle Database (SQL Developer)*** - Foi operado para ser possível verificar as características da rede elétrica (topologia) que foram guardadas em base de dados assim como os valores da telemetria;
- ***DB Beaver*** - Recorreu-se para ser possível alojar os valores provenientes da previsão conseguindo assim, validar os mesmos;
- ***Eclipse*** - Utilizou-se este *Integrated Development Environment (IDE)*, para desenvolvimento de uma página *web* de forma exibir os resultados da previsão e da otimização da rede elétrica;
- ***Kafka*** - Empregue de forma a existir comunicação entre *SCADA* e módulo de gestão da previsão, para receber os valores oriundos da telemetria, entre outros.

3.2 Rede elétrica de estudo

No início do projeto foi discutido com as empresas parceiras sobre o estado da rede elétrica. Após ter sido chegado a uma conclusão foi procedido à restrição da rede elétrica já existente da *E-Redes* moldando o estado da rede elétrica para o estado acordado previamente, utilizando o sistema *SCATEX*.

Foi aplicado filtros, por forma a ser possível formar a ilha da rede onde, foi discutido que só irá ser analisado uma saída por cada barramento da subestação. Os valores da rede elétrica são valores reais da rede inicial e provêm da telemetria, como foi restringido o número de saídas de cada subestação, esta fica em desequilíbrio para os valores telemetrados, de forma a mitigar esta situação, foi criada uma carga *fictícia* em cada subestação com o simples objetivo de conseguir equilibrar os valores telemetrados com o número de saídas existentes.

A zona estudada da rede elétrica é a do centro litoral, verificada na Figura 3.1.




Figura 3.1: Mapa Geográfico da Zona Centro Litoral Portugal

De forma a ser possível verificar a dimensão da rede a estudar, é verificado nas Figuras 3.2 e 3.4, onde averigua-se que consoante o utilizador do sistema *SCATEX* estiver a aproximar-se mais no plano geográfico o número de equipamentos visíveis aumenta, assim como o nível da rede a operar.






Figura 3.5: Mapa Geográfico mais detalhado da Rede em Média Tensão (MT)

Na rede elétrica estudada existe a subestação de *Carvoeira*, verificada na Figura 3.6 que possui a particularidade de ser uma subestação injetora e por isso permanece interligada à restante rede de 150 kV .




Figura 3.6: Subestação Injetora

No caso de estudo da rede foi necessário fazer uma restrição para que, a previsão e otimização ocorra numa versão mais restrita da rede atual. Com recurso ao sistema *SCATEX* elaborou-se um filtro para a rede final, como é averiguado na Figura 3.7 com a coloração a azul claro.




Figura 3.7: Filtro da rede elétrica estudada

Para não sub dimensionar a rede foi proposto apenas uma saída de cada barramento por subestação, na Figura 3.8 é possível comprovar tal medida assim como, a coloração a azul claro para verificar que pertencem ao Filtro averiguado na Figura 3.7.



Figura 3.8: Filtro na subestação

Na Figura 3.8 é possível verificar que a rede AT, transformadores, barramentos da rede de MT, equipamentos de medição e bateria de condensadores estão incluídos no filtro.

No sistema *SCATEX* existe uma aplicação de energia que é executada ciclicamente, denominada de trânsito de potências e que no qual, é possível ver os resultados na Figura 3.9 e também os valores das telemetrias reais. Nas saídas que não estão incluídas no filtro a telemetria foi colocada com o valor zero ("0") e não existe resultados de trânsito de potências.




Figura 3.9: Trânsito de Potências

Como existe apenas uma saída por barramento, foi criado uma carga *fictícia* conseguindo assim, compensar os valores totais na rede, podendo usar os valores reais da telemetria em toda a zona estudada da rede. Se não existisse a adição desta carga, os valores dos transformadores (rede AT) estariam muito diferentes dos valores das saídas (rede MT) devido à restrição no número delas mesmas.

3.3 Caracterização da Rede Elétrica

Com as ferramentas do sistema *SCATEX* foi possível fazer uma caracterização da rede elétrica mais pormenorizada, assim como a inclusão de armazenamentos de energia ao longo das subestações e a verificação e mudança das características dos equipamentos existentes na rede que estavam com informação importante em falta, verifica-se na Figura 3.10 que foi utilizado a ferramenta editor do sistema *SCATEX* de forma a verificar que valores estão presentes e os que faltam nos parâmetros dos equipamentos:

Transformador 2 Enrolamentos ☒

Transformador 2 Enrolamentos
LSTVSUSTP1-XF

Informação geral

Identificador : LSTVSUSTP1-XF Tipo : TRANSFORMER
 Subtipo : NOT DEFINED Nivel Tensão : 60
 Descrição : TP AT/MT 1

Enrolamento 1 : LSTVSUSTP1-W1 ✕ Enrolamento 2 : LSTVSUSTP1-W2 ✕

Posicione os enrolamentos aqui.

Informação Transformador

Condutância de magnetização (mS) : 0.0038888111126664 Tensão base de Saturação (kV) :
 Susceptância de magnetização (mS) : Condutância de magnetização de Saturação (mS) :
 Condutância de magnetização Homopolar(mS) : Joelho da curva de magnetização :
 Susceptância de magnetização Homopolar(mS) : Tipo de arrefecimento :

1

Tensão Nominal (kV) : 60 Resistência (Ohm) : 0.28
 Potência Nominal (MVA) : 20 Reatância (Ohm) : 9
 Tipo de ligação : Estrela Resistência Homopolar (Ohm) : 0.78
 Resistência de Neutro (Ohm) : Reatância Homopolar (Ohm) : 22.49
 Reatância de Neutro (Ohm) :
 Posicione a tomada aqui : LSTVSUSTP1-RT ✕

Figura 3.10: Detalhe do Transformador

Na Figura 3.10 verifica-se as várias variáveis que complementam o equipamento transformador e nos valores em falta recorreu-se a manuais de equipamentos elétricos dos clientes e de revendedores de equipamentos por forma, a concluir a configuração dos mesmos.

Depois da configuração da rede elétrica e dos valores em falta dos equipamentos, a rede elétrica estudada da ilha da Carvoeira apresenta a seguinte constituição:

- Número de:
 - Cargas: 580;
 - Linhas: 1731;
 - Equipamentos: 5182;
 - Baterias de condensadores: 24;
 - Geradores síncronos: 15;
 - Transformadores de potência: 41;
 - Transformadores de tensão: 145;
 - Transformadores de corrente: 182;
 - Barramentos: 344;
 - Seccionadores: 1689;
 - Armazenamento de energia: 3;
 - *Produtor em Regime Especial (PRE)*: 13.

- **Produtor em Regime Especial (PRE)**

Irá ser dado com mais ênfase no Produtor em Regime Especial (PRE) neste ponto, como interligam com a rede, que tipo podem ser e quantos existem na rede.

São produtores que não pertencem à gestão da empresa distribuidora (*Energias de Portugal* (EDP) mais conhecida agora por *E-REDES*) e que têm a possibilidade de consumir ou produzir energia consoante os seus contratos energéticos.




Figura 3.11: Produtor Independente

Onde ao utilizar o sistema *SCATEX* é possível obter detalhes da instalação de um Produtor em Regime Especial (PRE) na Figura 3.12, ao continuar com o exemplo da Figura 3.11 obtemos as seguintes informações:

Hierarchical Level: 2

[DRCT_CLD](#) → [LXER06](#)
[\(5432,97\)](#) → [\(10473,8852740\)](#)
[AO CALDAS DA RAINHA](#) → [PRE VALE DE GALEGOS](#)

Type EOLICA,PRODUTOR INDEPENDENTE

Uid (10473,8852740)

Description PRE VALE DE GALEGOS

Network level 60

AoRs CLD_AT **Diagram**

Level 3

Entity	Entity Up	Description	Type	Subtype	N
1 LXER06-K001	LXER06	PAINEL SINTETICO	LOGPANEL	SINTETICO	
2 LXER06SLIG1	LXER06	501 L9006 PC V. GALEGOS	LOGPANEL	NOT DEFINED	

Figura 3.12: Detalhe da Instalação de Produtor em Regime Especial (PRE)

De acordo com as informações da Figura 3.12, é possível averiguar que se trata de um produtor em regime especial eólico com interligação com a subestação de Vale de Galegos em 60 kV.

Na figura 3.13 averigua-se os detalhes de energia do PRE em causa:

Transformador 2 Enrolamentos
LXER06SLIG1XF

Informação geral

Identificador : LXER06SLIG1XF Tipo : TRANSFORMER
 Subtipo : NOT DEFINED Nível Tensão : 60
 Descrição : TP AT/MT 1

Posicione os enrolamentos aqui.

Enrolamento 1: LXER06SLIG1W1 ✕ Enrolamento 2: LXER06SLIG1W2 ✕

Informação Transformador

Condutância de magnetização (mS) : 0.0044444444444444 Tensão base de Saturação (kV) :
 Susceptância de magnetização (mS) : Condutância de magnetização de Saturação (mS) :
 Condutância de magnetização Homopolar(mS) : Joelho da curva de magnetização :
 Susceptância de magnetização Homopolar(mS) : Tipo de arrefecimento :

1

Tensão Nominal (kV) : 60 Resistência (Ohm) : 0.26
 Potência Nominal (MVA) : 27.95 Reactância (Ohm) : 6.56
 Tipo de ligação : Estrela Resistência Homopolar (Ohm) : 0.74
 Resistência de Neutro (Ohm) : Reactância Homopolar (Ohm) : 16.41
 Reactância de Neutro (Ohm) :
 Posicione a tomada aqui
 LXER06SLIG1RT ✕

Figura 3.13: Detalhes de Energia de um Produtor em Regime Especial (PRE)

Ao utilizar o sistema *SCATEX* é permitido fazer *traces* das ligações elétricas, por forma a verificar as suas ligações. No exemplo a verificar nas Figuras 3.14, 3.15 e 3.16, foi executado um trace de cor castanho, onde é possível

averiguar a ligação de 60kV do produtor independente até à subestação de Vale de Galegos.




Figura 3.14: *Trace* da interligação Produtor Independente




Figura 3.15: *Trace* da interligação Produtor Independente para a Subestação




Figura 3.16: *Trace* da interligação Subestação

Em suma, a rede elétrica a estudar possui cerca de 13 produtores independentes onde, três deles são do tipo cogeração e dez são do tipo eólica, conforme é comprovado na listagem obtida pelo sistema *SCATEX* na Figura 3.17.

	Entity	Entity Up	Description	Type Δ	Subtype	Network level
1	LXK01I	L	PRE TVD 4119 ENERSEIXO	COGERACAO	PRODUTOR INDEPENDENTE	30 kV
2	LXK01W	L	PRE AGROGER	COGERACAO	PRODUTOR INDEPENDENTE	60 kV
3	LXK001	L	PRODUTOR / CENTRAL	COGERACAO	PRODUTOR INDEPENDENTE	30 kV
4	LXIB28	L	PRE SERRA DA ESCUSA	EOLICA	PRODUTOR INDEPENDENTE	10 kV
5	LXIB26	L	PRE CABECO JARMELEIRA	EOLICA	PRODUTOR INDEPENDENTE	10 kV
6	LXER39	L	PRE SOBRAL II	EOLICA	PRODUTOR INDEPENDENTE	30 kV
7	LXJOG2	L	PRE JOGUINHO II	EOLICA	PRODUTOR INDEPENDENTE	60 kV
8	LXER09	L	PRE TVD 0010 MARAVILHA 1	EOLICA	PRODUTOR INDEPENDENTE	30 kV
9	JXER35	J	PRE SERRA DEL-REI	EOLICA	PRODUTOR INDEPENDENTE	60 kV
10	LXER33	L	PRE PARQUE EOLICO DO PO	EOLICA	PRODUTOR INDEPENDENTE	60 kV
11	LXER06	L	PRE VALE DE GALEGOS	EOLICA	PRODUTOR INDEPENDENTE	60 kV
12	LXK01V	L	PRE CATEFICA	EOLICA	PRODUTOR INDEPENDENTE	60 kV
13	LXIB22	L	PRE MFR 5537 PE S. MAMED	EOLICA	PRODUTOR INDEPENDENTE	30 kV

Figura 3.17: Número e Tipo de Produtores Independentes

Na Figura 3.18 comprova-se que o PRE está a injetar na rede 0.67 MW porque o seu valor de potência é de sentido negativo. Na Figura 3.19 verifica-se o sentido da injeção.




Figura 3.18: Injeção de um Produtor em Regime Especial (PRE)



Figura 3.19: Injeção de um Produtor em Regime Especial (PRE) na Rede

No final deste trabalho sobre a caracterização da rede elétrica, este foi validado com a execução de um trânsito de potências onde se conseguiu obter os resultados de acordo com a telemetria, indicando que as características estavam bem caracterizadas.

3.4 Módulos da previsão

Como o processamento da previsão é feito através de várias etapas, aqui referido como módulos, irá ser explicado o seu processo de distribuição ao longo deste subcapítulo, com atenção que os módulos descritos não estão por ordem de execução porque existe execuções paralelas.

- **Módulo 1** - Verificação e processamento dos dados relativos às potências ativa e reativa telemetradas (Receção e Transmissão dos dados):

É um módulo que está sempre "*à escuta*" de novas variações na telemetria e sempre que existir um nova variação, esta é automaticamente recolhida e guardada em base de dados. Verificar se existe novas alterações dos dados telemetrados da rede é de extrema importância a fim de, não prejudicar a eficácia de todo o processo para ser usado posteriormente na previsão, este módulo foi subdividido em três tarefas:

- Em primeira instância, é utilizado *Kafka*, de forma a serem criados *Kafka consumers* para recolha das potências ativa e reativa médias;
- De seguida, é elaborado cálculos de potência onde a ideia é fazer uma subtração da consumida e injetada por cada consumidor ou ponto gerador;

- No final, é feita uma avaliação dos dados a fim de identificar valores em falta ou até valores que possam estar com erros, fazendo estimação destes mesmos recorrendo a análises periódicas.

A utilização deste módulo necessita de ter uma constante comunicação com a base de dados devido a, se existir uma nova telemetria esta é enviada automaticamente e guardada em base de dados.

- **Módulo 2** - Previsão das potências ativa e reativa em relação ao consumo e à geração destas (Processo de previsão):

O módulo 2 é o módulo mais fulcral de toda a previsão pois, é neste módulo que é iniciado os processos de previsão que foram explicados no estado da arte da presente tese, referente no Capítulo 2.

A previsão foi feita de forma a obter os valores de potência ativa e reativa quer das várias cargas existentes na rede, quer da produção dos *PGE*, referenciada no Subcapítulo 3.3.

Este módulo irá também conter várias funcionalidades no âmbito da previsão:

- Treino de modelos de previsão;
- Utilização destes modelos de previsão já treinados, para a inclusão de novas variáveis de entrada no sistema, de forma a ser possível fazer novas previsões com bases nestas novas mudanças.

A escolha de quais algoritmos é que poderia ser usado na previsão foi discutido com todos as empresas participantes do projeto *Grid's Predictive Management Considering Distributed Energy Resources* (GPDER) onde, se chegou à conclusão de dois algoritmos: Foram idealizados dois algoritmos diferentes, conforme o tipo de histórico existente das instalações, o *Gradient Boosting* (GB) e *Quantile Regression* (QR):

- A escolha do algoritmo *Gradient Boosting* (GB) recaiu por ser um modelo de previsão robusto, tendo inúmeros exemplos da sua aplicabilidade em casos de previsão no âmbito elétrico e também na sua não linearidade, o que permite modelar as relações entre os consumos e suas variáveis independentes, isto é, existir a possibilidade de existir cargas com aumentos de consumo aquando existe uma temperatura alta ou uma temperatura baixa;
- O algoritmo *Quantile Regression* (QR) também era um algoritmo válido mas como o projeto GPDER era de âmbito de previsão que requeria um grande número de dados históricos para a sua eficácia, não foi utilizado.

