

# Previsão de carga eléctrica como uma ferramenta computacional de apoio às *Smart Grids*

## *Load forecasting as a computational tool to support Smart Grids*

Svetlana Chemetova, Paulo Santos

Department of Electrical Engineering  
Instituto Politécnico de Setúbal, ESTSetúbal  
Setúbal, Portugal

{svetlana.chemetova, paulo.santos}@estsetubal.ips.pt

Mário Ventim-Neves

Department of Electrical Engineering  
Universidade Nova de Lisboa  
Lisboa, Portugal

ventim@uninova.pt

**Resumo** — A previsão da carga eléctrica é uma tarefa fundamental para planeamento, operação e exploração dos Sistemas de Energia Eléctrica. A importância da previsão tornou-se mais evidente com a reestruturação do sector energético nacional e com a criação de projectos ligados com as *smart grids*, nomeadamente em Portugal – o InovGrid.

Este artigo descreve o modelo computacional de previsão do Diagrama de Carga Diária baseado no algoritmo Levenberg-Marquardt de Redes Neurais Artificiais. Os dados a utilizar são as séries temporais de potência activa registados pelo Sistema de Telecontagem da EDP Distribuição e as séries temporais climáticas do Instituto Português do Mar e da Atmosfera, recolhidas na cidade de Évora, uma das primeiras cidades inteligentes (*smart cities*) em Portugal. O horizonte da previsão é de curto prazo: desde 24 horas até uma semana. Foram obtidos bons resultados observados pelos indicadores estatísticos de erros.

**Palavras Chave** – *previsão de carga; redes inteligentes; subestações; redes neuronais artificiais; séries temporais.*

**Abstract** — Load forecasting is a fundamental task for the planning, operation and exploration of the Electric Power Systems. The importance of forecasting has become more evident with the restructuring of the national energy sector and the creation of projects linked to smart grids, namely in Portugal - InovGrid.

This paper describes the computational forecast model of the Daily Load Diagram based on the Levenberg-Marquardt algorithm of Artificial Neural Networks. The data to be used are the time series of active power recorded by the EDP Distribution Telemetry System and the climatic time series of the Portuguese Institute of the Sea and Atmosphere, collected on the city of Évora, one of the first smart cities in Portugal. The forecast horizon is short term: from 24 hours to a week. The good results observed by the statistical error indicators were obtained.

**Keywords** - *load forecasting; smart-grids; substations; artificial neural networks; time series.*

### I. INTRODUÇÃO

A previsão do consumo de energia eléctrica é uma das tarefas fundamentais para o planeamento, operação e exploração dos Sistemas de Energia Eléctrica (SEE). A importância da previsão actualmente tem crescido significativamente, devido principalmente ao papel essencial para a gestão e controlo do SEE.

A energia eléctrica ao ser produzida tem que ser obrigatoriamente consumida em simultâneo. Diferente de outros bens da sociedade humana (petróleo, gás etc.), a energia eléctrica não pode ser eficientemente armazenada e, por isso, não podemos produzi-la em excesso. Por outro lado, a sua escassez vai levar a falta do fornecimento de energia eléctrica que é prejudicial, tanto para os consumidores como para as empresas de produção e de distribuição da energia eléctrica.

Sabendo antecipadamente (previsivelmente) a altura de maior consumo de energia eléctrica e a evolução dos valores do diagrama de carga, os operadores do SEE conseguem, de uma forma mais eficiente, planear a regulação dos grupos geradores e o arranque dos grupos de reserva. Nas centrais termoeléctricas isto resulta também na diminuição das emissões de CO<sub>2</sub>. Os diagramas de carga constroem-se na base de valores de potência média tomada (é um valor recolhido por cada intervalo de 15 minutos, que resulta da integração de potência instantânea e cujo resultado é dividido pelo intervalo de tempo [1]), registados pelo SCADA (*Supervisory Control And Data Acquisition*).

Este artigo apresenta a aplicação computacional prática desenvolvida para a previsão de diagrama de carga diária, usando as séries temporais de dados do sector eléctrico de Portugal. Para testar e avaliar o modelo de previsão de carga, a escolha recaiu sobre a área urbana da cidade de Évora, no contexto do desenvolvimento de redes inteligentes nesta cidade, um projecto-piloto realizado pela EDP Distribuição, denominado InovGrid [2]. A Fig. 1 apresenta a arquitectura geral do InovGrid focada no cliente e numa infra-estrutura integrada do sector eléctrico nacional.

