

Metodologia para Estimação e Previsão dos Perfis das Curvas de Carga por Subestação e Classes de Consumo

R. C. Souza¹, L. Medeiros¹, E. Christo¹, M. Lessa¹, F. Lessa¹, PUC-Rio, A. V. Salesse, ELEKTRO

RESUMO

O presente trabalho é realizado a partir de convênio firmado entre a concessionária de energia elétrica - ELEKTRO - e a instituição educacional - PUC/RIO (Fundação Padre Leonel Franca). Participa ainda do Projeto o EPRI - Electric Power Research Institute, através da PUC-Rio.

O projeto a qual se desenvolve o presente trabalho é dividido em três fases. A primeira levantamento dos dados disponíveis, metodologias e análise preliminar; a segunda análise estatística dos dados disponíveis, modelagem matemática de tratamento dos dados e previsão das curvas de carga, validação e testes do modelo; finalmente a terceira fase, desenvolvimento de ferramenta computacional e treinamento. Atualmente, o trabalho se encontra na segunda fase, onde ferramentas estatísticas estão sendo utilizadas para modelagem e previsão das cargas ativas e reativas. Identificação dos perfis das curvas de carga.

PALAVRAS-CHAVE

carga ativa, carga reativa, classes de consumo, estimação perfis de carga, previsão.

I. INTRODUÇÃO

Via de regra conjuntos de dados de medição apresentam *missing case e outliers*, e para os dados utilizados neste trabalho (medição de demanda ativa e reativa em subestações) constatou-se tais ocorrências. Como Durante a análise preliminar dos dados disponíveis pode ser perceber a necessidade da utilização, utilizou-se de técnicas estatísticas para a recuperação desses dados., pois os mesmos apresentavam um grande número de *missing case e outliers*. Técnicas como Filtro de Kalman e Regressão Linear Simples foram utilizadas. Sendo assimNo estágio atual do trabalho para análise estatística dos dados e modelagem matemática, toda uma metodologia foi desenvolvida para demonstrar a correlação das cargas ativas e reativas. Paralelamente, ferramentas para estimação dos perfis das curvas de carga estão sendo estudadas.

¹ Este projeto é financiado pela ELEKTRO

Reinaldo C. Souza (reinaldo@ele.puc-rio.br)

Lucio Medeiros(lucio@ele.puc-rio.br)

Eliane Christo (eliane@ele.puc-rio.br)

Marcio Lessa (mllessa@rdc.puc-rio.br)

Flavia Lessa (fslessa@ele.puc-rio.br)

Antônio V. Salesse (asalesse@elektro.com.br)

II. REGRESSÃO LINEAR SIMPLES

No que tange a metodologia empregada na previsão das curvas de carga, encontra-se em estudo aquela que deverá ser a mais adequada para a obtenção da carga ativa, uma vez que, a priori, os dados disponibilizados não possuíam uma consistência desejável para os valores de carga reativa. Como se sabe o fator de potência sofre variações entre concessionárias e ainda entre períodos o que pode dificultar o cálculo direto da carga reativa. Uma vez que se busca o perfil da curva de carga reativa, a solução simplista de adotar um fator de potência para a instalação em estudo não é suficiente, considerando que tal grandeza sofre variações de acordo com o período estudado, bem como depende fortemente do mix das classes de consumo atendidas pelas instalações. Para evitar estes problemas, um método de regressão linear foi aplicado a fim de fixar uma relação entre a carga ativa e reativa, para que uma possa ser calculada através da outra sem, necessariamente, conhecer o fator de potência exato utilizado.

A regressão linear simples é definida de acordo com a equação abaixo:

$$y = \beta_1 x + c \quad (1)$$

onde:

y= potência reativa (MVar)

x= potência ativa (MW)

β_1 = coeficiente

c= constante

O coeficiente de correlação linear foi calculado conforme fórmula abaixo:

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\left[\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2 \right]^{1/2}}; \quad 0 \leq |r| \leq 1 \quad (2)$$

No caso dos dados em estudo o coeficiente de correlação linear entre as potências ativa e reativa foi de 76,16%. Este valor corresponde uma alta correlação entre as variáveis, ou seja, a carga reativa pode ser estimada através da carga ativa.