Nas situações em que ocorreu falta de valores numéricos (não existência de valores meteorológicos ou do mais recente histórico de medidas) os modelos utilizaram combinações de diferentes variáveis por forma a mitigar a ausência destes.

Os modelos que mais se adequaram como modelos ideais foram os treinados consoante as medidas mais recentes e da sua previsão meteorológica.

Como os modelos de previsão foram guardados localmente, possibilitou uma maior rapidez de execução pois, a cada carregamento da previsão irá ser aplicado as novas variáveis de entrada nos modelos já treinados.

Na execução da previsão foi utilizado o modelo mais adequado com recurso a esforço computacional, de forma a efetuar as previsões de cada instalação. No âmbito dos dias de feriado, a previsão executou um pós-processamento nos pontos de consumo.

Posteriormente a toda esta previsão efetuada, os resultados foram guardados em base de dados para ser possível a sua verificação de valores, assim como a definição das configurações do sistema usadas.

- **Módulo 3** - Cálculo de *Key Performance Indicator (KPI)* para a previsão, de forma a ser possível "medir" a eficácia da previsão (Cálculo dos KPI):

Neste módulo foi representado a criação de indicadores de qualidade (*KPI*), de forma a medir a performance e o correto desempenho. O cálculo dos erros de previsão é de forma agendada e configurável.

Um momento com valor t é considerado o seu valor observado y_t nesse instante e $\hat{y}_t$ o seu valor previsto e por último, n ser o número de observações.

Com estas normas é possível averiguar os seguintes indicadores de qualidade (*KPI*):

– Equação de *Mean Absolute Error (MAE)*:

- * Permite calcular o desvio entre o valor observado e o seu valor previsto.

$$\frac{1}{n} \sum_t |y_t - \hat{y}_t| \quad (3.1)$$

– Equação de *Root Mean Squared Error (RMSE)*:

- * De forma a complementar o erro calculado pelo *MAE* para erros de maior magnitude é utilizado a seguinte fórmula:

$$\sqrt{\frac{1}{n} \sum_t (y_t - \hat{y}_t)^2} \quad (3.2)$$

– Equação de *Continuous Ranked Probability Score (CRPS)*:

- * Utilizado devido à natureza da previsão considerando a sua distribuição.
- * F é a função de distribuição da previsão para o valor observado x e a função $I(i)$ retorna a seguinte situação:
 - Retorna "1" se o argumento i for superior a "0";
 - Retorna "0" se o argumento i for inferior ou igual a "0"

$$CRPS(F, x) = \int_{-\infty}^{+\infty} (F(y) - I(y - x))^2 dy \quad (3.3)$$

– Equação de *Normal Mean Absolute Error (NMAE)*:

- * As medidas resultantes do cálculo *MAE* são divididos pela a subtração das medidas máximas observadas e previstas da correspondente série.

$$\frac{MAE}{(Max(y_t) - Max(\hat{y}_t))} \quad (3.4)$$

– Equação de *Normal Root Mean Squared Error (NRMSE)*:

- * As medidas resultantes do cálculo *RMSE* são divididos pela a subtração das medidas máximas observadas e previstas da correspondente série.

$$\frac{RMSE}{(Max(y_t) - Max(\hat{y}_t))} \quad (3.5)$$

As equações *NMAE* e *NRMSE*, permitem existir uma comparação percentual, o que irá possibilitar comparar os erros provenientes de cada instalação.

- **Módulo 4** - Recolha dos dados inerentes à previsão meteorológica (Valores meteorológicos):

Este módulo tem como objetivo fazer a aquisição da previsão dos valores meteorológicos, conseguindo assim uma previsão mais realista.

Os valores obtidos são provenientes da *MeteoGalicia* [33], que possibilita a existência de serviços de meteorologia utilizando o modelo *Weather Research and Forecasting (WRF)* que obtêm no seu repositório um grande conjunto de informação sobre os países da Europa.

O tempo de recolha da previsão é feita às 00h (*Coordinated Universal Time (UTC)*) e é gerado em ficheiro *NETCDF4*, que guarda a malha de coordenadas geográficas e as suas previsões.

Como esta obtenção da previsão de valores meteorológicos possibilita fazer em torno de vários países da Europa, é preciso fazer configuração da sua cobertura espacial.

A configuração proporciona três escolhas de malha, como verificado na Figura 3.20:

- 4 km;
- 12 km;
- 36 km.




Figura 3.20: Cobertura Espacial da Zona das Malhas

A seleção da malha recaiu para os de 12km com restrição para a zona de Portugal de forma, a ser possível abranger todos os equipamentos de produção e de consumo. A escolha da malha teve em especial atenção à zona geográfica do modelo a estudar, isto é, ocupou todas as zonas da rede descrita no Subcapítulo 3.2.

De forma a verificar se os dados estão atualizados e que possuem a data correta de recolha irá ser utilizado procedimentos de verificação, assim como:

- 1 - Verificar e atualizar as coordenadas da grelha (rede elétrica);
- 2 - Verificação da datação do último ficheiro *NETCDF4* para cada ponto da grelha;
- 3 - Caso o ponto 2 não esteja com todos os ficheiros *NETCDF4* atualizados, fazer atualização destes mesmos;
- 4 - Processamento da informação recolhida (extração de variáveis importantes) e verificação das situações que não contêm informação;
- 5 - Popular a base de dados com a informação detalhada e processada no ponto 4.

Na Figura 3.17, é possível verificar os tipos de argumentos de condição meteorológica que os produtores independentes dependem. Todos os produtores independentes têm como variáveis o fator *vento*, isto porque são de natureza eólica.

As variáveis recolhidas dos ficheiros meteorológicos, em relação à energia eólica são as seguintes:

- Direção (*dir*) com a sua unidade em $^{\circ}$;
- Módulo do vento (*mod*) com a sua unidade em m/s ;
- Vento longitudinal a 10 metros (*u*) com a sua unidade em m/s ;
- Vento longitudinal no modelo – nível 1 (*ulev1*) com a sua unidade em m/s ;
- Vento longitudinal no modelo – nível 2 (*ulev2*) com a sua unidade em m/s ;
- Vento longitudinal no modelo – nível 3 (*ulev3*) com a sua unidade em m/s ;
- Vento latitudinal a 10 metros (*v*) com a sua unidade em m/s ;
- Vento latitudinal no modelo – nível 1 (*vlev1*) com a sua unidade em m/s ;
- Vento latitudinal no modelo – nível 2 (*vlev2*) com a sua unidade em m/s ;
- Vento latitudinal no modelo – nível 3 (*vlev3*) com a sua unidade em m/s .

- **Módulo 5** - *Representational State Transfer (REST) Application Programming Interface (API)* para comunicação com plataforma de previsão:

A comunicação feita neste componente é feita por *Hypertext Transfer Protocol (HTTP)* onde permite ao utilizador operar os serviços criados ou até, modificar que métodos são invocados e quais não o são.

Este componente permite dois métodos do *HTTP*:

- **GET** - Acessar à informação alojada na base de dados da plataforma:
 - * Obter a previsão das potências;
 - * Verificar as medições de potência recolhidas;
 - * Visualizar a configuração da instalação;
 - * Investigar os cálculos de performance obtidos (*KPI*).
- **POST** - Criar novos pedidos à base de dados para recolha de dados:
 - * Registar novas instalações;
 - * Configuração do sistema;
 - * Publicar medidas.

Na Listagem 3.1 é possível verificar um pedido *HTTP* com o método *GET* para obter informações sobre os quantis *10*, *50* e *90* das previsões da Potência Ativa, com *register_type* com o valor de *P* sobre a instalação *inst1* entre os dias *20 de janeiro de 2021* e *21 de janeiro de 2021*.

```

1      {
2          http://{host}:{port}/api/forecast/
              measurements?installation_code=inst1&
              register_type=P&start_date=2021-01-20T00
              :00:00Z&end_date=2021-01-21T00:00:00Z&
              quantiles=10,50,90
3      }
```

Listagem 3.1: Parâmetros de um pedido *HTTP* com o método *GET*

3.5 Arquitetura geral da solução

Por forma a demonstrar uma imagem geral da arquitetura referenciada nos capítulos anteriores, foi elaborada a Figura 3.21.

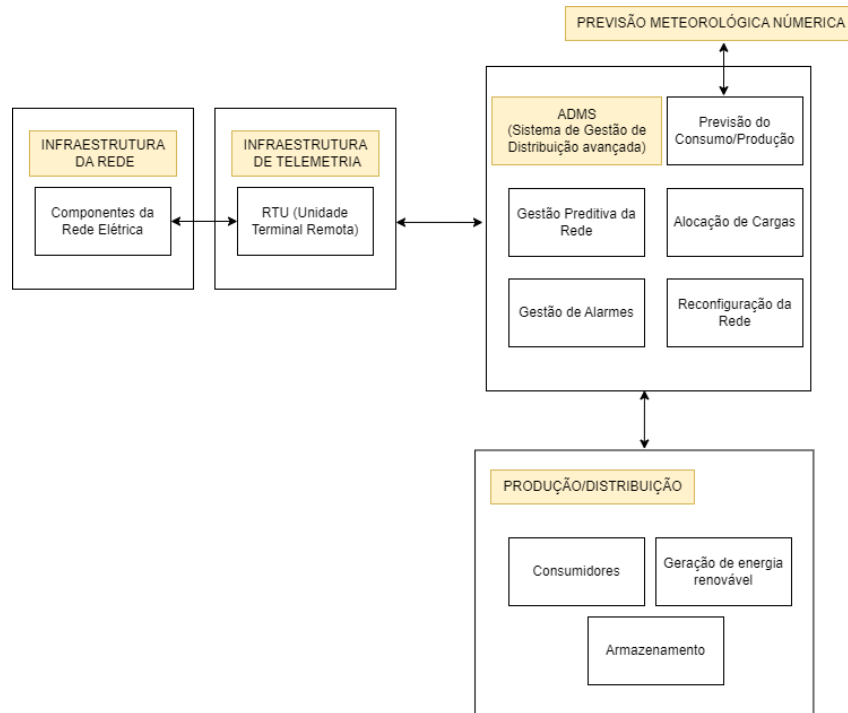


Figura 3.21: Arquitetura geral da solução

Como é possível verificar através da Figura 3.21 existe constante comunicação entre os vários componentes inerentes do projeto, de notar que as setas que interligam os componentes são de duplo sentido, isto é, existe dupla comunicação entre os componentes:

- O componente de infraestrutura da rede que possui os vários componentes da rede, faz comunicação com a infraestrutura de telemetria através das *RTU* permitindo assim, o envio dos valores dos componentes da rede obtendo assim um estado da mesma;
- O componente *ADMS* é onde se verifica o maior número de módulos da arquitetura pois, esta comporta-se como uma base de dados central e por isso, todas as informações da rede, alocação de cargas, gestão de alarmes e configurações das cargas e geradores são guardadas neste componente. Para a previsão de produção e consumo é utilizada toda a informação existente em base de dados assim como, os dados provenientes da previsão dos dados meteorológicos;

- O último componente de produção/distribuição, possui informação sobre as cargas e geradores de energia renováveis. A existência do novo equipamento na rede que é os *storages* que possibilita o armazenamento e descarregamento da respetiva energia quando esta seja mais economicamente favorável, sem perturbar o comportamento normal da rede.

3.5.1 Kafka

Como referido no Módulo 1 do Subcapítulo 3.4 a tecnologia que permite fazer uma constate comunicação com a *SCADA* é o *Kafka*, todas as mensagens são de natureza *Kafka* de forma a serem lidas e recebidas por toda a plataforma.

- **raw_measure** - Processo de recolha dos valores de P [*Potência Ativa*] e Q [*Potência Reativa*] telemetrados:

Numa etapa inicial, existe comunicação entre a *SCADA* e *RTU* para permitir a recolha dos valores telemetrados, um exemplo desta mensagem está na Listagem 3.2. Esta recolha acontece sempre que exista novas alterações da telemetria para obter um estado da rede mais atualizado. Posteriormente a *SCADA* faz comunicação com a *ADMS*, guardando toda a informação recolhida em base de dados.

```

1      {
2          "installation":"inst1",
3          "values":
4          [
5              {
6                  "datetime":"2018-10-19T01:15:00Z",
7                  "value":80.0,
8                  "units":"kw",
9                  "register_type":"A+"
10             }
11         ]
12     }
```

Listagem 3.2: Mensagem *Kafka* Telemetrada

Onde é possível verificar que a instalação é *inst1* registou o seu valor de potência ativa consumida (*A+*) de 80.0 kW no dia 19 de outubro de 2018 às 01h:15m:00s.

- **forecast__task** - Envio dos dados para o cálculo da previsão:

A comunicação será feita a após o pedido da plataforma de previsão, a fim de providenciar uma hora para o começo do cálculo da previsão, um exemplo desta mensagem está na Listagem 3.3, podendo também ser configurável para existir pedidos cíclicos.

```
1      {
2          "installation_code" : "inst1",
3          "horizon": 24,
4          "launch_time": "2018-10-20 23:00:00"
5      }
```

Listagem 3.3: Mensagem *Kafka* para começo do cálculo da Previsão

A instalação que queremos que exista previsão é *inst1* com o horizonte temporal para o cálculo da previsão de 24 horas e a sua data de início no dia 20 de outubro de 2018 às 23h:00m:00s.

- **forecast__result** - Receção dos resultados do cálculo da previsão:

Após o cálculo da previsão a plataforma envia uma mensagem com os resultados, um exemplo desta mensagem está na Listagem 3.4.

```
1      {
2          "status_code": 1,
3          "error_msg": "ok",
4          "installation_code" : "inst1",
5          "result": [
6              {
7                  "register_type": "P",
8                  "datetime": "2018-10-20T23:00:00Z",
9                  "request": "2018-10-20T23:00:00Z",
10                 "q50": -437.57
11             },
12             {
13                 "register_type": "P",
14                 "datetime": "2018-10-21T00:00:00Z",
15                 "request": "2018-10-20T23:00:00Z",
16                 "q50": -238.17
17             }
18             {
19                 "register_type": "P",
20                 "datetime": "2018-10-21T01:00:00Z",
21                 "request": "2018-10-20T23:00:00Z",
22                 "q50": -78.14
23             }
24             .
25             .
26             .
27         ]
28     }
29 }
30 }
```

Listagem 3.4: Mensagem *Kafka* do resultado do cálculo da Previsão

A instalação onde foi feito o cálculo da previsão é *inst1*, as suas mensagens foram de sucesso *ok* e *1* e resultou na previsão da Potência Ativa *P* para as 24h seguintes da sua data inicial *20 de outubro de 2018* às *23h:00m:00s*, com o valor guardado na variável *q50* que é referenciado como *quantile 50* e sintetizado no Subcapítulo 4.2.

3.5.2 Plataforma de Previsão

Depois de existir comunicação pelo o uso da tecnologia *Kafka* é possível verificar na Figura 3.22 o que acontece com estas mensagens.




Figura 3.22: Arquitetura de integração com Plataforma de Previsão

Na Figura 3.22 verifica-se que o componente *Kafka* possui três tipos de mensagens, explicadas anteriormente e o que acontece com o conteúdo das mesmas.