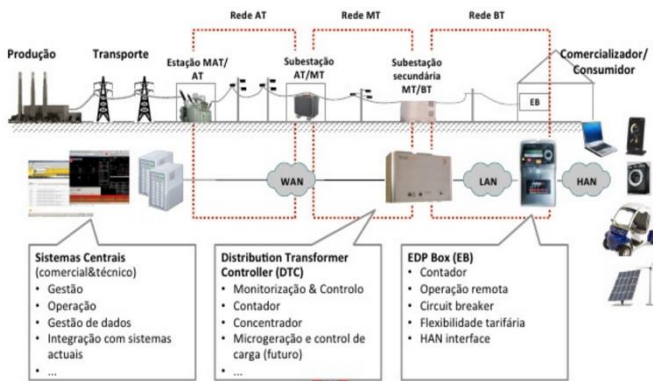


Figure 1. Arquitectura do InovGrid (fonte: [3])

## II. RECOLHA DE INFORMAÇÃO

A zona urbana da cidade de Évora é alimentada em Média Tensão, 15 kV, por duas subestações eléctricas de distribuição ligadas à subestação REN – ÉVORA: subestação de Évora e subestação de Caeira. A Fig. 2 ilustra a topologia dessas redes de distribuição e as referidas subestações.




Figure 2. Aspecto topológico das redes de distribuição na zona da cidade de Évora e arredores

Entre os sectores de consumo de energia eléctrica da cidade de Évora prevalecem o doméstico, serviços e indústria.

Os dados que fazem parte do conjunto “histórico” das variáveis endógenas do algoritmo da previsão foram recolhidos nos enrolamentos de 15 kV de cada transformador, através do sistema de telecontagem de energia, relativos aos anos 2013-2015. Compreendem valores de potência activa (em kW) e de potência reactiva indutiva e capacitiva (em kvar).

Os factores climáticos que influenciam o consumo de energia eléctrica são a temperatura ambiente, a humidade relativa do ar, a velocidade do vento, a pluviosidade e a luminosidade. Com o objectivo de avaliar o impacto desses factores no diagrama de carga, foram recolhidos os dados meteorológicos junto do IPMA - Instituto Português do Mar e da Atmosfera.

Como exemplo, apresenta-se na Fig. 3 o diagrama de carga da cidade de Évora numa semana de Inverno (6 - 12 de Janeiro), e de Verão (4 - 10 de Agosto) do ano 2014. É notória uma redução de consumo no Verão em comparação com o

Inverno. Observa-se também o menor consumo no fim da semana, devido ao tradicional abrandamento das actividades económicas.




Figure 3. Diagrama de carga semanal de Inverno e de Verão

Todos os dados foram colocados nas folhas de cálculo Excel para poderem ser usados para alimentação do sistema de previsão desenvolvido. Os dados em falta (*outliers*) foram substituídos pelos valores médios adjacentes, ou do período cronológico homólogo, conforme se tratasse de intervalos curtos, ou longos.

## III. MÉTODOS DE PREVISÃO

### A. Análise geral

O modelo de previsão da carga eléctrica pode ser dividido em cinco etapas [4]:

1. Objectivo do Modelo
2. Colecta e Análise dos Dados
3. Selecção da Técnica de Previsão
4. Obtenção das Previsões
5. Monitorização do Modelo

Na primeira etapa define-se a razão pela qual será necessário prever, o produto que será previsto (a carga eléctrica) e o grau de confiabilidade desta previsão. Depois faz-se a colecta e análise dos dados históricos do produto, para identificação e desenvolvimento da melhor técnica de previsão nessa situação. Na etapa seguinte, define-se a melhor técnica quantitativa de previsão baseada na análise de dados históricos através de modelos matemáticos. À medida que a carga prevista for sendo calculada, deve-se compará-la com a carga real registada, calculando o erro obtido, para poder efectuar uma monitorização do modelo.