Baseado em análises anteriores, em que ficou comprovada a forte correlação entre as cargas reativa e ativa (ex. figura 1), consiste a idéia de trabalhar as duas cargas conjuntamente. Porém, também visto anteriormente, os dados de carga reativa em algumas subestações (áreas de

veraneio) apresentam valores ‘zeros’ ou ‘negativos’ devido à presença de compensadores capacitivos fixos na rede de distribuição que, por sua vez, injetam reativos de valor constante no sentido da carga para a fonte, “mascarando” por vezes a correlação entre demanda ativa e reativa medida junto à fonte (subestação).




FIGURA 1

Este fato foi observado, em grande escala, nas subestações localizadas nas regiões litorâneas, como por exemplo, subestação de UBATUBA 1, a qual está sendo utilizada como experiência para os modelos desenvolvidos neste estudo, juntamente com a subestação ARARAS 1, que, por possuir uma componente de carga significativa no segmento industrial, apresenta um comportamento mais homogêneo. Estudos existentes de análise e previsão de carga ativa mostram que esta apresenta sazonalidades. Como a carga reativa é fortemente correlacionada com a carga ativa, é de se esperar também nelas efeitos sazonais. Isto foi comprovado quando se procurou uma classificação dos dados ao longo do ano. Foi feita uma *Análise de Agrupamento* (AA) da série de carga reativa e comparada com a mesma metodologia aplicada a carga ativa. Este método é especificado a seguir e foi implementado no software estatístico SPSS 8. Em todas as técnicas apresentadas a seguir os dados de carga reativa e ativa são utilizados em PU (por unidade) para evitar incompatibilidade de unidades e grandezas. Os perfis de curva de carga em P.U. (Por Unidade) é a curva formada pelas cargas horárias normalizadas pela demanda média de energia diária, ou seja,

$$PU_{i,h} = \frac{C_{i,h}}{DM_i}, \quad i = \overline{1,365} \quad e \quad h = \overline{1,24} \quad (3)$$

e

$$DM_i = \frac{\sum_{h=1}^{24} C_{hi}}{24}, \quad i = \overline{1,365} \quad (4)$$

III. ANÁLISE DE AGRUPAMENTO (AA)

Compreende o conjunto de técnicas que têm como objetivo a identificação de grupos ou classes de objetos semelhantes entre si dentro de um conjunto de objetos.

Em termos de matriz de dados, a AA acrescenta uma nova variável que representa a classe do objeto.

O problema de classificar pessoas ou objetos em gru-

pos homogêneos está presente em numerosas áreas de estudo. Em todos, a AA é utilizada no sentido de obter um ou mais dos seguintes resultados:

- **Classificação dos n objetos em k grupos: participação.**

Em geral, o número de grupos é fixado a priori. É muito difícil definir um critério objetivo para determinar o número ideal de agrupamentos.

- **Caracterização dos grupos.**

Em geral, um grupo é caracterizado pelo seu centróide e pelo número de elementos. O alcuro do centróide pode também envolver variáveis que não foram utilizadas para definir os agrupamentos.

- **Diferenciação dos grupos.**

Seleção das variáveis que mais determinam a diferença entre os grupos.

- **Compreensão de informação.**

Freqüentemente, lida-se com grandes volumes de dados, da ordem de dezenas de milhares ou alguns milhões. Neste caso, a manipulação, armazenamento, transmissão e modelagem dos dados fica grandemente prejudicada, tornando importante a utilização de técnicas para diminuir a quantidade de objetos.

A AA pode ser utilizada com este objetivo, substituindo os dados originais por estatísticas descritivas de cada grupo.