Possibilidade de configuração através de uma *REST API server* permitindo uma melhor gestão do modelo:

- A configuração do pedido de previsão é alojada na mensagem *forecast_task* e é feita no arranque ou a pedido do utilizador;
- De acordo com a Figura 3.21 os valores telemetrados estão guardados na *ADMS* e é um processo que ocorre sempre que existirem novas telemetrias, de forma a popularem as mensagens de *raw_measure*;
- Verifica-se que é lido as mensagens de *raw_measure* e *forecast_task* pela plataforma da previsão para dar início ao cálculo da previsão;
- Possibilidade de treinar todo o processo da previsão, a fim de ajustar o modelo com novos pedidos do utilizador ou serem ciclicamente feitos;

- A plataforma de previsão faz o cálculo com recurso ao algoritmo de *Gradient Boosting (GB)* e retorna uma mensagem com o respetivo conteúdo para a mensagem de *forecast_result*;
- A mensagem *forecast_result* é lida pela *ADMS* a fim de guardar os resultados em base de dados;

Na plataforma de previsão temos vários detalhes que vão ser explicados de seguida:

- *Saídas da previsão*
 - O *output* da plataforma é a previsão das cargas e da geração dos *PRE* em forma de potência ativa e reativa;
 - Possível fazer previsão para um horizonte temporal até 72h seguintes;
 - Resultado da previsão em forma probabilista (*quantil*).
- *Funções Integrantes*
 - *REST API server* por forma a poder configurar que módulos é que estão disponíveis, retirar ou até adicionar novos;
 - Integração com a tecnologia *Kafka* para suportar o consumo e a publicação de mensagens entre os vários componentes e processamento das medidas telemetradas a fim de minimizar o erro de leitura, averiguado no Módulo 1 do Subcapítulo 3.4;
 - Cálculo de medidores de performance (*KPI*) com vista a medir a eficácia da previsão, verifica-se no Módulo 3 do Subcapítulo 3.4;
 - Previsão Numérica Meteorológica com o modelo *WRF*, referente no Módulo 4 do Subcapítulo 3.4.

A fim de mostrar os módulos existentes e como cada componente comunica elaborou-se a Figura 3.23 que explica a sintaxe para uma melhor lucidez na matéria:




Figura 3.23: Arquitetura de integração com módulos

É possível verificar que existe 5 módulos que foram descritos no Subcapítulo 3.4 e que consoante qual pedido *HTTP* é feito, a natureza das mensagens é diferente. A coloração azul permite ao utilizador verificar que é feito um pedido *HTTP* com o método *POST* e a coloração verde é feito com o método *GET*.

Os pedidos *POST*, permitem ao utilizador fazer publicações de mensagens, podendo assim modificar instalações e configurar o sistema já o pedido *GET* consegue recuperar as mensagens guardadas em base de dados que possibilita ao usuário verificar os dados que estão a ser armazenados.

Todos os pedidos *HTTP* são feitos através da *streamline* do *Kafka*. Para simplificar a arquitetura da comunicação envolvente com *Kafka* desenhou-se a Figura 3.24.




Figura 3.24: Arquitetura de integração com módulos em *Kafka*

Onde é possível verificar que a coloração azul é a publicação de mensagens e a coloração verde é o consumo das mesmas. O utilizador com o pedido *HTTP* e o método *POST* consegue publicar na *streamline* do *Kafka* novos pedidos de cálculo de previsão e enviar novos dados da rede, que irão ser consumidos pela *REST API* para serem armazenados em base de dados. Quando o usuário faz um pedido *HTTP* com o método *GET* a *REST API* publica a mensagem na *streamline* do *Kafka* com os resultados da previsão para o utilizador consumir.

Toda a execução desta plataforma de previsão é demonstrada na Figura 3.25.




Figura 3.25: Arquitetura de execução da plataforma de previsão

- Na componente das aplicações de energia, averiguar Subcapítulo 3.6, existe uma execução da previsão às 00h:00m onde é guardada em base de dados, podendo também ser feito a pedido do utilizador quando este envia uma mensagem com o tópico *forecast_task*;
- Os dados guardados irão ser ajustados com base em perfil de engenharia para serem o mais realista possível, isto é, adição de eventos calendarizados, histórico de medidas e transformação das variáveis recebidas pela previsão numérica de meteorologia;
- O módulo de previsão é sustentável no algoritmo *Gradient Boosting (GB)* que por sua vez, faz a previsão das potências ativas (*P*) e reativas (*Q*). Este modelo de previsão já é pré-treinado para ser de mais rápida execução e com maior veracidade consoante os dados recebidos, os valores de "treino" são guardadas na base de dados para uma posterior execução de previsão, estes dados guardados são calendarizados por forma, a ser utilizado o modelo de treino mais recente;
- O resultado da previsão é para um horizonte temporal de 72h após a data de início e armazenada na mensagem com o tópico *forecast_result* que é enviada pela *streamline* do *Kafka* para o utilizador que publicou o pedido.

3.6 Criação do pólo funcional

Para a construção de um pólo funcional, de forma a ser possível concluir o projeto, foi desenhado um sistema com as várias funções dos componentes:

- **SCADA** - Monitorizar as medidas telemetradas e o estado da rede em tempo real, operar/controlar a rede através do envio de comandos e uma constante comunicação com as *RTU* de forma a verificar as alterações nos valores da telemetria e caso existe, receber os novos valores e guardar em base de dados;
- **DMS** - Alojjar execuções de aplicações de energia, carregar as características da rede com a respetiva coloração da mesma em tempo real.
- **Servidor de Aplicações de Energia:**

Os valores da previsão são guardados em base de dados num servidor de cálculo com o propósito para tal.

É um serviço que está alojada na parte do componente *DMS* que por sua vez, tem os valores e estado da rede elétrica com os cálculos referentes à previsão e otimização da rede elétrica.

Foi elaborada uma *API* por cada tipo de equipamento, por forma a popular as *tabs* da página *web* de visualização, averiguar Subcapítulo 4.1, que comunica com o servidor em causa para ir buscar os valores referentes a cada tipo de equipamento.

O processo da otimização da rede elétrica é evocar os resultados da previsão e com a rede elétrica toda carregada faz cálculos de energia e validações sobre o comportamento da mesma, resultando assim nos valores da otimização da rede elétrica que irá ser chamada pela *API* referente à página *web*, de forma a transmitir o resultado para a *GUI*.

3.7 Análise sumativa

Neste capítulo, abordou-se algumas das características do produto comercializado pela EFACEC e das ferramentas (tecnologias) utilizadas, de forma a auxiliarem o projeto GPDER. Estas tecnologias foram de grande importância para o desenvolvimento do projeto e para aprendizagem pessoal pois, são ferramentas que são muito utilizadas no dia a dia empresarial em vários setores.

Neste capítulo foi elaborado, de uma forma resumida, a caracterização do caso de estudo para o projeto *Grid's Predictive Management Considering Distributed Energy Resources (GPDER)*. No âmbito da restrição da rede elétrica foi utilizado o sistema SCATEX, onde conhecimentos foram adquiridos sobre este sistema. Com isto, é possível verificar que é um sistema que abrange do mais pequeno até ao maior detalhe de uma rede elétrica. Caracterizou-se a rede elétrica ao adicionar cargas *fictícias* por forma a ser possível mitigar as diferenças provenientes da telemetria da rede atual com a rede restrita. Validou-se a rede elétrica ao comparar os resultados simulares entre a execução da aplicação de trânsito de potências com os valores de telemetria reais usados na rede.

De notar que a consideração da previsão de Produtor em Regime Especial (PRE) evidencia que o projeto tende como seu objetivo, se aproximar mais da realidade e dos problemas que existem nas redes elétricas atuais.

Foi também elaborado um pequeno excerto do processo de previsão, assim como os módulos que o compõe, com uma breve explicação de cada por forma a elucidar ao leitor sobre uma visão mais pormenorizada sobre o projeto.

Existe uma constante comunicação com os vários componentes do sistema para que exista uma recolha, verificação e transmissão de dados atempadamente e ciclicamente para que a previsão ocorra com os dados mais recentes e com o menor aparecimento de ruído na informação.

Verificou-se como foi feito a construção de um pólo funcional para o âmbito do projeto, que funções e componentes eram necessários assim como, uma breve explicação do servidor de aplicações de energia.

Capítulo 4

Desenvolvimento gráfico e Explicação do Algoritmo de Previsão


Neste capítulo irá ser demonstrado os desenvolvimentos da parte gráfica, no âmbito web, de forma a ser possível visualizar os resultados da previsão de cargas e de geração assim como, a da otimização da rede elétrica.

Irá ser referido algumas características usadas no algoritmo Gradient Boosting (GB) por forma a complementar toda a informação sobre o caso de estudo que se têm vindo a ser retratado na presente Tese.

4.1 Desenvolvimento gráfico

A otimização da rede elétrica é uma otimização multi temporal usando o *Multi-Period Optimal Power Flow (MOPF)*, isto é, uma otimização que providencia resultados de hora em hora onde, sugere manobras nos equipamentos para obter um melhor estado da rede quando comparada com o inicial. Apresenta resultados das tomadas de transformadores e o carregamento/descarregamento dos *storages* na rede, tendo sempre em conta o comportamento financeiro do mercado de forma a fazer uma melhor gestão da rede elétrica.

Neste segmento irá ser explicado com mais detalhe a página *web*, na Figura 4.1, onde existe uma *GUI* de visualização dos resultados da previsão e da otimização da rede elétrica para as próximas 24h. A otimização da rede elétrica é feita para as 24 horas seguintes e usa os valores da previsão como valores base.




Period	Equipment Description	Equipment Type	Changes	Initial Position	Final Position	Cost
01:00	Cliente Agregador 2	Load	P (kW)	2784	2997	0.0
01:00	SE TELHEIRO ANTIGA - AGG 108 - Cliente Agregador 1	Load	P (kW)	2828	2901	0.0
02:00	Cliente Agregador 2	Load	P (kW)	2784	3038	0.0
02:00	SE TELHEIRO ANTIGA - AGG 108 - Cliente Agregador 1	Load	P (kW)	2706	3240	0.0
02:00	SE TELHEIRO ANTIGA - AGG 119 - Cliente Agregador 3	Load	P (kW)	3546	3757	0.0
03:00	SE TELHEIRO ANTIGA - AGG 119 - Cliente Agregador 3	Load	P (kW)	3517	3842	0.0
03:00	SE TELHEIRO ANTIGA - AGG 108 - Cliente Agregador 1	Load	P (kW)	2656	3306	0.0
03:00	Cliente Agregador 2	Load	P (kW)	2784	3043	0.0
04:00	SE TELHEIRO ANTIGA - AGG 119 - Cliente Agregador 3	Load	P (kW)	3471	3840	0.0
04:00	Cliente Agregador 2	Load	P (kW)	2784	3046	0.0
04:00	SE TELHEIRO ANTIGA - AGG 108 - Cliente Agregador 1	Load	P (kW)	2654	3396	0.0
05:00	Cliente Agregador 2	Load	P (kW)	2784	3035	0.0
05:00	SE TELHEIRO ANTIGA - AGG 108 - Cliente Agregador 1	Load	P (kW)	2664	3322	0.0
05:00	SE TELHEIRO ANTIGA - AGG 119 - Cliente Agregador 3	Load	P (kW)	3487	3807	0.0
06:00	SE TELHEIRO ANTIGA - AGG 108 - Cliente Agregador 1	Load	P (kW)	2698	3286	0.0
06:00	Cliente Agregador 2	Load	P (kW)	2784	3028	0.0
06:00	SE TELHEIRO ANTIGA - AGG 119 - Cliente Agregador 3	Load	P (kW)	3494	3755	0.0
09:00	PC VALE DE GALEGOS - STORAGE 01 - ARMAZENADOR	Storage	StateOfCharge (%)	50	26	0.0
09:00	SE TELHEIRO ANTIGA - AGG 119 - Cliente Agregador 3	Load	P (kW)	5063	4668	59.29

Figura 4.1: *GUI* elaborado para visualização dos resultados da previsão e da otimização

Na elaboração das tabelas de informação foi utilizado a biblioteca *PrimeFaces* [34], que possibilitou utilizar vários *templates* de recursos que foram necessários no decorrer da tarefa.

Para uma melhor percepção do resultado da previsão e da otimização ao longo do intervalo de tempo, assim como as informações que é possível obter desse mesmo intervalo, foi criado na parte superior da página 24 figuras circulares que representam os 24 períodos de um dia e possibilita ao utilizador escolher um deles para que seja possível, verificar o resultado da previsão assim como a da otimização da rede elétrica nesse intervalo. Na Figura 4.2 é demonstrado como este processo de escolha de um índice horário é apresentado e executado ao utilizador.




Period	Equipment Description	Equipment Type	Changes	Initial Position	Final Position	Cost
01:00	Cliente Agregador 2	Load	P (kW)	2784	2997	0.0
01:00	SE TELHEIRO ANTIGA - AGG 108 - Cliente Agregador 1	Load	P (kW)	2828	2901	0.0

Figura 4.2: Página *web* com índice horário escolhido

De forma a recuperar todos os dados dos 24 períodos é simplesmente executar o botão de "*All Periods*".


- **Tab Changed Equipment** - Referente aos movimentos propostos derivados da otimização da rede, verificado na Figura 4.3.



Period	Equipment Description	Equipment Type	Changes	Initial Position	Final Position	Cost
01:00	Cliente Agregador 2	Load	P (kW)	2784	2997	0.0
01:00	SE TELHEIRO ANTIGA - AGG 108 - Cliente Agregador 1	Load	P (kW)	2828	2901	0.0
02:00	Cliente Agregador 2	Load	P (kW)	2784	3038	0.0
02:00	SE TELHEIRO ANTIGA - AGG 108 - Cliente Agregador 1	Load	P (kW)	2706	3240	0.0
02:00	SE TELHEIRO ANTIGA - AGG 119 - Cliente Agregador 3	Load	P (kW)	3546	3757	0.0
03:00	SE TELHEIRO ANTIGA - AGG 119 - Cliente Agregador 3	Load	P (kW)	3517	3842	0.0
03:00	SE TELHEIRO ANTIGA - AGG 108 - Cliente Agregador 1	Load	P (kW)	2656	3306	0.0
03:00	Cliente Agregador 2	Load	P (kW)	2784	3043	0.0
04:00	SE TELHEIRO ANTIGA - AGG 119 - Cliente Agregador 3	Load	P (kW)	3471	3840	0.0
04:00	Cliente Agregador 2	Load	P (kW)	2784	3046	0.0
04:00	SE TELHEIRO ANTIGA - AGG 108 - Cliente Agregador 1	Load	P (kW)	2654	3396	0.0
05:00	Cliente Agregador 2	Load	P (kW)	2784	3035	0.0
05:00	SE TELHEIRO ANTIGA - AGG 108 - Cliente Agregador 1	Load	P (kW)	2664	3322	0.0
05:00	SE TELHEIRO ANTIGA - AGG 119 - Cliente Agregador 3	Load	P (kW)	3487	3807	0.0
06:00	SE TELHEIRO ANTIGA - AGG 108 - Cliente Agregador 1	Load	P (kW)	2698	3286	0.0
06:00	Cliente Agregador 2	Load	P (kW)	2784	3028	0.0
06:00	SE TELHEIRO ANTIGA - AGG 119 - Cliente Agregador 3	Load	P (kW)	3494	3755	0.0
09:00	PC VALE DE GALEGOS - STORAGE 01 - ARMAZENADOR	Storage	StateOfCharge (%)	50	26	0.0
09:00	SE TELHEIRO ANTIGA - AGG 119 - Cliente Agregador 3	Load	P (kW)	5063	4668	59.29

Figura 4.3: Página web - Tab Changed Equipments

- **Islands** - Resultados da potência total gerada, consumida, perda e custos globais da ilha afetada, aferido na Figura 4.4.