De uma forma muito resumida a evolução das metodologias de previsão registaram um avanço significativo. Na década sessenta surgiram as metodologias essencialmente baseadas em aproximações regressivas, nas décadas de oitenta e princípios de noventa do século passado surgem as metodologias baseadas no conhecimento e técnicas de redes neuronais artificiais, sistemas híbridos e algoritmos genéticos. O limite e a adaptabilidade de cada um dos métodos dependem da diversidade e profundidade temporal da informação recolhida, do horizonte da previsão, bem como do clima da região geográfica e do grau de interdependência entre o consumo e as variáveis climáticas [1].

Existem vários métodos de previsão de cargas eléctricas:

1. Métodos Estatísticos (tradicionais)
  - a) Regressão Linear Múltipla
  - b) Alisamento Exponencial
  - c) Séries Temporais Estocásticas:
    - Modelo Auto-Regressivo
    - Modelo da Média Móvel
    - Modelo da Média Móvel Auto-Regressivo (ARMA)
2. Métodos de Inteligência Artificial
  - a) Redes Neurais Artificiais
  - b) Lógica Fuzzy
  - c) Algoritmos Genéticos

Os métodos Estatísticos têm vantagem de serem técnicas matemáticas já bem desenvolvidas e estudadas, mas dependem de uma modelação matemática complexa, além de terem dificuldade de lidar com variações rápidas de factores como clima, feriados etc. O modelo regressivo considera a carga como uma combinação linear de funções tais como sinusóides, exponenciais, etc. Consiste na determinação da curva que melhor se ajuste aos dados históricos da carga, utilizando o método de mínimos quadrados. Os modelos baseados em séries temporais incorporam na previsão não só os dados históricos, mas também os factores tais como temperatura ambiente, sazonalidade e efeitos aleatórios.

Os métodos baseados na Inteligência Artificial permitem lidar de melhor forma com a incerteza, bem como com as funções não lineares. A previsão baseada na teoria de Inteligência Artificial, propriamente Redes Neurais Artificiais, foi amplamente aceite no mundo científico e da engenharia, tornando-se a técnica mais difundida para a previsão de carga. Existem diversas publicações científicas que provam a qualidade e robustez das previsões baseadas em redes neuronais [1], [5], [6], [7], [9].

#### B. Metodologia adoptada

A Fig. 4 descreve a estrutura geral do modelo proposto neste trabalho na forma de um diagrama de blocos.

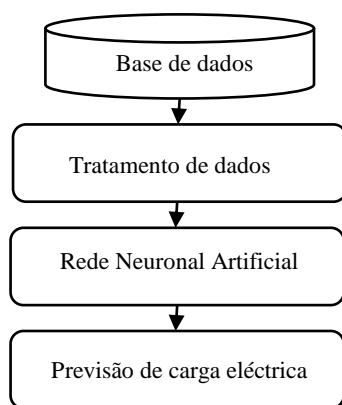


Figure 4. Diagrama de blocos do modelo de previsão

Uma Rede Neuronal Artificial (RNA) é composta por várias unidades de processamento, denominadas de neurónios, cujo funcionamento é bastante simples. O modelo do neurónio é inspirado no sistema nervoso biológico: ele recebe os valores de entrada ( $x_i$ ) que são ponderados por valores associados com cada sinapse ( $\omega_i$ ), chamados pesos sinápticos. Todos os valores ponderados são somados inicialmente, que resulta no nível de actividade do neurónio ( $v$ ) que a seguir é processado pela função de activação ( $\phi(\cdot)$ ) para o valor de saída ( $y$ ). A Fig. 5 apresenta esquematicamente o modelo do neurónio artificial.




Figure 5. Esquema de um neurónio artificial

Neste trabalho a previsão de carga eléctrica é feita através de Redes Neurais Artificiais *feedforward* onde existe apenas um sentido de passagem de informação (da esquerda para a direita) que corresponde a uma rede de alimentação directa.

O treinamento da rede foi realizado através do algoritmo de retropropagação (*backpropagation*), que é um procedimento sistemático de adaptação de pesos de redes neuronais baseado no método do gradiente descendente.