- **Taxonomia.**

Classificação dos objetos em classes hierárquicas. A cada nível da hierarquia, um grupo se divide em dois. Cada subdivisão pode ser atribuída a uma variável que diferencia os grupos, dando uma interpretação aos níveis hierárquicos. A classificação hierárquica pode também ser usada como base para determinar uma partição de X dando uma orientação para se decidir o número de agrupamentos e fornecendo uma solução inicial para a classificação não-hierárquica.

- **Identificação de observações aberrantes.**

Os agrupamentos com um número excessivamente pequeno de objetos freqüentemente indicam observações aberrantes, os chamados *outliers*. De modo geral, devem ser eliminados de análises subseqüentes.

O conceito de agrupamento é de difícil formalização. Intuitivamente, pode-se definir um agrupamento como um conjunto de objetos parecidos entre si e, ao mesmo tempo, diferentes de objetos pertencentes a outros agrupamentos. Representando os objetos como n pontos no espaço com p variáveis os agrupamentos podem ser definidos como regiões contínuas com altas densidades de pontos separadas de outras regiões – também de alta densidade – por regi-

ões de baixa densidade. Uma característica importante do problema de agrupamentos é a dificuldade de se formalizar critérios para definir o número k de agrupamentos. Na prática, este número é decidido após várias tentativas, examinando a separação dos agrupamentos juntamente com a dispersão e o número de elementos de cada um. Existe uma enorme variedade de métodos de construção de agrupamentos propostos na literatura. Neste estudo, foi utilizado um método não-hierárquico também conhecido como *K-means*. Visto que, a aplicação de métodos hierárquicos requer muita memória e, por isso, pode ser inviável quando há uma grande quantidade de dados.

A. Métodos Não-Hierárquicos (K-MEANS)

Os métodos não-hierárquicos são em geral mais rápidos e de simples implementação. Na sua forma básica, o método *K-means* parte de um conjunto de centróides de classifica os objetos no agrupamento cujo centróide está mais próximo. No caso geral, o número de agrupamentos a ser obtido deve ser determinado externamente. Uma vez classificados, os objetos induzem um novo conjunto de centróides que por sua vez induzem uma nova classificação e assim por diante até que o algoritmo forneça os mesmos agrupamentos duas interações seguidas. Esquemáticamente, tem-se:



FIGURA 2 – Esquema do K-means

Esta metodologia de agrupamentos foi feita, como exemplo, nas subestações ARARAS 1 e UBATUBA 1. Na primeira, como tem um comportamento mais homogêneo, foi possível classificar os dados de carga reativa em 5 grupos esquematizados a seguir:




FIGURA 3 – Agrupamentos da subestação ARARAS 1

Observou-se que os dados de carga reativa (exemplo feito para o ano de 2000) se dividem em verão e inverno; dias úteis e domingo / feriado; e ainda, a segunda-feira e o sábado apresentam comportamentos diferenciados.

No caso da subestação UBATUBA 1, foi possível classificar somente em dois grupos, verão e inverno (figura 4). Este resultado é importante já que os compensadores se

fazem presentes somente nos meses de inverno, como comprova a figura 5.




FIGURA 4 – Agrupamento da subestação UBATUBA 1

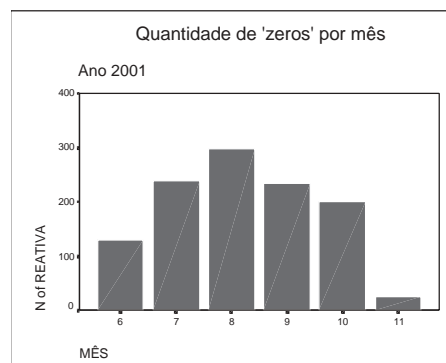


FIGURA 5 – Presença de compensadores na subestação UBATUBA 1

Estes grupos foram também observados nos dados de carga ativa para as subestações correspondentes. A similaridade entre eles facilita o trabalho em conjunto das cargas. Como já foi visto em trabalhos anteriores, é comum utilizar a classificação de carga leve, média e pesada convencional. Porém, após um estudo para redução de dimensionalidade, verificou-se que de acordo com os grupos acima encontrados, a classificação de carga leve, média e pesada pode seguir dimensões diferentes às convencionais. O item a seguir mostra a metodologia adotada.