Period	Island	P Generated Final (MW)	P Consumed Final (MW)	Q Generated Final (MW)	Q Consumed Final (MW)	P Loss Initial (kW)	P Loss Final (kW)	Q Loss Initial (kVar)	Q Loss Final (kVar)	Cost Initial	Cost Final
01:00	REN CARVOEIRA	57.11	55.95	20.9	21.62	1671.89	1161.98	-671.25	-720.93	4869.33	4820.12
02:00	REN CARVOEIRA	55.37	54.26	19.79	20.69	1584.54	1116.87	-964.65	-903.68	4736.58	4767.48
03:00	REN CARVOEIRA	54.76	53.66	19.35	20.32	1555.45	1101.53	-1057.99	-961.6	4692.95	4751.44
04:00	REN CARVOEIRA	54.14	53.05	19.08	20.09	1537.72	1091.83	-1127.82	-1010.62	4660.2	4736.37
05:00	REN CARVOEIRA	54.67	53.56	19.37	20.31	1568.14	1114.01	-1037.49	-941.96	4760.34	4822.82
06:00	REN CARVOEIRA	54.78	53.65	19.52	20.43	1587.0	1125.17	-988.71	-913.35	4801.16	4890.51
07:00	REN CARVOEIRA	60.37	59.0	22.7	22.86	1894.95	1368.15	-72.34	-164.41	5503.8	5439.15
08:00	REN CARVOEIRA	70.14	68.24	27.9	26.49	2422.44	1897.51	1490.43	1404.79	6431.54	6368.33
09:00	REN CARVOEIRA	74.87	72.76	30.93	28.77	2843.48	2108.65	2703.85	2076.95	7118.02	7020.87
10:00	REN CARVOEIRA	75.15	73.04	31.08	28.87	2820.02	2109.26	2682.52	2117.11	7025.6	7057.3
11:00	REN CARVOEIRA	75.65	73.54	31.56	29.31	2888.86	2112.73	2885.32	2153.29	7119.28	7088.72
12:00	REN CARVOEIRA	75.42	73.31	31.25	29.03	2831.28	2107.41	2724.25	2125.18	7028.58	7015.96
13:00	REN CARVOEIRA	72.99	70.96	29.38	27.52	2561.44	2030.8	1946.0	1845.99	6590.67	6572.55
14:00	REN CARVOEIRA	74.39	72.34	30.07	28.05	2620.34	2054.17	2148.72	1954.58	6650.1	6573.47
15:00	REN CARVOEIRA	73.58	71.66	29.54	27.83	2465.37	1922.67	1815.12	1684.24	6166.44	6067.79
16:00	REN CARVOEIRA	73.32	71.46	29.29	27.7	2390.89	1860.45	1678.25	1581.19	5843.21	5727.29
17:00	REN CARVOEIRA	71.17	69.45	28.14	26.91	2244.52	1715.18	1322.68	1229.12	5260.97	5121.37
18:00	REN CARVOEIRA	70.94	69.23	28.09	26.84	2238.04	1707.82	1349.91	1254.31	4970.64	4814.99
19:00	REN CARVOEIRA	74.0	72.15	29.73	28.02	2397.87	1850.63	1818.45	1677.4	5997.87	5247.1

Figura 4.4: Página web - Tab Islands

Verifica-se nas Figuras 4.5 e 4.6 da página web o resultado da previsão, sendo estes os valores iniciais das *tabs* de cargas (*Loads*) e de geração (*Generators*) respetivamente:


Period	Equipment Description	Contracted Power (kVA)	P Initial (kW)	P Final (kW)	Q Initial (kVar)	Q Final (kVar)	V Initial (kV)	V Final (kV)
01:00	PT MFR 0253 RUA CAMINHO - CARGA - TP MT/BT 1	630.0	70.31	70.31	34.05	34.05	9.55	9.54
01:00	PTCS TORRES VEDRAS - PTC TVD 1113C000NNN - PTC TVD 0	500.0	45.74	45.74	32.61	32.61	29.89	30.79
01:00	PT TVD 0477 LAMCO DA AB - CARGA - TP MT/BT 1	400.0	72.42	72.42	51.63	51.63	29.85	30.75
01:00	PRE SERRA DEL REI - PAINEL SINTETICO - TP MT/BT	50.0	4.98	4.98	0.0	0.0	20.41	20.42
01:00	PT TVD 0064 GIBALTAR - CARGA - TP MT/BT 1	400.0	45.37	45.37	21.37	21.37	10.27	10.07
01:00	PT TVD 0216 CASAL FONTAI - CARGA - TP MT/BT 1	250.0	45.57	45.57	32.49	32.49	29.87	30.77
01:00	PT PNI 0178 FERREL (CAMI - AEREO - TP MT/BT 1	100.0	5.12	5.12	2.48	2.48	15.02	14.97
01:00	PT PNI 0089 PENICHE - CARGA - TP MT/BT 2	400.0	139.6	139.6	28.19	28.19	14.81	14.76
01:00	PTCS TORRES VEDRAS - PTC TVD 1113C132mm - PTC TVD 32	600.0	27.08	27.08	12.76	12.76	10.29	10.1
01:00	SE CABEDA - 315B TSA II - TP MT/BT 2	5000.0	0.0	0.0	0.0	0.0	30.41	31.31
01:00	PT SMA 0084 CASAS DE S - AEREO - TP MT/BT 1	160.0	16.58	16.58	5.74	5.74	9.75	9.71
01:00	PTCS LOURINHA - PTC LNH 1108C35mm - PTC LNH 5396 CA	300.0	16.48	16.48	7.98	7.98	29.73	30.63
01:00	SE ATUOLUGIA - TSA I - TRANSF SERV AUXILIARES-REACT NEUT	5000.0	1337.5	1337.5	180.55	180.55	29.66	30.55
01:00	PT TVD 0169 CASAL CAUJO - AEREO - TP MT/BT 1	100.0	11.32	11.32	5.33	5.33	10.25	10.06
01:00	PT MFR 0322 CHARNECA - CARGA - TP MT/BT 1	400.0	55.4	55.4	26.83	26.83	10.36	9.35
01:00	PT MFR 3872 S DOMINGOS F - AEREO - TP MT/BT 1	160.0	48.92	48.92	26.34	26.34	10.44	9.44
01:00	PTCS MAIRA - PTC MFR 1109C152mm - PTC MFR 5216 ENER	500.0	30.97	30.97	8.81	8.81	9.93	9.85
01:00	PT PNI 0078 PENICHE - CARGA - TP MT/BT 1	250.0	87.21	87.21	17.61	17.61	14.79	14.74
01:00	PT TVD 0687 CASAL PORTEL - AEREO - TP MT/BT 1	100.0	11.7	11.7	4.67	4.67	10.39	10.04

Figura 4.5: Página web - Tab Loads

Period	Equipment Description	Installed Power (kVA)	P Injected Initial (kW)	P Injected Final (kW)	Q Injected Initial (kVar)	Q Injected Final (kVar)	V Initial (kV)	V Final (kV)
01:00	PRE SERRA DA ESCUSA - PAINEL BT - GEN	2300.0	0.0	0.0	0.0	0.0	0.39	0.39
01:00	PTC MFR 5742 SODIMALVEIR	170.0	170.0	170.0	0.0	0.0	9.75	9.72
01:00	PRE VALE DE GALEGOS - PAINEL SINTETICO - (GENERATOR)	27950.0	510.71	510.71	0.0	0.0	20.16	20.16
01:00	PRE MFR 5537 PE S MAMED - PAINEL BT - GEN	8300.0	0.0	0.0	0.0	0.0	6.08	6.26
01:00	PRE AGROGER - PAINEL SINTETICO - GENERATOR	9280.0	3286.02	3286.02	0.0	0.0	6.24	6.24
01:00	PRE CABECO JARMELEIRA - PAINEL BT - GEN	2200.0	63.32	63.32	0.0	0.0	0.36	0.41
01:00	PRE TVD 0010 MARAVILHA 1 - PAINEL BT - GEN	1800.0	-269.25	0.0	0.0	0.0	0.37	0.42
01:00	PRE TVD 0020 MARAVILHA 2 - PAINEL BT - GEN	3600.0	99.67	99.67	0.0	0.0	0.37	0.42
01:00	PRE CATEFICA - PAINEL SINTETICO - GENERATOR	19350.0	329.26	329.26	0.0	0.0	20.72	20.72
01:00	PRE JOGUINHO II - PAINEL SINTETICO - GENERATOR	27950.0	270.56	270.56	0.0	0.0	20.85	20.85
01:00	PRE PARAQUE EOLICO DO PO - PAINEL SINTETICO - (GENERATOR)	9800.0	1395.99	1395.99	0.0	0.0	20.43	20.43
01:00	PTC TVD 5565 TLN - IMOBIL	40.0	40.0	40.0	0.0	0.0	29.88	30.78
01:00	PRE ALTO DA FOLGOROSA - PAINEL SINTETICO - (GENERATOR)	19350.0	187.08	187.08	0.0	0.0	20.85	20.86
01:00	PRE SERRA DEL REI - PAINEL SINTETICO - (GENERATOR)	22800.0	1777.82	1777.82	0.0	0.0	20.41	20.42
01:00	PRE TVD 4119 ENERSEDO - PAINEL BT - GEN	2100.0	781.88	781.88	0.0	0.0	0.4	0.41
02:00	PRE CATEFICA - PAINEL SINTETICO - GENERATOR	19350.0	269.23	269.23	0.0	0.0	20.72	20.72
02:00	PRE MFR 5537 PE S MAMED - PAINEL BT - GEN	8300.0	0.0	0.0	0.0	0.0	6.08	6.26
02:00	PRE ALTO DA FOLGOROSA - PAINEL SINTETICO - (GENERATOR)	19350.0	151.84	151.84	0.0	0.0	20.85	20.86
02:00	PRE AGROGER - PAINEL SINTETICO - GENERATOR	9280.0	3004.06	3004.06	0.0	0.0	6.24	6.24

Figura 4.6: Página web - Tab Generators

Existe também uma *tab* para cada tipo de equipamento, sendo estes os barramentos (*Busbars*), linhas de transporte (*Lines*), transformadores (*Transformers*) e armazenamento de energia (*storages*), sendo que as Figuras 4.7, 4.8, 4.9 e 4.10 correspondem aos equipamentos referidos:



Period	Equipment Description	V1 Final (kV)	V2 Final (kV)	Tap Initial	Tap Final	P1 Final (kW)	P2 Final (kW)	Q1 Final (kVar)	Q2 Final (kVar)	P Loss Initial (kW)	P Loss Final (kW)	Q Loss Initial (kVar)	Q Loss Final (kVar)
01:00	SE ATOUNGUA - 511 TP AT 3 - TRANSFORM	61.21	15.04	9	9	6437.91	-6425.75	2869.48	-2594.8	27.76	12.16	277.17	274.68
01:00	PRE TVD 4119 ENERSEIXO - SINTETICO - T	30.86	0.41	12	12	-782.33	782.67	-4.05	6.93	3.55	0.34	3.02	2.87
01:00	SE TORRES VEDRAS SUL - TP AT I - TP AT II	62.15	10.28	9	9	799.19	-798.56	2301.96	-2283.04	15.56	0.63	18.47	18.92
01:00	SE ATOUNGUA - 509 TP AT 1 - TP AT/MT 1	61.21	30.55	7	7	2334.85	-2334.37	437.81	-416.25	13.27	0.48	22.34	21.56
01:00	SE MAFRA - TP AT I - TP AT/MT 1A	59.16	9.86	0	0	295.33	-295.3	46.37	-45.9	11.26	0.03	10.92	0.47
01:00	SE CASALINHOS DE ALFAIAT - TP AT I - TP	61.28	10.07	11	11	4403.07	-4396.44	2319.63	-2180.26	15.48	6.63	133.64	139.36
01:00	SE LOURINHA - 504 TP AT I - TP AT/MT 1	61.59	30.73	7	7	1669.47	-1669.19	534.19	-522.6	13.77	0.28	12.1	11.59
01:00	SE MAFRA - TP AT II - TP AT/MT 2	59.16	9.84	0	0	690.49	-690.28	287.33	-284.42	9.72	0.21	2.96	2.91
01:00	PRE PARQUE EOLICO DO PO - 501 SEATO	61.26	20.43	12	12	-1352.73	1353.83	12.62	0.24	16.72	1.1	12.7	12.86
01:00	PRE CATEFICA - SINTETICO - TRANSFORM	62.15	20.72	12	12	-329.32	329.33	-1.47	1.76	17.18	0.01	0.27	0.29
01:00	SE TORRES VEDRAS SUL - TP AT II - TP AT	62.15	10.33	9	9	4825.7	-4821.52	611.77	-536.46	19.16	4.18	73.57	75.3
01:00	SE MAFRA - TP AT I - TP AT/MT 1	59.16	9.86	11	11	295.33	-295.3	46.37	-45.9	11.46	0.03	12.98	0.47
01:00	PRE SERRA DEL REI - 501 SEATOUNGUA PI	61.24	20.42	12	12	-1772.57	1773.05	4.97	4.89	19.22	0.48	9.71	9.86
01:00	PRE ALTO DA FOLGOROSA - SINTETICO -	62.54	20.86	12	12	-183.7	183.77	1.08	0.51	0.07	0.07	1.59	1.59
01:00	PRE CABECO JARMELEIRA - 101 SE MAFR	9.85	0.41	4	4	-61.28	63.32	0.17	0.0	2.28	2.04	0.17	0.17
01:00	SE TELHEIRO ANTIGA - 507 TRANSF POTE	59.51	9.84	15	15	5500.3	-5495.73	2394.42	-2278.5	19.95	4.58	105.46	115.92
01:00	SE MATACAES - TP MT II - TP AT/MT 2	62.54	31.01	7	7	9231.84	-9217.39	1910.36	-1568.66	33.39	14.45	335.66	341.7
01:00	PRE JOGUINHO II - P501 MATACAES - TP	62.54	20.85	12	12	-270.58	270.59	-0.68	0.9	19.56	0.01	0.2	0.22
01:00	PRE AGROGER - LN60 9011A-DOS-CUNH	62.25	6.24	12	12	-3228.7	3235.83	57.58	0.05	20.03	7.12	57.29	57.63

Figura 4.9: Página web - Tab Transformers

Period	Equipment Description	Nominal Active Power (kW)	State of Charge Initial (%)	State of Charge Final (%)	V Final (kV)
01:00	PC VALE DE GALEGOS - STORAGE 01 - ARMAZENADOR	2500.0	50	50	60.48
01:00	SE MATACAES - STORAGE 01 - ARMAZENADOR	2500.0	50	50	31.15
02:00	SE MATACAES - STORAGE 01 - ARMAZENADOR	2500.0	50	50	31.16
02:00	PC VALE DE GALEGOS - STORAGE 01 - ARMAZENADOR	2500.0	50	50	60.53
03:00	PC VALE DE GALEGOS - STORAGE 01 - ARMAZENADOR	2500.0	50	50	60.54
03:00	SE MATACAES - STORAGE 01 - ARMAZENADOR	2500.0	50	50	31.16
04:00	PC VALE DE GALEGOS - STORAGE 01 - ARMAZENADOR	2500.0	50	50	60.55
04:00	SE MATACAES - STORAGE 01 - ARMAZENADOR	2500.0	50	50	31.16
05:00	PC VALE DE GALEGOS - STORAGE 01 - ARMAZENADOR	2500.0	50	50	60.54
05:00	SE MATACAES - STORAGE 01 - ARMAZENADOR	2500.0	50	50	31.16
06:00	PC VALE DE GALEGOS - STORAGE 01 - ARMAZENADOR	2500.0	50	50	60.53
06:00	SE MATACAES - STORAGE 01 - ARMAZENADOR	2500.0	50	50	31.16
07:00	SE MATACAES - STORAGE 01 - ARMAZENADOR	2500.0	50	50	31.13
07:00	PC VALE DE GALEGOS - STORAGE 01 - ARMAZENADOR	2500.0	50	50	60.33
08:00	SE MATACAES - STORAGE 01 - ARMAZENADOR	2500.0	50	50	31.09
08:00	PC VALE DE GALEGOS - STORAGE 01 - ARMAZENADOR	2500.0	50	50	59.91
09:00	SE MATACAES - STORAGE 01 - ARMAZENADOR	2500.0	50	32	31.1
09:00	PC VALE DE GALEGOS - STORAGE 01 - ARMAZENADOR	2500.0	50	26	59.94
10:00	SE MATACAES - STORAGE 01 - ARMAZENADOR	2500.0	32	29	31.07

Figura 4.10: Página web - Tab Storages

De forma a popular as tabelas vistas nas Figuras anteriores com a informação correspondente a cada *tab*, foi elaborada uma *Application Programming Interface (API)* que evoca os serviços individuais correspondentes, verificado no Subcapítulo 3.6.