O algoritmo de retropropagação descreve-se através dos procedimentos seguintes [8]:

1. Apresentação de uma série temporal de dados  $x_1, x_2 \dots x_m$  (padrão) da rede, a qual fornece uma saída  $y$ .
2. Cálculo do erro que é igual à diferença entre o valor desejado (alvo) e a saída para cada valor de  $y$ .
3. Cálculo do erro retropropagado pela rede associado à derivada parcial do erro quadrático de cada elemento relacionado aos pesos  $\omega_1, \omega_2 \dots \omega_i$ .
4. Ajuste dos pesos de cada elemento.
5. Apresentação de um novo padrão da rede e repetição do processo até que haja a convergência da rede: valor absoluto do erro < tolerância arbitrada.

#### C. A composição do vector de entrada no modelo de previsão

Para definir a estrutura e a composição do vector de entrada para o modelo baseado em RNA segue-se uma sequência de passos seguintes [5]. Inicialmente, é executado o pré-processamento de dados, principalmente para preencher as lacunas causadas por falta na operação do sistema de aquisição de dados. Em seguida, é feita uma análise de correlação entre as variáveis endógenas e exógenas, para identificar influências relevantes de factores aleatórios independentes na dinâmica do consumo de energia eléctrica. As variáveis endógenas são os valores da potência activa, as variáveis exógenas são meteorológicas. Concluiu-se que só a temperatura do ar

apresenta uma correlação significativa com a potência activa, e mesmo assim com valores baixos. É praticamente inexistente a correlação entre a potência e as restantes variáveis climáticas: humidade do ar, velocidade do vento e nebulosidade. Assim, definiu-se que o vector de entrada do modelo de previsão proposto vai incluir só as variáveis da potência. Em seguida, a série temporal de potência é submetida a uma análise de entropia para determinar o comprimento da série de memória de curto prazo. Isto serve para identificação do comprimento máximo da sequência relevante de valores contíguos de potência a ser incluída no vector de entrada no algoritmo da RNA. No final, é realizada uma análise de auto-correlação dos valores de potência no passado, baseada no comportamento da carga em períodos homólogos de semanas anteriores à semana de previsão [1].

Após esta análise, foi definido o seguinte vector de entrada, constituído por 13 variáveis endógenas:  $[P(t-1), P(t-2), P(t-3), P(t-23), P(t-24), P(t-25), P(t-167), P(t-168), P(t-169), \Delta_1, \Delta_2, \Delta_3 \text{ e } \Delta_4]$ . As variáveis  $P(t-1), P(t-2) \dots P(t-n)$  são os valores de potência usados na construção do vector de entrada. O gradiente  $\Delta_i$  é calculado para os valores de carga adjacentes  $P(t-k), P(t-k+1)$  em que  $k$  é o "deslocamento para trás", por exemplo:  $\Delta_1 = P(t-23) - P(t-24), \Delta_2 = P(t-24) - P(t-25)$  etc. A Fig. 6 mostra a variável de previsão  $P(t)$  e duas variáveis contíguas anteriores,  $P(t-1)$  e  $P(t-2)$ .




Figure 6. A variável de previsão  $P(t)$  e as duas anteriores,  $P(t-1)$  e  $P(t-2)$

O número de neurónios na única camada oculta era a metade da camada de entrada. A função tangente hiperbólica foi escolhida para a camada oculta. Utilizou-se uma função linear para a camada de saída. O vector de entrada foi normalizado entre -1 e 1. Este é um arranjo bem comprovado, adequado quando, como no caso presente, as relações entre as variáveis em jogo têm um forte comportamento não-linear. Em muitos modelos de previsão de curto prazo este tipo de estrutura de ANN é amplamente utilizado [1], [5].

#### IV. RESULTADOS

Para validar o sistema computacional de previsão da carga eléctrica proposto neste trabalho, foram realizados os ensaios com o mesmo.

O software MatLab R2012b foi a ferramenta utilizada para treinar, validar e simular o sistema predictor proposto. Conforme foi descrito em cima, implementou-se um método baseado no algoritmo da retropropagação do erro

(backpropagation), Levenberg-Marquardt. Além de permitir o ajuste da topologia da rede neuronal (número de camadas e de neurónios por camada), o software permite o ajuste dos parâmetros de treinamento tais como número de iterações no treinamento, taxa de aprendizagem, etc. O conjunto de treinamento e validação é usado para ajustar os parâmetros do modelo proposto, enquanto que o conjunto de teste é utilizado para medir o desempenho do modelo.