B. Análise de Fatores – AF

É técnica de redução de dimensionalidade que tem por objetivo principal a identificação de variáveis chamadas *Fatores Latentes* que sintetizam a informação comum a grupos de variáveis. A AF é baseada em um modelo explícito, em que as variáveis de X são expressas como uma função linear de um número reduzido de fatores latentes. Nela se deseja interpretar os fatores através de uma análise subjetiva do conteúdo das variáveis que ele representa. Assim seu objetivo final é identificar conjuntos de variáveis associadas a cada fator. O modelo de AF é invariante a mudanças de escala. Isto é, a direção dos novos eixos correspondentes aos fatores permanece a mesma qualquer que seja a unidade de medida de X . Os fatores podem sofrer uma rotação sem prejuízo para o modelo, pois a matriz de covariância dos fatores continuará sendo a identidade. A adequação da escolha do número de componentes é julgada a partir da proporção

da variância explicada pelas componentes, ou seja, a proporção da comunalidade total para a variância total é um importante indicador da qualidade do modelo. O principal aspecto que distingue a AF dos demais métodos de redução de dimensionalidade é o que a AF tem por objetivo não só a redução de dimensionalidade como também a interpretabilidade das novas variáveis. Para isso, os novos eixos devem ser, cada um separadamente, altamente correlacionados com diferentes grupos de variáveis. Neste aspecto, a AF funciona também como uma técnica de agrupamento de variáveis. Os métodos de determinação de matriz de fatores, no entanto não levam em consideração sua interpretabilidade. Note-se também que esta matriz será tanto mais interpretável quanto mais os pesos têm valores extremos. Um recurso para melhorar a interpretabilidade é realizar uma rotação rígida (eixos giram em conjunto) dos eixos. Isto pode ser feito sem prejuízo para a qualidade de ajuste do modelo. O método para determinar rotações ortogonais dos fatores neste estudo, foi o conhecido como *Varimax*.

C. Rotação Varimax

O objetivo deste método é encontrar uma rotação dos fatores que maximize a variância do quadrado das colunas da matriz transposta de fatores. Maximizando a variância, espera-se obter o máximo de valores extremos para os pesos de cada da matriz de pesos.

Os valores dos fatores podem eventualmente ser utilizados em análises subsequentes, com entrada para um outro modelo. Porém, os fatores não são observáveis e nem se pode obtê-los através de uma transformação inversa.

D. Relação entre as Técnicas

Existe uma relação entre os métodos de AA e os métodos de redução de dimensionalidade. A AF tem como objetivo a redução do número de variáveis. Para isso, novas variáveis são criadas – fatores comuns – que, mesmo em menor número, preservam a maior parte da informação. Frequentemente, há também o interesse de interpretar as novas variáveis com base no peso dos fatores.

A AA é uma técnica de redução de complexidade através da diminuição do número de objetos, que serão substituídos pelos grupos. Analogamente à interpretação dos fatores em AF, frequentemente é necessário caracterizar os grupos, determinando qual ou quais variáveis os diferenciam.

Ainda comparando AA com AF. As técnicas de redução de dimensionalidade são baseadas na matriz de covariância ou de correlação, as quais expressam o grau de associação entre cada par de variáveis. Também na AA, é necessário construir uma matriz que reflita a semelhança

entre os objetos dois a dois. Esta matriz é a matriz de similaridade, ou, alternativamente, a matriz de distância.

E. Resultados Alcançados

Aplicando AF nas subestações ARARAS 1 e UBATUBA 1, a classificação de carga reativa leve, média e pesada segue linhas diferentes de acordo com o grupos encontrados anteriormente na AA. A seguir serão apresentados alguns exemplos das ‘novas’ classificações de carga reativa leve, média e pesada. Para a subestação ARARAS 1, nos dias úteis e verão, observa-se: carga reativa leve= 1 às 5h e 14 às 17h; carga reativa média= 9 às 13h; carga reativa pesada= 6 às 8h e 18 às 24h. Já para subestação UBATUBA 1, tem-se: carga reativa leve= 1 às 6h e 13 às 17h; carga reativa média= 7 às 9h e 18 às 21h; carga reativa pesada= 10 às 12h e 22 às 24h.