4.2 Algoritmo de previsão

Neste capítulo irá ser demonstrado a configuração do algoritmo referido no módulo 2 do Subcapítulo 3.4.

O algoritmo referido é o *Gradient Boosting (GB)* que por sua vez, é possível verificar um pequeno resumo deste algoritmo no Capítulo 2.


Neste algoritmo seguiu-se a ideologia de *Gradient Boosting Trees*, com a biblioteca *Python Sklearn* [35].

A configuração deste algoritmo, está presente na Listagem 4.1, sendo as respetivas variáveis usadas as seguintes:

```
1 {  
2     'learning_rate': 0.015,  
3     'min_samples_leaf': 0.01,  
4     'n_estimators': 600,  
5     'max_depth': 7,  
6     'min_samples_split': 0.015,  
7     'max_features': 'sqrt',  
8     'random_state': 1,  
9     'subsample': 0.8,  
10    "verbose": 0,  
11    "loss": "quantile",  
12    "quantiles": <QUANTILES>  
13 }
```

Listagem 4.1: Parâmetros do algoritmo *Gradient Boosting (GB)*

Um nó da árvore de decisão (*tree*) é um nó principal enquanto que um nó folha (*leaf*) é um nó terminal, podendo ser verificado na Figura 4.11.

Figura 4.11: Execução do algoritmo *Gradient Boosting (GB)* [36]

No qual é possível retirar a seguinte informação: Todas as figuras de azul são consideradas como nós principais pois a partir delas, existem outras subdivisões enquanto que, as figuras de coloração verde são nós folhas pois são nós terminais, que não existe divisão além destas. Verifica-se que não é possível existir mais divisões mesmo se o número de amostras para ser um nó folha o permitisse devido à configuração da variável *max_depth*, averigua-se o processo de divisão de nó árvore com o parâmetro *min_samples_split* assim como a criação dos nós folhas com a configuração de *min_samples_leaf* assim como, o seu critério de divisão denominado de *max_features* ter a sua influência com o número de características.

Na escolha dos valores dos hiperparâmetros do algoritmo *Gradient Boosting (GB)* é preciso ter atenção e serem testados pois, podem levar a instabilidades caso seja um valor demasiado elevado ou demasiado baixo no seu conjunto. Na explicação individual dos hiperparâmetros foi referido o que a instabilidade gere no modelo mas existe uma definição para cada uma destas instabilidades:

- **Overfitting** - Quando é utilizado um grande volume de informação para gerar um melhor conjunto de decisões este pode provocar uma instabilidade que é denominada de *overfitting* onde, o modelo poderá ser o mais completo pela grande quantidade de dados usados mas poderá usar ruído recolhido nos dados de amostras ou padrões não em conforme com o resto dos dados;
- **Underfitting** - Em contrapartida é utilizado um menor volume de dados podendo originar um modelo com menor ruído mas demasiado simplista que não consegue captar padrões importantes para as decisões.

Uma breve explicação de cada hiperparâmetro e qual é a sua faixa de valores para cada objetivo que o utilizador pretenda [35] [36] [37] [38] [39]:

- ***learning_rate***

Hiperparâmetro que possibilita o quanto é que cada *weak learner* irá contribuir, um número menor de *learning rate* implica que cada árvore (*tree*) irá ter menor influência na previsão final, sendo um parâmetro que controla o *step size*. Controla o quanto é que os erros (*weak learner*) dos modelos anteriores influenciam a convergência e performance, conseguindo escalar de forma a poder controlar as contribuições para o novo modelo.

Para uma melhor percepção foi elaborada a seguinte Equação 4.1, para cada iteração "*i*":

$$Modelo(i) = Modelo(i - 1) + learning_rate * WeakLearner(i) \quad (4.1)$$

Onde cada parâmetro da equação tem um propósito definido:

- Modelo(i) - Corresponde ao modelo atualizado após a adição de um novo *Weak Learner* na iteração "*i*";
- Modelo(i-1) - Equivale ao modelo na iteração anterior ("*i-1*");
- learning_rate - Representa o hiperparâmetro que controla o *step size*;
- WeakLearner(i) - É a nova previsão elaborada pelo *weak learner* na iteração "*i*".

É um valor entre [0 a 1] sendo que um valor menor implica mais iterações (converge de forma mais devagar) mas tende a gerar melhor estabilidade enquanto que um valor maior leva a um processo mais rápido mas pode gerar instabilidade (por exemplo, ruído existente que não seja de relevância para a convergência).

- ***min_samples_leaf***

Este hiperparâmetro controla o número mínimo de amostras necessárias para a criação de nós folhas (*leaf*).

O método de criação de nós implica na constante divisão da informação para provocar a criação dos mesmos, isto é uma técnica que melhora a performance do algoritmo.

Estes nós são de grande importância pois, consegue ajudar a prevenir ajustes em demasia ao controlar as complexidades de cada árvore (*tree*). Na criação de um nó folha se a divisão resultante possuir um menor número de amostras do que o valor do hiperparâmetro *min_samples_leaf*, essa divisão não é feita.

O processo é o seguinte: Na divisão para a criação de um nó, esta possui uma amostra de 0.001, esta divisão não se torna num nó de uma folha pois, o hiperparâmetro possui um valor de 0.01 que é um valor mínimo que cada amostra deve ter para ser considerada nó folha.

São valores entre [0.0 e 1.0] que representa o número mínimo de amostras de forma, a ser considerado um nó folha (nó terminal) na estrutura da árvore (*tree*). Um valor muito alto pode implicar grandes restrições na criação de árvores de decisão, resultando em árvores de decisão muito simples podendo não capturar padrões importantes, já se o valor for muito baixo ajusta melhor aos dados de treino mas com possível captura de ruído.

- ***n_estimators***

Número de *boosting* a efetuar, isto é, número de *weak learners* que irá influenciar o modelo atual com recurso ao modelo anterior e o hiperparâmetro de *learning_rate* para obter o modelo atualizado, verificar Equação 4.1.

Determina o número de modelos da floresta (árvores de decisão/iterações) que vão ser necessários para o modelo final. Este número de árvores é treinada individualmente com subconjuntos de informação.

Não existe um número máximo previsto para este parâmetro e por isso este varia entre [1 a ∞], tendo sempre em atenção na melhor escolha consoante as especificações existentes. Se o valor do hiperparâmetro for muito grande pode gerar modelos mais complexos que pode possibilitar a captura de padrões importantes na informação mas pode levar a um grande aumento no custo computacional e poderá provocar instabilidade se o conjunto de informação for de dimensão reduzida.

- ***max_depth***

Limita a profundidade que cada árvore de decisão têm no conjunto final, esta profundidade tem como base o número de camadas desde os nós das árvores de decisão até aos nós das folhas.

O valor não possui restrição, podendo ser entre [1 a ∞]. Um grande valor traduz nas árvores de decisão individuais serem mais "*profundas*" e capturarem melhores padrões mas poderão também capturar maior ruído e possuem maior custo computacional, no entanto, se o valor for demasiado baixo implica a serem árvores de decisão mais simples e menos profundas o que pode resultar a não conseguirem recolher os padrões importantes.

O risco de instabilidade pode ser reduzido mesmo com um valor de hiperparâmetro elevado porque, o modelo final é um conjunto de previsões de várias árvores individuais com diferentes padrões e subconjuntos de informações.

- ***min_samples_split***

Hiperparâmetro que é responsável pelo o controlo do número mínimo de amostras necessárias na divisão das construções de árvores de decisão para a criação de nós árvore.

Por forma a ser possível dividir, o algoritmo verifica se o número de amostras é maior que o valor do hiperparâmetro *min_samples_split*. Se acontecer esta divisão é criado um nó árvore, caso não aconteça esta divisão transforma-se em nó folha.

Os valores deste hiperparâmetro variam entre [0.0 a 1.0]. Um maior valor implica a construção de árvores de decisão com maiores tamanhos de amostras, árvores que são mais sucintas a reterem melhor os padrões mas poderão conter ruído e outras amostras indesejadas. Um menor valor possibilita a construção de árvores de decisão mais simples mas pode não capturar padrões importantes, o custo computacional aumenta e a sua eficiência computacional é diminuída devido a ser preciso um maior número de divisões.

Existe uma paralelidade sobre os hiperparâmetros *min_samples_leaf* e este em concreto, enquanto que o primeiro é usado com base a evitar a criação de nós de folhas com dimensões muito reduzidas (focado no controlo dos nós folhas), já no segundo é utilizado como forma de controlar a complexidade das árvores de decisão limitando criar nós com dimensões pequenas (controlo de nós árvore de decisão).

- ***max_features***

Indica qual é a característica que é necessária verificar quando é decidido a melhor divisão para os *weak learners*.

O número de recursos é referente aos atributos do conjunto de informação que foi introduzida no algoritmo por forma a fazer a sua previsão. Estes atributos são características da rede elétrica, as suas respetivas variáveis e valores da previsão meteorológica.

O algoritmo do modelo possibilita o treino de cada árvore de decisão com uma escolha aleatória na característica com base nos números de recursos que irá utilizar. Com esta possibilidade de aleatoriedade é possível verificar que existe uma grande diversidade nas árvores de decisão resultantes e com tal, averigua-se um melhor desempenho com uma possível redução na eventual existência em sobreajuste nos conjuntos.

O valor deste hiperparâmetro pode ser inteiro e que no qual, será esse número de recursos que irá ser utilizado, enquanto que se for de valor fracionário, a lógica mantém-se e será o valor fracionário dos recursos que irá ser utilizado. Se o valor for baixo pode ajudar no controlo da complexidade da construção

das árvores de decisão, reduzir o custo computacional e ser mais rápido no treino. Um valor alto deste hiperparâmetro pode ser utilizado quando é interligado com outros hiperparâmetros de forma a reduzir a instabilidade, devido à possível existência de ruído nas árvores de decisão mais complexas.

Um exemplo é: Se for utilizado o valor de *"sqrt"* o algoritmo calcula a raiz quadrada do número total de recursos do conjunto de informações existentes e que no qual será o valor utilizado na divisão para a construção das árvores de decisão, conseguindo introduzir assim aleatoriedade no processo.

- ***random_state***

É responsável pela aleatoriedade ou consistência que é fornecida a cada estimador de árvore (*tree*) de forma a garantir a sua reprodução, além de conseguir controlar a permutação dos recursos em cada divisão.

Este controlo de consistência é possível ao definir o hiperparâmetro com um valor inteiro, manipulando a sua reprodução a produzir as mesmas decisões nas suas várias execuções, certificando que outras condições não são alteradas, conseguindo assim fazer comparações entre os vários modelos resultantes.

Se não for um valor consistente poderá ter um custo computacional que não se justifique.

- ***subsample***

Valores entre [0.0 a 1.0] onde controla a fração de amostras de treinamento que irá ser usada para treinar cada árvore individual, um valor de 0.8 neste hiperparâmetro traduz-se em que 80% dos dados irão ser usados para treinar as árvores individuais.

Ao fazer a seleção dos dados que irá ser usada no treinamento das árvores individuais introduz aleatoriedade que pode melhorar o desempenho do modelo. Esta seleção pode ser benéfica quando se obtém um grande volume de dados de informações de treinamento e pode ser feita uma melhor separação dos dados que podem ser usados para treinamento das árvores de decisão dos dados que possam ter ruído captado na recolha de dados.

Um valor menor introduz menor variabilidade entre as várias árvores de decisão do conjunto pois é usado um menor valor de dados de treinamento o que pode implicar a árvores de decisão muito semelhantes entre si, enquanto que um valor alto inclui alta variabilidade pois está exposta a mais conjuntos de dados, o que leva à obtenção de árvores de decisão mais diversificadas mas poderá levar à instabilidade pois poderá usar dados que possam incluir ruído no conjunto.

- ***verbose***

Hiperparâmetro que controla a informação exibida durante as várias iterações de treinamento.

Os valores vão de $[0 \text{ a } \infty]$, sendo que um número maior providencia uma informação mais completa sobre o processo de treino.

- ***loss***

Função de perda que irá ser otimizada como indicador de medição de qualidade durante o treino das árvores de decisão, existem múltiplas funções que podem ser usadas como a *Mean Absolute Error (MAE)*, entre outras.

Ao usar no hiperparâmetro a função *Quantile Regression (QR)*, implica que o objetivo da função de perda é a estimação dos quantis da distribuição, isto é, otimização dos parâmetros por forma a mitigar os erros de quantil para o quantil escolhido no parâmetro $\leq \text{QUANTILES} \geq$ (minimizar a diferenciação entre quantil da distribuição e o quantil previsto), que por sua vez é de natureza dinâmica e configurável. Com esta configuração é possível a criação de vários modelos onde, cada um deles possui um valor de quantil diferente para várias outras estimações.

Os valores que poderiam ser escolhidos variam entre $[0.0 \text{ a } 1.0]$, sendo que é usual usar os valores de 0.25 (quantil baixo ou $Q1$), 0.50 (quantil mediano ou $Q2$) e o 0.75 (quantil alto ou $Q3$). Caso seja usado o valor de 0.25, implica que está a ser estimado o 25º quantil da distribuição, isto é, indica que a estimação dos valores irá fazer previsões com base em 25% do limite inferior do conjunto de dados.

Se na escolha de valores para um hiperparâmetro resultar em instabilidade, neste caso pode ser combatido com a variação noutro hiperparâmetro por forma a ser possível mitigar esta instabilidade e conseguir estabilizar o processo de previsão.

A previsão para cada tipo de potência existente (P e Q) demora cerca de 2 segundos após o modelo ter sido previamente treinado, que é algo pressuposto para uma melhor eficácia da utilização da previsão proveniente deste algoritmo.

4.3 Síntese analítica

Na demonstração dos resultados foi utilizado uma página *web*, de forma a ser possível tornar uma vista de mais fácil de percepção. A página *web* irá demonstrar os resultados de um *Multi-Period Optimal Power Flow (MOPF)* e os resultados provenientes da previsão das cargas e de geração.

Foi uma tarefa bastante desafiadora e enriquecedora devido a todas metodologias e tecnologias que estes tipos de encargos possuem nesta área.

O algoritmo *Gradient Boosting (GB)* é muito utilizado nas tarefas de previsão e na pesquisa sobre ele, verificou-se que é mais abrangente do que no início é apresentado, como por exemplo, nas escolhas dos valores dos hiperparâmetros é de extrema importância para averiguar se o modelo se comporta com o devido objetivo e que é possível fazer combinações entre estes hiperparâmetros, por forma a conseguir mitigar algumas instabilidades que possam surgir na escolha das variáveis iniciais.

Capítulo 5

Análise e interpretação de resultados

Neste capítulo irá ser demonstrado os resultados da previsão do projeto Grid's Predictive Management Considering Distributed Energy Resources (GPDER) assim como, algumas particularidades acerca do esforço computacional existente para esta previsão.

5.1 Análise de Resultados

Foram analisados os resultados provenientes da previsão de cargas e de geração, mais propriamente da utilização do algoritmo *Gradient Boosting* (GB) onde, é possível verificar uma explicação mais aprofundada sobre os hiperparâmetros e que valores foram utilizados no Subcapítulo 4.2. No Subcapítulo 4.1 é possível verificar nas Figuras 4.5 e 4.6 alguns resultados da previsão nos respectivos campos de valores iniciais.