As séries temporais de potência foram divididas em três conjuntos de dados: conjunto de treinamento (com 50% dos dados), conjunto de validação (com 25% dos dados) e conjunto de teste (com 25% dos dados). Os dados do ano 2013 foram utilizados para os treinos de previsão, e os do ano 2014 – para a simulação.

Como exemplo, os resultados obtidos são apresentados nas Fig. 7 e 8 na forma gráfica. Cada gráfico mostra um diagrama de carga real obtido a partir do sistema de telecontagem e o diagrama de carga previsto (*forecast*). Não é por acaso, que o dia 4 de Fevereiro de 2014 foi escolhido: na base de dados de EDP Distribuição esse dia foi registado como o dia de maior consumo em 2014, em Portugal continental.




Figure 7. Diagrama diário de carga real e previsto




Figure 8. Diagrama semanal de carga real e previsto

O desempenho da previsão foi avaliado com base nos indicadores estatísticos apresentados na Tabela 1.

TABLE I. PARAMETROS ESTADÍSTICOS PARA A ANÁLISE DO ERRO

O valor absoluto do erro <i>Forecast error</i>	$e_t = P_t - \hat{P}_t$
O valor do erro médio <i>Mean error</i>	$ME = \sum_{t=1}^n \frac{e_t}{n}$
Percentagem do erro <i>Percentage error</i>	$PE_t = \frac{(P_t - \hat{P}_t)}{\hat{P}_t} 100$
Percentagem media absoluta do erro <i>Mean absolute percentage error</i>	$MAPE = \sum_{t=1}^n \frac{ PE_t }{n}$

Nessas expressões,  $P_t$  é o valor de potência registado pelo sistema de telecontagem (real),  $\hat{P}_t$  é o valor de potência calculado (previsto),  $n$  é o número de registos (membros de amostra).

A percentagem média absoluta do erro (MAPE) é o indicador estatístico mais divulgado na bibliografia sobre os métodos de previsão de carga eléctrica. Quanto menor o valor do MAPE, melhor o desempenho da previsão [5], [10].

A Tabela 2 representa dois indicadores de erro mais significativos: o valor máximo de  $PE_t$  e MAPE para os casos de estudo correspondentes a carga das subestações da cidade de Évora. O período em análise é o dia 4 de Fevereiro de 2014, uma semana, de 3 até 9 de Fevereiro de 2014 e duas semanas, de 3 até 16 de Fevereiro de 2014. Os resultados são satisfatórios, considerando que o valor máximo de MAPE nos estudos de previsão deste tipo não deve exceder 5% [1], [5].

TABLE II. PARAMETROS ESTADÍSTICOS PARA A ANÁLISE DO ERRO

Período	Max $ PE_t $ (%)	MAPE (%)
Um dia	2,30	0,78
Uma semana	4,90	1,01
Dois semanas	6,51	1,11

Na Fig. 9 está ilustrada como exemplo a evolução da percentagem de erro para o período de duas semanas, de 3 a 16 de Fevereiro 2014.




Figure 9. Percentagem de erro no período de duas semanas

Relativamente à análise de erro aplicada à potência máxima (ponta) do diagrama de carga da cidade de Évora, observa-se que esta ocorreu em 21 de Janeiro de 2014 às 20:00. O  $PE_t$  naquele momento é pequeno: 0,70%. O MAPE de 10 registos com cargas mais elevadas do mesmo ano é de 0,94%. Como os indicadores estatísticos de erros ainda permanecem abaixo de 5%, os resultados do modelo de previsão continuam satisfatórios.

Com o objectivo de melhorar o desempenho do nosso modelo de previsão acrescentaram-se os valores de patamares de carga no vector de entrada do modelo, como mais uma variável endógena. Os patamares de carga são valores médios de carga em intervalos horários. Servem para simplificar a quantidade de informações utilizada na análise e procedimentos de fenómenos que ocorrem na operação de sistemas eléctricos [8].

A Fig. 10 ilustra os patamares do diagrama de carga da cidade de Évora, baseados no cálculo do valor de potência média sazonal, nos dias úteis (Pat. DU), Sábados, Domingos e feriados do ano 2013. Analisando empiricamente a curva que representa o diagrama de carga diário médio, chega-se a conclusão que para os sábados, domingos e feriados “adapta-se” o mesmo perfil de patamares (Pat. SDF).