TABELA 1

	DIA ÚTIL (DU)			VERÃO VERÃO		
	ARARAS 1			UBATUBA 1		
	Pesada	Leve	Média	Leve	Média	Pesada
H1-Reat		-0,66464		-0,92021		
H2-Reat		-0,69512		-0,94946		
H3-Reat		-0,67278		-0,95796		
H4-Reat		-0,68902		-0,95417		
H5-Reat		-0,67691		-0,93258		
H6-Reat	-0,68115			-0,89623		
H7-Reat	-0,86413				0,645247	
H8-Reat	-0,63736				0,936671	
H9-Reat			0,806711		0,829522	
H10-Reat			0,829348			0,502055
H11-Reat			0,849531			0,653098
H12-Reat			0,788738			0,680345
H13-Reat			0,68939	0,669766		
H14-Reat		0,70478		0,794357		
H15-Reat		0,903515		0,875274		
H16-Reat		0,916618		0,878599		
H17-Reat		0,758993		0,869385		
H18-Reat	0,78023				-0,62461	
H19-Reat	0,521505				-0,92238	
H20-Reat	0,684367				-0,89081	
H21-Reat	0,797072				-0,68786	
H22-Reat	0,842101					-0,80286
H23-Reat	0,801643					-0,92679
H24-Reat	0,755002					-0,92895

Do exposto, na seqüência dos trabalhos serão exploradas as seguintes linhas:

- Completar a série de carga reativa com os valores fornecidos pelos compensadores correspondentes, quando estes forem fixos.
- Trabalhar com as mesmas técnicas com a série de Fator de Potência, pois esta é mais consistente e tem variabilidade menor ($0.5 < FP < 1$). Se encontrarmos um ‘bom’ modelo de previsão para a série de FP, com análises multivariada (incluindo a carga ativa), poder-se-á completar a série de reativo aonde os compensadores atuam.
- Repetir as análises com outras subestações.

■ IV. COMMEND

O desenvolvimento da metodologia para a obtenção dos perfis de curva de carga ativa por segmentos de consumo está sendo efetuado com a participação do EPRI – Electric Power Research Institute – que possui várias ferramentas para esta finalidade. A equipe da PUC-Rio utilizará o software fornecido pelo EPRI adaptando-o a realidade dos dados da ELEKTRO. Por motivos operacionais, o modelo denominado COMMEND, originalmente desenvolvido para obtenção dos perfis de carga do segmento comercial será utilizado nesta fase, fazendo-se a devida adaptação para os três segmentos (residencial, comercial e industrial).

■ V. CONSIDERAÇÕES FINAIS

Este texto apresentou de forma sucinta as linhas gerais do projeto em andamento, bem como as ferramentas e técnicas empregadas até o momento para o tratamento e recuperação dos dados.

Como principais resultados obtidos, destaca-se a confirmação da possibilidade de obtenção da curva de demanda reativa em função da demanda ativa, por outras técnicas que não o uso simplificado de um fator de potência estimado para as instalações.

A definição de uma ferramenta única para obtenção dos perfis de demanda ativa de cada um dos segmentos de consumo possibilitará avançar para os objetivos finais do projeto, simplificando as atividades de implementação da metodologia, bem como o desenvolvimento de uma ferramenta computacional, viabilizando sua aplicação prática.

■ IV. REFERÊNCIAS BIBLIOGRÁFICAS

LIVROS:

[1] JOHNSON, Richard A.; WICHERN, Dean W.; *Applied Multivariate Statistical Analysis*; Prentice Hall; 4ª edition, 1998.

PERIÓDICOS:

[2] VEIGA, Álvaro; *Análise Multivariada de Dados*; Núcleo de Estatística Computacional – PUC/RIO; 1995.

MANUAIS:

[3] Manual do SPSS 8.