A base desta análise tem em conta os parâmetros definidos no módulo 3 do Subcapítulo 3.4. Foram demonstrado as várias *Key Performance Indicator* (KPI) onde, *Mean Absolute Error* (MAE) e *Root Mean Squared Error* (RMSE) avaliam a previsão de cargas e da geração e o *Continuous Ranked Probability Score* (CRPS) a previsão probabilística.

Foi dividido em duas partes onde, na Tabela 5.1 é indicado as previsões das cargas e a Tabela 5.2 demonstra os resultados da previsão da geração das energias renováveis.

Tabela 5.1: Resultado de Previsão de Cargas

Intervalo da previsão	Potência Ativa			Potência Reativa		
	<i>MAE</i>	<i>RMSE</i>	<i>CRPS</i>	<i>MAE</i>	<i>RMSE</i>	<i>CRPS</i>
1h - 24h	5.64	9.41	4.18	7.52	11.88	5.63
25h - 48h	5.99	9.90	4.43	8.47	13.14	6.36
49h - 72h	6.16	10.14	4.57	8.53	13.23	6.42

Tabela 5.2: Resultado de Previsão de Geração das Energias Renováveis

Intervalo da previsão	Potência Ativa			Potência Reativa		
	<i>MAE</i>	<i>RMSE</i>	<i>CRPS</i>	<i>MAE</i>	<i>RMSE</i>	<i>CRPS</i>
1h - 24h	10.08	14.75	7.51	14.77	22.26	10.99
25h - 48h	11.42	16.46	8.54	15.29	22.82	11.41
49h - 72h	12.43	17.76	9.31	15.58	23.13	11.62

Como é possível verificar pelas tabelas anteriores o horizonte temporal possível é de cerca de até 72 horas depois, verificar o Subcapítulo 3.5.2.

O erro na previsão tende a aumentar consoante o aumento no intervalo temporal da previsão, sendo lógico devido a fazer mais estimações sobre os valores e mais cálculos computacionais devido a não serem informações das medidas mais recentes. Verifica-se também que os erros da Potência Ativa são geralmente menores que as da Potência Reativa pois, nesta última a rede elétrica tem um maior impacto com os equipamentos que possui.

A previsão das cargas tende a ter um erro gradual menor do que o das energias renováveis pois, é uma operação que não atribui um peso substancial às variáveis dependentes dos valores meteorológicos, averiguando de forma mais perceptível a importância destas variáveis meteorológicas na Figura 5.2.

Na figuras seguintes é exemplificado com gráficos visuais sobre as curvas que cada *quantil* influencia o modelo final de previsão.

Na Figura 5.1 é possível verificar a previsão das cargas para uma execução no dia 19 de junho de 2018 às 00h:00m e com um horizonte temporal de 72h.




Figura 5.1: Resultados da previsão de carga

Verifica-se que o *quantil q50* se apresenta como uma mediana dos outros *quantis* e fixa-se com uma previsão mais centrada enquanto que o *quantil q05* se foca mais no limite inferior e o *quantil q95* no limite superior do conjunto de informação, sendo mais notório a diferenciação dos limites inferior e superior aquando a previsão da potência reativa (Gráfico da potência reativa) existe uma maior distância entre o *q95* e *q50* do que *q50* e o *q05*, devido à influência que a rede elétrica e dos equipamentos têm, mostrando-se menos linear que a potência ativa.

Na Figura 5.1 é possível verificar duas previsões de energia renovável, uma execução no dia 4 de outubro de 2018 às 00h:00m com a meteorologia sem impacto nas variáveis da previsão e outra execução no dia 1 de novembro de 2018 às 00h:00m com uma meteorologia que impacta diretamente as variáveis da previsão e ambas com um horizonte temporal de 72h.




Figura 5.2: Resultados da previsão de energia renovável

Foi elaborado duas previsões de geração de energia renovável para ser perceptível que os valores meteorológicos (provenientes de uma outra previsão meteorológica, módulo 4 do Subcapítulo 3.4) possuem um peso substancial nos valores da previsão e com isso, verifica-se uma maior diferença entre os *quantis*.

Como esta previsão é auxiliada por esforço computacional foi também analisado como é que era possível fazer mais rapidamente a previsão ao adicionar mais máquinas.

Em termos de esforço computacional, foi analisado um cenário de teste igual para todas as execuções mas variando o número de máquinas que executam a previsão, como é possível averiguar na Tabela 5.3 e no gráfico na Figura 5.3.

Tabela 5.3: Esforço Computacional na Previsão

Número de máquinas	Tempo de Execução (s)
1	1536
2	835
3	586
4	449




Figura 5.3: Número de máquinas e tempo de execução (s)

Com base na Tabela 5.3 e Figura 5.3 é possível escalar horizontalmente o cenário de redução de esforço computacional, pelo simples facto de possuir só uma base de dados e ser o *bottleneck* nesse cenário, por mais que seja possível adicionar mais máquinas.

5.2 Sumário da Análise de Resultados

Neste subcapítulo elaborou-se uma análise sobre os resultados provenientes da previsão quer de cargas quer da geração de energia.

Verifica-se que a previsão tende a ter uma agravante nos indicadores de qualidade (*Key Performance Indicator (KPI)*) quando o seu intervalo temporal se tende a estender até ao limite do horizonte temporal de 72h, isto porque, como já não é possível obter as medidas mais recentes é feita mais estimações e cálculos computacionais que influenciam o valor final do modelo. A previsão da Potência Reativa também se verifica com um valor maior de erro que a Potência Ativa devido às condições que a rede elétrica possui fazerem variar a potência em questão. Na previsão de geração é averiguado que existe uma forte influência da meteorologia presente na rede para o modelo final, modificando por completo a perspetiva e o resultado aquando comparado com uma previsão com uma meteorologia diferente.

No cálculo da previsão é previsto que todos os processos presentes nos Subcapítulos 3.4, 3.5 e 4.2 têm impacto no tempo de duração da previsão e por isso, foi elaborada várias repetições com os mesmos parâmetros com número de máquinas diferente, podendo assim analisar o efeito que mais máquinas têm e verificou-se que é escalado horizontalmente, isto é, um aumento exaustivo do número de máquinas

não se reflete em geral numa diminuição substancial do tempo de cálculo da previsão, uma das formas de diminuição deste tempo poderá ser no aumento do número de bases de dados presentes nos processos.

Capítulo 6

Conclusão

6.1 Análise Conclusiva

O trabalho referente visa demonstrar as dificuldades existentes numa rede elétrica atual e por forma a mitigar alguns destes problemas, foi criado o projeto *Grid's Predictive Management Considering Distributed Energy Resources (GPDER)*.

São referidos vários algoritmos e técnicas de previsão utilizados no mercado de energia onde, continuam a ser sujeitos a vários casos de uso que tornam possível a sua contínua otimização para um mundo em permanente mudança.

A tese de exemplo elabora o projeto *Grid's Predictive Management Considering Distributed Energy Resources (GPDER)* e os componentes necessários a fim de demonstrar o processo de previsão onde, foi um módulo integral para a execução deste projeto pois, foi ponto de partida para posteriormente com os resultados desta previsão, ser possível otimizar a rede elétrica a estudar. Os sistemas presentes possuem várias tecnologias que são utilizadas nos dias de hoje no mundo empresarial assim como, sistemas elaborados pela empresa portuguesa *Efacec Power Solutions (EFACEC)* que são usadas em múltiplos clientes nacionais e internacionais.

A rede elétrica foi bem caracterizada tendo o seu trânsito de potências a dar resultados similares aos valores reais telemetrados que indica que as características elétricas foram bem capturadas. Foram considerados na rede elétrica o Produtor em Regime Especial (PRE) de forma, a fazer uma comparação mais realista da rede elétrica existente, estes produtores têm uma particularidade podendo ser equipamentos

geradores de energia elétrica mas também equipamentos consumidores consoante os seus contratos energéticos com as empresas autorizadas.

A arquitetura composta este projeto é de natureza complexa a fim de ser possível minimizar todos os impactos externos que possam causar numa previsão eficaz e eficiente. No âmbito do processamento da previsão foram referidos vários módulos necessários a fim de ser feita uma previsão eficiente. Existência de uma continua comunicação entre a *streamline* do *Open-source Distributed Event Streaming Platform (Kafka)* com a *Supervisory Control and Data Acquisition (SCADA)* para recolha e escrita dos valores mais recentes providenciados pela telemetria. Utilização do algoritmo *Gradient Boosting (GB)* por forma a fazer todo o cálculo da previsão com especial atenção nos parâmetros escolhidos. Elaboração de vários indicadores sobre a qualidade dos dados recebidos e transmitidos, conseguindo assim fazer uma medição sobre a eficácia das informações envolvidas. Recolha numérica da previsão meteorológica com a finalidade de serem usadas como *inputs* para a previsão de cargas e de geração de energia elétrica. Uso de uma *Representational State Transfer (REST) Application Programming Interface (API)* com a intenção de poder fazer mudanças nos vários módulos de forma, a ser possível fazer uma configuração do sistema, assim como, verificar as medições de *Key Performance Indicator (KPI)* e resultados da previsão, entre outros.

O ambiente do pólo foi bem construído fazendo a modelização com os componentes *Distribution Management System (DMS)* e *Supervisory Control and Data Acquisition (SCADA)*, fazendo capturas ajustes na telemetria recebida. O servidor elaborado para as aplicações de energia carrega as características da rede e do resultado da previsão de cargas e de geração, fazendo cálculos elétricos e validações resultando na otimização da rede elétrica. Verificou-se que as medidas *Supervisory Control and Data Acquisition (SCADA)* chegavam ao servidor e que este conseguia comunicar com o servidor da previsão.

Construiu-se um sistema funcional e integrado com a visualização dos resultados de previsão e da otimização provenientes dos vários módulos executados numa página *web*. No campo dos parâmetros e da escolha do algoritmo *Gradient Boosting (GB)* foram feitas várias diligências com todas as empresas participantes do projeto *Grid's Predictive Management Considering Distributed Energy Resources (GPDER)*.

Após de todas as execuções necessárias para uma previsão eficaz é possível verificar que os resultados possuem valores de *Mean Absolute Error (MAE)*, *Root Mean Squared Error (RMSE)* e *Continuous Ranked Probability Score (CRPS)* que aumentam consoante o aumento do horizonte temporal da previsão, que era algo previsível porque, não estariam a ser usados os valores mais recentes da telemetria e os dados estariam a serem sujeitos a várias estimações que introduz um aumento no erro percentual. No âmbito das previsões das cargas é de notar que existe uma diferenciação entre a potência ativa e a potência reativa onde, foi analisado e conclui-se que devido

à natureza dos equipamentos na rede elétrica a estudar esta tem um impacto direto na potência reativa, o que perfaz um aumento no erro. Na previsão da geração o valor do erro é notoriamente maior que o das previsões de cargas pois, esta tem *inputs* que são influenciados pela previsão numérica meteorológica que se faz notar quando se compara a previsão gerada em dias com valores meteorológicos diferentes.

Em suma, foi dedicado muito tempo de aprendizagem ao projeto *Grid's Predictive Management Considering Distributed Energy Resources (GPDER)* devido à introdução de novas tecnologias que permitiram adquirir conhecimentos nas mesmas. Foram feitas várias reuniões com as empresas parceiras no projeto a fim de, ser modelado o projeto e a arquitetura da solução a todas as vertentes do objetivo final, fazendo todo este processo uso dos sistemas da *Efacec Power Solutions (EFACEC)* assim como, das tecnologias utilizadas no dia a dia da empresa. As previsões obtiveram um valor de erro bastante baixo conseguindo identificar quais e o porque de existirem diferenças numéricas entre as várias potências e entre a previsão de cargas com a previsão da energia gerada.

6.2 Perspetivas futuras

No âmbito hipotético da redução dos tempos de cálculo é possível existir uma redução maior ao criar mais base de dados para uma comunicação em paralela, a fim de ser escrito e lidos os valores mais rapidamente, traduzindo assim numa execução de previsão mais rápida.

Um dos pontos da elaboração de todo este projeto *Grid's Predictive Management Considering Distributed Energy Resources (GPDER)* é poder ser um produto vendido pela *Efacec Power Solutions (EFACEC)*, a fim de complementar os sistemas já existentes e melhorar os componentes de gestão elétrica das redes podendo assim, criar um valor económico maior à empresa e de mais interesse por parte dos clientes novos ou até clientes que já utilizam o sistema atual.

É um produto que transmite uma melhor gestão da rede elétrica e por isso, deve ser moldada a todos os sistemas transversais existentes para que, possa ser usado em múltiplos clientes de forma a verificarem uma melhor previsão e com isso, ser possível existir uma redução nos custos de manutenção e de produção mas também na quantidade de energia importada e, aumentar o nível de exportação que poderá ser benéfico para as empresas distribuidoras e que possa resultar numa tradução de maior lucro para as mesmas empresas.

Referências

- [1] “The next generation of adms functions for predictive management of der,” in CIREN 2023, no. 10375, (Rome, Italy), CIREN - International Conference on Electricity Distribution, June 2023. [Citado na página 2]
- [2] CIREN, “Cired 2023 international conference exhibition on electricity distribution,” Jun. 2023. [Citado na página 2]
- [3] K.-B. Song, Y.-S. Baek, D. H. Hong, and G. Jang, “Short-term load forecasting for the holidays using fuzzy linear regression method,” IEEE Transactions on Power Systems, vol. 20, no. 1, pp. 96–101, 2005. [Citado nas páginas 5, 6 e 10]
- [4] O. Babayomi, Z. Zhang, T. Dragicevic, J. Hu, and J. Rodriguez, “Smart grid evolution: Predictive control of distributed energy resources—a review,” International Journal of Electrical Power Energy Systems, vol. 147, p. 108812, 2023. [Citado na página 6]
- [5] R. S. Anurag, “Load forecasting by using anfis,” International Journal of Research and Development in Applied Science and Engineering, vol. 20, no. 1, 2020. [Citado nas páginas 6 e 17]
- [6] A. A. Mamun, M. Sohel, N. Mohammad, M. S. Haque Sunny, D. R. Dipta, and E. Hossain, “A comprehensive review of the load forecasting techniques using single and hybrid predictive models,” IEEE Access, vol. 8, pp. 134911–134939, 2020. [Citado nas páginas vii, 6 e 7]
- [7] A. Altunkaynak, “Sediment load prediction by genetic algorithms,” Advances in Engineering Software, vol. 40, no. 9, pp. 928–934, 2009. [Citado nas páginas vii, ix, 8, 10, 11, 20 e 21]
- [8] S. K. Aggarwal, L. M. Saini, and A. Kumar, “Electricity price forecasting in deregulated markets: A review and evaluation,” International Journal of Electrical Power Energy Systems, vol. 31, no. 1, pp. 13–22, 2009. [Citado nas páginas vii, 8 e 9]
- [9] Z. Yun, Z. Quan, S. Caixin, L. Shaolan, L. Yuming, and S. Yang, “Rbf neural network and anfis-based short-term load forecasting approach in real-time price environment,” IEEE Transactions on Power Systems, vol. 23, pp. 853–858, Aug 2008. [Citado nas páginas vii, 9, 16, 17 e 21]