Podemos identificar os valores de patamares como sendo as cargas de vazio, cheia e ponta. Esses nomes são iguais aos usados no sistema tarifário português, embora os intervalos temporais de patamares no nosso modelo são diferentes, correspondem ao comportamento “natural” de diagrama de carga.

Para o Verão é suficiente usar só dois patamares de carga, como mostra a Fig. 11.

Após o treino do modelo de previsão com consideração de patamares de carga, chegou-se à conclusão que os indicadores estatísticos usados na análise de erros de previsão sofreram pequenas melhorias na ordem das centésimas. Embora não constitua grande “progresso” no desempenho do modelo, pode ser importante nalgumas situações do comportamento de rede de energia eléctrica, por exemplo, na altura de reconfigurações da rede ou funcionamento em regime de sobrecarga.




Figure 10. Os patamares de diagrama diário médio de carga de Inverno




Figure 11. Os patamares de diagrama diário médio de carga de Verão

## V. CONCLUSÕES

Este artigo apresenta um estudo das séries temporais de carga eléctrica e propõe um modelo de previsão de carga a curto prazo em redes de distribuição de energia eléctrica em média tensão. O modelo proposto baseia-se nos algoritmos de Redes Neurais Artificiais, em combinação com padrões (patamares) sazonais de carga, destina-se a prever o consumo de energia a curto prazo, para a hora seguinte. Como casos de estudo foram usadas as subestações da cidade Évora, a pioneira das *smart grids* em Portugal, onde se começou a desenvolver o projecto InovGrid.

Este modelo mostrou-se eficiente e de fácil utilização, onde a actualização de seus parâmetros se processa de forma rápida e eficaz.

A comparação dos erros de previsão (entre os quais o mais importante é o MAPE), mostrou que o modelo predictor tem um bom desempenho e pode ser utilizado como uma ferramenta de suporte na gestão e controlo de redes de energia eléctrica.

## AGRADECIMENTOS

Os autores agradecem às empresas EDP Distribuição e IPMA pela disponibilidade dos dados que foram usados nos ensaios do modelo de previsão desenvolvido.

## REFERÊNCIAS BIBLIOGRÁFICAS

- [1] P. J. C. Santos, "Previsão de cargas em horizonte de curto-prazo aplicada a subestações de distribuição", Coimbra, 2005, pp.62–63.
- [2] Smart Energy Grid, <http://www.inovgrid.pt/pt> accessed in January 2017.
- [3] P.Ferreira, "InovGrid - Redes inteligentes ao serviço da prosperidade renovável", Seminário "O Meio Edificado ao Serviço de uma Elevada Qualidade de Vida", Setúbal, Abril 2012.
- [4] Tubino, D. F. (2007), Manual de planeamento e controlo da produção. Brasil, Atlas S.A.
- [5] Hippert, H., Pereira, C., & Sousa, R., "Neural Networks for Short-Term Load Forecasting: A Review and Evaluation", IEEE Transactions on Power Systems, 16, pp. 44-55, February 2001.
- [6] F. Giacometto, J. Cárdenas, K. Kampouropoulos, L. Romeral, "Load Forecasting in the User Side Using Wavelet – ANFIS", IECON 2012 - 38th Annual Conference of the IEEE Industrial Electronics Society, pp. 1049-1054, 2012.
- [7] S.Skolthanarat, U.Lewlompaisarl, K.Tungpimolrut, "Short-term Load Forecasting Algorithm and Optimization in Smart Grid Operations and Planning", IEEE Conference on Technologies for Sustainability, pp. 165-171, 2014.
- [8] D. A. A. d. Farias, "Previsão da Carga de Energia Diária em Patamares Combinando Técnicas Estatísticas e de Inteligência Computacional," Rio de Janeiro, 2008.
- [9] C. Chen, Y. Tzeng and J. Hwang, "The application of artificial neural networks to substation load forecasting," Electric Power Systems Research 38, pp. 153-160, 1996.
- [10] C.Borges, Y.Penya and I.Fernández, "Evaluating Combined Load Forecasting in Large Power Systems and Smart Grids", IEEE Transactions on Industrial Informatics, Vol. 9, 3, August 2013.