-
- [10] P. Vadapalli, “6 types of regression models in machine learning you should know about,” 2022. 03,17,2023. [Citado na página 10]
- [11] V. K. Mishra, V. Bajaj, A. Kumar, D. Sharma, and G. Singh, “An efficient method for analysis of emg signals using improved empirical mode decomposition,” AEU - International Journal of Electronics and Communications, vol. 72, pp. 200–209, 2017. [Citado nas páginas vii e 12]
- [12] S. Ho and M. Xie, “The use of arima models for reliability forecasting and analysis,” Computers Industrial Engineering, vol. 35, no. 1, pp. 213–216, 1998. [Citado na página 13]
- [13] B. Doucoure, K. Agbossou, and A. Cardenas, “Time series prediction using artificial wavelet neural network and multi-resolution analysis: Application to wind speed data,” Renewable Energy, vol. 92, pp. 202–211, 2016. [Citado na página 13]
- [14] G. Zhang, “Time series forecasting using a hybrid arima and neural network model,” Neurocomputing, vol. 50, pp. 159–175, 2003. [Citado na página 13]
- [15] A. K. Alexandridis and A. D. Zaprakis, “Wavelet neural networks: A practical guide,” Neural Networks, vol. 42, pp. 1–27, 2013. [Citado na página 14]
- [16] B. D. Baker and C. E. Richards, “A comparison of conventional linear regression methods and neural networks for forecasting educational spending,” Economics of Education Review, vol. 18, no. 4, pp. 405–415, 1999. [Citado na página 14]
- [17] J. Liu, P. Li, X. Tang, J. Li, and J. Chen, “Research on improved convolutional wavelet neural network,” Scientific Reports, vol. 11, p. 17941, Sep 2021. [Citado na página 14]
- [18] sciencedirect, “Foraging behavior,” 2022. 03,19,2023. [Citado na página 15]
- [19] L. Wang, S.-X. Lv, and Y.-R. Zeng, “Effective sparse adaboost method with esn and foa for industrial electricity consumption forecasting in china,” Energy, vol. 155, pp. 1013–1031, 2018. [Citado na página 15]
- [20] Q.-K. Pan, H.-Y. Sang, J.-H. Duan, and L. Gao, “An improved fruit fly optimization algorithm for continuous function optimization problems,” Knowledge-Based Systems, vol. 62, pp. 69–83, 2014. [Citado na página 15]
- [21] J. Zhang, Y.-M. Wei, D. Li, Z. Tan, and J. Zhou, “Short term electricity load forecasting using a hybrid model,” Energy, vol. 158, pp. 774–781, 2018. [Citado nas páginas 15 e 22]

-
- [22] A. M. Coroiu, “Fuzzy methods in decision making process - a particular approach in manufacturing systems,” IOP Conference Series: Materials Science and Engineering, vol. 95, p. 012154, oct 2015. [Citado na página 16]
- [23] J. Hoare, “Gradient boosting explained – the coolest kid on the machine learning block,” 2017. 02,27,2023. [Citado na página 17]
- [24] A. Pal, “Gradient boosting trees for classification: A beginner’s guide,” 2023. 02,27,2023. [Citado nas páginas vii, 17, 18 e 19]
- [25] A. Kumar, “Gradient boosting algorithm: Concepts, example,” 2022. 21,06,2023. [Citado nas páginas vii, 17 e 19]
- [26] J. Hoare, “Predict customer churn with gradient boosting,” 2018. 03,17,2023. [Citado na página 18]
- [27] A. Menegaki, “Chapter 6 - quantile regression approach: A new approach in the energy-growth nexus with substantial benefits in asymmetry accounting,” in A Guide to Econometrics Methods for the Energy-Growth Nexus (A. Menegaki, ed.), pp. 127–148, Academic Press, 2021. [Citado na página 19]
- [28] C. Wan, J. Lin, J. Wang, Y. Song, and Z. Y. Dong, “Direct quantile regression for nonparametric probabilistic forecasting of wind power generation,” IEEE Transactions on Power Systems, vol. 32, no. 4, pp. 2767–2778, 2017. [Citado na página 19]
- [29] Y. Akdi, E. Gölveren, and Y. Okkaoğlu, “Daily electrical energy consumption: Periodicity, harmonic regression method and forecasting,” Energy, vol. 191, p. 116524, 2020. [Citado na página 20]
- [30] B. Yegnanarayana, Artificial neural networks. PHI Learning Pvt. Ltd., 2009. [Citado na página 21]
- [31] R. H. Byrd, J. Nocedal, and R. A. Waltz, Knitro: An Integrated Package for Nonlinear Optimization, pp. 35–59. Boston, MA: Springer US, 2006. [Citado na página 22]
- [32] J. Chen, J. Wu, M. Luo, and J. Zhang, “A knitro-based real-time locomotion method for imitating the caterpillar-like climbing strategy,” in 11th IEEE International Conference on Control Automation (ICCA), pp. 145–150, 2014. [Citado na página 22]
- [33] MeteoGalicia, “Servidor thredds de meteogalicia,” 2023. 20,06,2023. [Citado na página 46]
- [34] PrimeTek, “Getting started,” 2023. 15,05,2023. [Citado na página 62]

- [35] scikit-learn developers, “sklearn.ensemble.gradientboostingregressor,” 2023. 05,07,2023. [Citado nas páginas 67 e 69]
- [36] A. Jain, “Complete machine learning guide to parameter tuning in gradient boosting (gbm) in python,” 2022. 06,07,2023. [Citado nas páginas viii, 68 e 69]
- [37] M. B. Fraj, “In depth: Parameter tuning for gradient boosting,” 2017. 06,07,2023. [Citado na página 69]
- [38] J. Brownlee, “How to configure the gradient boosting algorithm,” 2016. 06,07,2023. [Citado na página 69]
- [39] ritvikmath, “Gradient boosting : Data science’s silver bullet,” Set. 2021. [Citado na página 69]

Anexo A

Scatex

Características do produto *Sistema SCADA/ADMS (SCATEX)*.



Network Manager

SCATEX^{SCADA}

SCATEX^{DMS}

SCATEX^{EMS}

SCATEX^{OMS}

SCATEX^{ADMS}

SCATEX^{RAIL}

Overview

ScateX# is the unified, yet modular Efacec ADMS, result of more than 30 years of experience in the grid automation. Designed to combine SCADA, Distribution Management System (DMS) and Outage Management System (OMS) capabilities under a single, multi-language platform with a unified user experience, enables utilities to manage the grid for high, medium and low voltage levels with maximum security and return of investment.

Grid dispatcher operators are facing new operational challenges to maintain the same levels of safety in operation while increases the penetration of renewable-based production (mainly wind and solar base) in the different voltage levels of distribution network and the integration in the grid of new distributed resources with flexibility in the control of active and reactive power, electric vehicles, energy storage and controllable loads, coupled with emerging business models (aggregators and flexible operators) that provides the necessary flexibility to the grid.

At the same time, the installation of Advanced Metering Infrastructures (AMI) systems and the increase of network distribution automation provided new strategies of monitoring and control of the distribution network.

ScateX# was designed having modularity as a priority. This enables flexible deploys as single SCADA, single DMS, single OMS or as a fully ADMS either for high voltage, medium voltage or low voltage, protecting the client investment for future evolution of the system.

ScateX# is built upon a real-time cybersecure infrastructure and includes many innovative features that provide quick and easy access to real-time information, improving situational awareness and readily providing enhanced decision support. The set of network, power and outage management applications further leads to efficient operation and network optimization.

Featuring openness, flexibility, expandability and performance, ScateX# can scale to meet the needs of large networks and infrastructures, enabling customers to leverage stepwise investment strategies. Moreover ScateX# can be tailored to meet the specific needs of each user to deliver unmatched cost/benefit solutions.

Recognizing that straightforward deployment, integration and maintenance is a fundamental requirement, ScateX# presents end-to-end engineering and management of the whole infrastructure from control room, through communications infrastructure and remote plant or field equipment. Moreover ScateX# includes a complete solution for operator training that enables you to maintain operator team readiness.



Key Features

- Fully integrated SCADA/DMS/OMS platform
- Unified and powerful operations user interface
- Flexible realtime dashboard
- Full set of power management applications
- Full set of outage management applications
- Realtime centralized FDIR
- Realtime mobile integration
- Communication network infrastructure monitoring and management
- Electric vehicle charging infrastructure monitoring and management
- Report designer and server
- Modules to help infrastructure commissioning using test workflows engine
- Energy module to execute LV power flow using energy network configuration
- Operator training system
- System historian
- Flexible and scalable platform
- Open and modular infrastructure
- Advanced engineering system
- Seamless application and systems integration
- High availability and cyber-secure product platform



Benefits

- Immediate situation awareness and intuitive real-time operation
- Improved system reliability and network SAIDI reduction
- Improved network operational efficiency
- Optimised crew/operator maintenance productivity
- Straightforward deployment, integration and maintenance
- Deliver real-time process and operations information throughout the organization
- Tailor-made solutions to meet the exact needs of each project




Overview of ScateX# Standard Product Assemblies

	For electrical, oil, gas and water utilities and industries, ScateX# Control Center bundles all the features required for advanced network operations and infrastructure management in a highly scalable extensible SCADA platform including advanced network-aware supervision and control applications in a unified user interface for 24/7 system operation and management. Prepared for smart grid deployments above one million of data points in one reliable and integrated SCADA/DMS solution, ScateX# Distribution Management System is the single real-time system access point for distribution network operations. Ready for tomorrow's distribution grid, ScateX# DMS combines core SCADA features with advanced power applications to support unified operation, automation, analysis, and reporting. Recognizing the dynamic nature of MV networks, ScateX# supports patterns for MV substations providing minimal engineering, installation and commissioning effort through semi-automated modeling features. As the real-time backbone of utility operations and management, the openness of ScateX# DMS also enables straightforward integration of external systems such as workforce, asset, advanced metering or customer information systems.
	For power generation and transmission companies ScateX# Energy Management System provides a real-time and high performance solution that drives systems efficiently, reliably and securely while providing enterprise decision makers with online process and energy information. ScateX# EMS combines SCADA operations with advanced applications including conventional and renewable generation planning, automatic generation control or contingency analysis, that constitute invaluable tools for network operators. Its open platform further enables the integration of third-party components and systems such as energy market interface or asset management systems.
	Prepared for smart grid deployments above one million of data points in one reliable and integrated SCADA/OMS solution, ScateX# OMS system is an open, modular and distributed system for the control and management of a power system. It targets the distribution utilities as it provides tools that enhance the control over the distribution quality of service, as well as tools that support a fast and safe service restoration to customers upon the occurrence of network outages. ScateX# OMS provides a fully integrated WEB user interface for OMS functionalities, including the interface to the enterprise systems including IIR, AVL and HDN.
	ScateX# ADMS is the full featured SCADA/DMS/OMS platform suited for distribution utilities to deliver high reliability, improved customer service and efficient operating costs while maintaining operational safety facing the growth of distributed generation and electric vehicles and the management of an active distribution network. In addition, improved situational awareness must be provided to the operator providing wider integration with the Information Technology (IT) systems of the organization.
	ScateX# RAIL bundles SCADA, operations management, power applications, condition monitoring and technical supervision, and providing a framework for seamlessly integrating railway applications and systems. ScateX# RAIL enables network operators to efficiently manage the railway electrification system, including substations and catenaries, as well as all associated infrastructure.

Modular System and Functional Components

ScateX# has been designed having flexibility in mind. A large set of functional components and services may be combined to be delivered in pre-defined and ready to be deployed packages. These pre-defined packages may be quickly configured for classical customer needs whether is increasing network automation for improved reliability, increasing network efficiency or improving personal productivity. In addition, tailored solutions may be designed to meet specific customer requirements. ScateX# is able to be expanded either in scale or in functionality, protecting the customer investment.



Base Modules

- Calculation Engine
- Diagrams Display Engine
- Historical data Engine
- Sequences of Commands Engine
- Temporary Network Elements
- Topology Processing
- Trending
- Tagging Engine
- SCADA Engine
- Hierarchical Model Browser
- Alarms/Events Correlation Engine
- Reports and notifications Engine
- Advanced Alarming
- Map visualization
- Dashboards

Optimising Modules

- DER Management
- Load Forecasting
- Distribution Power Analysis
- Feeder Optimisation
- Load Transfer Function
- Volt-Var Control

Operational Modules

- Automatic feeder generation
- Commissioning Environment
- Switching Orders Management
- Crew Management
- Mobile Integration
- Topological tracing
- Topological coloring
- Distribution Power Flow
- Distribution State Estimation
- Post Disturbance Review
- DTS
- Operational Studies
- Fault Analysis
- Infrastructure Management
- Device Monitoring

System Interfaces

- CIM
- Multispeak
- ICCP
- IEC 60870-5-101
- IEC 60870-5-104
- DNP 3.0
- SNMP
- OPC
- MODBUS
- WebServices
- OpenADR
- OCPP

Reliability Modules

- FDIR
- Fault Location
- Outage Analysis & Prediction
- Trouble Call Processing
- Load Shedding
- Storm Mode
- SAIDI Indexes
- Resource needs prediction
- Crew Management
- Short Circuits
- Protection coordination
- Peak demand reduction

System Integration

- GIS
- Metering Management Systems
- Customer Information Systems
- Asset Management Systems
- Workforce Management
- IVR
- MDM
- NMS
- CRM

Advanced User Interface

The standard user interface module includes a fully-integrated environment including a multi-screen window, menu and layout system featuring unified pick-and-drop, navigation, context menus, cross-application toolbars and shortcut interaction. The same user environment is presented for operational, planning, analysis, review or training purposes.

Standard user interface components include dashboards, data/event lists, real-time or historic trends, object model browsers, alarms management as well as interactive full vector graphics schematics or geographic displays with powerful layering, decluttering and object-oriented features. User interface screens can optionally integrate IP video feeds as well as locally available cartography and geolocation system for integration of field operations.

The powerful tagging, pinning and display engine allows integration of any **ScateX#** or external application directly into the operator user interface. Managing field controllability, system operating modes, alarm generation or getting feedback from condition monitoring, field crews or call centers directly on the display are examples of powerful user interface integration features available.

The display engine further supports synchronized diagram views that, together with the efficient navigation features, enable unprecedented system awareness for operators of large infrastructures.

The full integration of the control center with mobile devices enables switching work orders to be electronically sent to field crews. The crew can directly confirm the switching maneuvers improving the visibility of other crews, increasing safe working.

Multi-context Interface and Operational Work Orders

To efficiently manage planned or unplanned occurrences and field operations **ScateX#** provides an optional user interface solution that allows users to perform side-by-side on-the-fly integration of the real-world context with simulated network environments for network operation or planning.

Operators and managers can thus interactively create, record, validate and execute switching/work orders on their user interface station. Furthermore, operational document workflow management is available for maintenance or other work orders to be executed remotely or by field crews with the assistance of the mobile web-based field crew interface.



Unified User Interface

The **ScateX#** platform presents a high voltage, medium voltage, low voltage unified user interface environment for all internal and external applications, thus empowering remote operations and real-time management as well as enabling smooth integration with field and facility operations.

Multiple choices of local and remote user interface are possible, such as control room workstation, video wall, distributed operating stations or web access.

Components and Features	ADMS	CMS	DMS	EMS	RAIL	SCADA
Unified User Interface Environment (UI)						
Core User Interface Components						
Data lists, events and alarms, tags and pins, trends, model browsers, full vector graphics diagrams with advanced navigation and windowing, video-wall interface, online help, audible, alarms, geographic and map display, reports, dashboards	•	•	•	•	•	•
Network Model-based Components						
Auto-generated fully functional feeder schematics, coloring, tracing, redlining and dynamic model edits	•	•	•	•	◦	◦
Integrated Multi-context Interface						
Real world, study mode and/or engineering mode	•	•	•	•	◦	◦
Operational Management Components						
Operational or switching orders Interface	•	•	•	•	•	•
Management of planned and unplanned occurrences or outages	•	•	•	•	•	•
Multi-language - Up to 4 different languages						
◦	◦	◦	◦	◦	◦	◦
IP Video Integration						
◦	◦	◦	◦	◦	◦	◦
Cartography Integration and Geolocation						
◦	◦	◦	◦	◦	◦	◦
External Application Integration						
◦	◦	◦	◦	◦	◦	◦
Web Access Server						
Secure Multi-platform Web-access for UI	•	•	◦	◦	◦	◦
Mobile User Interface						
Mobile applications						
•	•	◦	◦	◦	◦	◦
• Core Feature by product assembly						
◦ Optional (Standard component)						
● Optional (Component customized according to customer requirements)						

Operations Management

SCADA Processing

The **ScateX#** SCADA engine supports hot-standby redundancy, performing all data/event and control direct execution, SBO and sequencing processing in conjunction with the multiple front end communication processors.

The SCADA processor further supports data logging and sequence of events recording together with the advanced alarm engine. Multi-source alarm processing with grouping, filtering, segregation and workflow handling including acceptance, notification and logging is available.

Also included in the core are printer management, the user defined calculation and logic engine for automation purposes and the tagging system host.

The facility of an electronic wallboard is provided by the flexible tagging system at the user interface. The electronic wallboard is therefore available in all types of diagrams including schematic, geographic or geo-schematic diagrams as well as list-based components.

Network Model-based Applications

All **ScateX#** management applications share a single object-based hierarchical model, with geo-referencing capabilities that enables flexible description of information such as resources, assets and connectivity.

The **ScateX#** user interface environment offers integrated network model-based components that can deliver dynamic coloring, tracing and automatically generated feeder schematics according to the network topology and current operating status.

Directly onto the user interface surface, operators may also update the network topological model according with field or management information through cuts, jumpers, temporary units or similar tagging actions.



Historical Information System

ScateX# HIS supports deep event and data logging storage from all sources including online RTUs, remote IED data records, user actions, alarms, calculations or system diagnostics, and can be deployed over the SCADA servers or at independent database servers.

The HIS features snapshot and playback to support post-event review analysis, power application studies or operator training sessions. Historic data can be access through data lists or trend displays, can be fed to other applications such as analysis, forecasting or statistics calculations and exported to external formats

Reports and Alerts



For supervisory accounting and performance management ScateX# provides a reports and alerts module that can produce real-time or historic reports based on the output of specific management applications or user-defined statistics.

Report notifications may be sent through email or SMS as well as displayed in dashboards, fully integrated within operation diagrams.

Communication Processors

Distributed front end processors and IP communication adapters run remote communication processing and system/device service access for either operational or management purposes. For inter-control center integration ScateX# fully supports ICCP, either in dedicated servers or SCADA server-integrated configurations.

Each ScateX# high-availability front end processor node supports simultaneous operation of multiple and optionally duplicated serial or IP channels. A wide set of protocols is available, including IEC, DNP, OPC, SNMP or Modbus, to name a few. All common communication infrastructures including RF, PLC, fiber, microwave or satellite links, SONET, SDH or IP backbones, GPRS/UMTS or WIMAX are supported.



Advanced Applications

Power Applications

Specifically designed for electrical network management from generation through transmission and distribution, Efavec power applications enable operators to optimally manage their networks and assets according to economic, technical and performance requirements.



ScateX# Power Application Software (PAS) provides a set of field-proven power management applications for operational support, network optimization and advanced automation having safety as a priority. Algorithm performance allows applications to run in study modes as well as in real-time, either cyclically, on-event, upon user request or as part of control execution verification, instruction and confirmation (VIC) cycles. Algorithm results can be presented directly on the operation surface, in advisory mode through result tables and suggested operation lists or, in fully automatic mode, updating field setpoints or execute controls.

ScateX# was designed to allow fast and safe outage restauration. When an outage occurs, the centralized FDIR automatically generates and executes a switching order to isolate the faulty area maximizing the recovered network. If necessary, the operator may then request to the FDIR additional switching orders that may be electronically dispatched to the crews mobile devices for manual execution. After maneuvers completion the crew may confirm its execution directly in the system by a secure channel.

Low Voltage Power Analysis

In general, the same power analysis tools that are used at higher voltages are applied to low voltage networks. Load profile data is combined with measured values to produce more accurate results.

Power application functions may be deployed in multi-server scalable architectures. All PAS applications provide configuration, diagnostic and execution information that can be set, logged or displayed.



Applications for Operations Management

Components and Features	ADMS	OMS	DMS	EMS	RAIL	SCADA
SCADA Engine						
SCADA Processor						
Data Acquisition and Event/ Control Processing, Data logging and Sequence of Events Recording, Alarm engine, User Calculations and Logics, Tagging System, Printer Management	o	o	*	*	*	*
Flexible Tagging System						
Temporary network elements, Safety tagging and interlock checks, Tagging lockout	*	*	*	*	*	*
Hot-standby and multi-server configurations	o	o	o	o	o	o
Network Model						
Object-oriented Dynamic Network Model and Topology Processor	*	*	*	*	o	o
Outage Monitoring (*)						
Including unsupplied energy and QoS index calculations according to IEEE 1366	o	o	o	o	-	o
Historical Information System (HIS)						
HIS integrated with SCADA server	o	o	o	o	o	*
Dedicated HIS server	*	*	*	*	*	o
HIS cluster	o	o	o	o	o	o
IED/RTU data file extraction and storage	o	o	o	o	o	o
Study Mode						
Side-by-side study mode for preparing operations and historical playback (sharing all core UI components)	*	*	*	*	o	o
Interface identical to real world mode						
PAS applications integrated in study mode	*	*	*	*	o	o
Simulation engine integrated in study mode						
Electrical Network, Telemetry and Telecontrol Simulation	o	o	o	o	*	*
Reports and Alerts						
Statistical calculations, reporting engine and dashboards server	o	o	o	o	o	o
SMS/email notifications	o	o	o	o	o	o

● - Core feature in product assembly
o - Optional (Standard component)
* - Optional (Component customized according to customer requirements)
(*) Optional feature to monitor QoS when DMS function is not included.

Advanced Management Applications

Components and Features	ADMS	OMS	DMS	EMS	RAIL	SCADA
Power Application Software (PAS)						
Operational Applications						
Power Flow	*	o	*	*	*	o
State Estimator	*	o	*	*	*	o
Reserve Monitoring	*	o	*	*	*	o
Emissions Monitoring	*	o	*	*	*	o
Others, please contact	o	o	o	o	o	o
Automation Applications						
Fault Detection, Location, Isolation and Reconfiguration (FDIR)	o	o	o	o	o	o
Automatic Generation Control (AGC)	o	o	o	o	o	o
Load Shedding	*	o	o	o	o	o
Others, please contact	o	o	o	o	o	o
Analysis and Optimization Applications						
Load Profile Modeling	o	o	o	o	o	o
Short Circuit Analysis	*	o	*	*	*	o
Distribution Optimal Power Flow (DOPF)	*	o	*	*	*	o
Optimal Power Flow (OPF)	*	o	o	*	*	o
Voltage Air Control (VAC)	o	o	o	o	*	o
Contingency Analysis (CTA)	o	o	o	o	o	o
Unit Commitment (UC)	o	o	o	o	o	o
Economical Dispatch (ED)	o	o	o	o	o	o
Interchange Transaction Scheduling (ITS)	o	o	o	o	o	o
Voltage Stability Analysis	o	o	o	o	o	o
Waterhead Management	o	o	o	o	o	o
Others, please contact	o	o	o	o	o	o
Forecast Applications						
Short-term Load Forecast	*	o	o	o	o	o
Wind Speed/Direction Forecast	o	o	o	o	o	o
Renewable Generation Forecast	o	o	o	o	o	o
Others, please contact	o	o	o	o	o	o
Technical Supervision Software						
Advanced condition and performance monitoring of process and assets						
Electrical Network Components	o	o	o	o	o	o
Wind Power Generation	o	o	o	o	o	o
Hydropower Generation	o	o	o	o	o	o
Photovoltaic Generation	o	o	o	o	o	o
Communications and Telecontrol Infrastructure	o	o	o	o	*	o
Railway Infrastructure	o	o	o	o	*	o
Others, please contact	o	o	o	o	o	o
● - Core feature in product assembly o - Optional feature * - Optional (Component customized according to customer requirements)						
(*) Depending on available PAS functions in the system.						



Outage Management System

The **ScateX#** OMS system is an open, modular and distributed system for the control and management of a power system. It targets the distribution utilities as it provides tools that enhance the control over the distribution quality of service, as well as tools that support a fast and safe service restoration to customers upon the occurrence of network outages.

The workstation provides a fully integrated user interface for the operator. It includes bi-directional navigation and highlighting mechanisms between tabular applications and any kind of diagram.

ScateX# OMS provides a fully integrated WEB user interface for OMS functionalities, including the interface to the enterprise systems including IVR, AVL and MDM, customer call handling and management and incident calculation to crew field positioning, outage monitoring capability (with Quality of Service reporting), etc.

The **ScateX#** OMS system integrates all the outage management functions and applications through a single data model. A single data model allows information from consumers, crews (repair and Survey), and SCADA to be processed in order to locate problem areas quickly.




ScateX# OMS stores and track customer call information, integrates this information with network connectivity updates, and processes this information through the Trouble Call Analysis engine to provide a comprehensive tool for outage management. From managing simple customer outages and tracking routine service work, to handling severe storm situations, **ScateX#** /OMS provides the support needed to restore consumer service, all in real-time.



Outage Management Applications

Components and Features	DMS	EMS	RAIL	CC	RAIL	CC
Outage Management						
User Interface Components						
Full tagging, context, UI surface integration with SCADA operational user interface	○	●				
Switching Order Integration						
Work order workflow integration	○	●				
HIS Integration						
Archiving and reporting	○	●				
Network Model Integration						
Topology processing	○	●				
Service Operator Interface						
Secure multi-platform web-access for UI	○	●				
Field Crew Interface						
Mobile web application	○	●				
Automatic Incident Predictor						
Trouble Call Analysis (TCA) system	○	●				
QoS Analysis						
IEEE 1366 indicators or others	○	●				
External Application Integration						
CIS (Customer Information System)	○	●				
External Application Integration						
CIS (Customer Information System)						
IVR (Integrated Voice Response)	○	●				
WfMS (Workforce Management System)						
AMI (Automated Metering Infrastructure)						
AVL (Automatic Vehicle Location)						

● - Core feature in product assembly
○ - Optional (Standard component)



Manageability

A Single System for Network Management

Network management systems handle large amounts of information are increasingly dynamic systems therefore requiring advanced engineering methods and tools, not only for easy setup and deployment, but also for continuous system management and maintenance throughout the system lifecycle. Moreover the value of advanced applications relies on the availability of an up-to-date network model.

As a single system solution, **ScateX#** enables administrators to maintain a single model for all applications including the SCADA, PAS,OMS, LV and ADMS subsystems. Furthermore users interface the system through a unified UI, reducing system complexity to manageable levels.




Low voltage networks can be several times larger than the higher voltage networks. The maintenance of the network model by the traditional approaches is impossible. It is therefore fundamental to be able to automatically import the network model from another source (ex: a GIS). The **ScateX#** supports incremental network model updates from external systems through CIM.

Integrated Engineering Environment

ScateX# supports current engineering requirements with an online integrated interactive CAD environment that includes template-based and object-oriented model editing tools, together with powerful copy/paste, import/export and model validation. The engineering environment supports database and network model design, user programming and diagram editing together with standard symbols with flexible dynamic behavior and templates for industry-specific applications, enabling engineers to customize and adjust the system instead of configuring it end-to-end. Full model version based edition is supported for diagrams, network equipments, network connectivity, SCADA model, communications model for all voltage levels of the network.


To complement the engineering toolset, **ScateX#** offers optional configuration repository server with full configuration history access and bulk/incremental updates as well as optional network simulation server for testing and dynamic validation.

Available for Efacec RTU and field equipment or for selected third-party providers, **ScateX#** can integrate RTU/IED configuration and management through the engineering system.



Infrastructure

Components and Features	
System Infrastructure	
Distributed RT-Bus	●
Integrated RBAC, Cyber security and Responsibility Areas	●
Distributed RT Clock Synchronization	●
System Watchdog, Self-monitoring and Diagnostics	●
Disaster Recovery	○
Power Applications System	○
Outage management System	○
Low Voltage management System	○
Front End Processing	
Multi-protocol/channel Processor	●
IEC 60870-5-101/104	○
DNP 3.0	○
MODBUS	○
Others, please contact	○
Configurations	
Front-end processor integrated with SCADA server	○
Independent Front-end processor in single or hot-standby configuration	○
Multi-front-end processors in single or hot-standby configuration	○
Communication Adapters	
IP Communication Adapters	○
ICCP	○
SNMP	○
OPC	○
Others, please contact	○
Configurations	
IP Communication adapters integrated with SCADA server	○
IP Communication adapters over dedicated servers	○
Systems Integration	
SQL interface, CIM-compliant and SOA/REST Application Adapter	
Geographical Information Systems (GIS)	
Workforce/Field-crew Management (WIMS)	
Asset Management Systems (AMS)	
Customer Information Systems (CIS)	
Metering Management Systems (AMI/MDM)	
Video- surveillance Systems	●
Railway/Train Management Systems	
Wide-area Monitoring Systems	
Market Management Systems	
Call Center and Interactive Voice Response Systems	
Enterprise Resource Planning Systems	
Other Technical Systems	
Engineering System	
Integrated Engineering Environment	
Integrated Configuration Tool, CAD Environment for Diagram/Symbol Editing, Online incremental/bulk changes, Import/Export Tools, Objects and Templates, Validation tools, etc.	●
Integrated RTU/IED Configuration Management	●
Application-specific engineering packages	●
Pre-engineered catalogs, symbols, reports, dashboards and templates	●
Version-managed Repository Server	○
Operator Training System	
Training Session Configuration and Management	○
Session Results, Playback and Resume	○
Operations Management Training	○
Advanced Management Applications Training*	○
● - Core feature in product assembly ○ - Optional (Standard component) ● - Optional (Component customized according to customer requirements) * - Depends on available PAC functions in the system	



Extensibility

By offering standard file format import/export facilities, SQL interface, Multispeak® and CIM-compatible SOA/REST application adapters, **ScateX#** minimizes the required effort when external applications need to be integrated.


Adapters and data exchange allow users to benefit from seamless integration with external or existing systems such as geographical information, workforce/field-crew management, call center, asset management, customer information, advanced metering, video- surveillance, public information or other technical systems.



Operator Training Simulator

Designed to provide realistic training sessions for **ScateX#** power network operators the Operator Training Simulator (OTS) is a standalone system that includes the electrical network simulation engine for all voltage levels with optional protection and automation simulation engine, including telemetry and telecontrol. The OTS system may also be setup to include any set of power applications, including automation applications and the ADMS subsystem.

The training session management model allows training sessions to be created from historical or current network configurations and snapshots and executed with manual or template-based incident/fault simulation. Training sessions can be recorded for analysis with pause/resume and playback functions.




Product Availability

ScateX# is available in fully customizable form according to the specific requirements of each system, but is also readily available in product assemblies that target the needs of specific utility or industry application.

Applications	ADMS	OMS	DMS	EMS	RAIL	SCADA
Remote SCADA and Telecontrol Systems	●		●	●	●	●
Condition Monitoring and Infrastructure Technical Supervision	●	●	●	●	●	●
Plant Local SCADA						●
Transmission Grid Management	●			●		
Distribution Network Management	●		●			
Low Voltage Network Management	●					
Outage Management	●	●				
Renewable Generation Management	●					
Railway Electrification Management					●	

Support

The **ScateX#** flexible and open platform ensures that your system is equipped with future-proof technology and that stepwise investment strategies are not hindered. Efavec further supports users with a full range of services from training and product support, through software customization, to project management, engineering and maintenance that ensure you have the best fitting solution for your requirements considering the full system life-cycle.





Main Office

Efacec Energia, Máquinas e Equipamentos Eléctricos, S.A.
Automation Business Unit

Rua Eng. Frederico Ulrich - Ap. 3078
4471-907 Moreira Maia
Portugal

Phone: +351 229 402 000
Fax: +351 229 485 428

ase.eng@efacec.com
www.efacec.com

www.efacec.com/automation

