

## 4 Previsão de Carga com Horizonte de Doze Meses em Períodos de Racionamento

O objetivo aqui é obter previsões de carga elétrica de médio prazo, em intervalos mensais, com origem no início da intervenção do racionamento. Propõe-se uma metodologia para representar o impacto da intervenção nessas previsões e fornecer fatores que poderão ser aplicados em situações de intervenção futura semelhante à ocorrida.

A partir da criação de vetores, cujos componentes indicam a taxa de redução dos valores mensais previstos, para a origem em questão, e da sua classificação, são estabelecidos grupos que possuem comportamentos semelhantes diante da intervenção. A técnica utilizada neste trabalho para classificação foi a de Redes Neurais Artificiais do tipo SOM (Self Organizing Maps) com algoritmo de aprendizagem de Kohonen.

O procedimento foi aplicado em algumas séries de carga elétrica de empresas que integram o Sistema Integrado Nacional (SIN) e os resultados encontrados são apresentados.

### 4.1. Mapas Auto Organizáveis de Kohonen

Métodos de agrupamento são usados para identificar uma estrutura natural de similaridades em objetos multidimensionais. Tais métodos visam a classificar um conjunto de  $N$  objetos em  $k$  classes mutuamente exclusivas, de tal forma que os objetos em um mesmo grupo sejam semelhantes entre si, porém, diferentes dos objetos pertencentes a outros grupos. Dependendo do método, o valor de  $k$  pode ou não ser especificado previamente.

Em Pessanha (2002), são apresentados diversos métodos de agrupamento, por exemplo, os métodos Hierárquicos<sup>1</sup> (Ward e

---

<sup>1</sup> Particionam um conjunto de  $N$  objetos seqüencialmente em 2, 3, 4 até  $N-1$  classes, obtendo no final uma estrutura em árvore, semelhante as classificações zoológicas (espécie, gêneros, famílias, ordem, etc).

NUDYC-DESCR2), os métodos Não-Hierárquico<sup>2</sup> (K-Means) e os métodos provenientes de inteligência artificial (Redes Neurais e Algoritmo FCM).

Quaisquer métodos citados acima poderiam ser utilizados nesta dissertação, mas a opção foi pelo mapa de Kohonen (1990), que são redes neurais artificiais utilizadas para classificar vetores de entrada (caracterizados por atributos) em grupos. São conhecidos por seu treinamento não supervisionado e o desconhecimento prévio sobre as classes que serão apresentadas ao treinamento, sendo assim capazes de auto-organizarem-se e reconhecerem padrões automaticamente. A Figura 4.1 mostra uma arquitetura típica de uma rede de Kohonen, que consiste em uma camada de entrada com  $n$  neurônios e uma camada de saída com  $c$  neurônios.

O objetivo básico dos Mapas de Kohonen é agrupar  $m$  elementos de um conjunto de padrões de entrada  $n$ , em  $c$  neurônios, ou seja, projeta-se o espaço de entrada em um espaço de menor dimensão. A ligação, entre os vetores de entrada e o de saída, é feita por protótipos, ou seja, cada neurônio no espaço de saída corresponde a um vetor-peso  $w$  que pode ser visto como um protótipo de características do espaço original, Zanini et al. (1999).

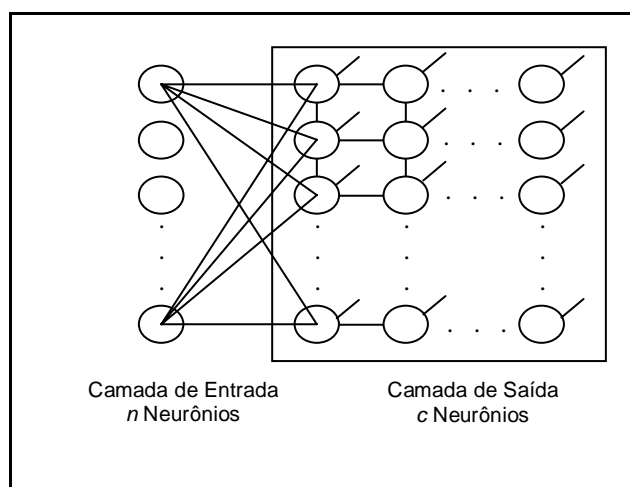


Figura 4.1 - Arquitetura de rede de Kohonen

A função de ativação da rede de *Kohonen* é baseada em uma medida da distância entre o vetor de entrada  $p$  e os pesos  $w$  de cada neurônio, expressa,

<sup>2</sup> Particionam o conjunto de objetos em um número fixo de  $k$  classes de maneira que a heterogeneidade interna da classe seja minimizada.

por exemplo, pela distância euclidiana. A equação 4.1 mostra o estado de ativação de um neurônio:

$$4.1 \quad g_j = \sum_{i=1}^n |p_j - W_{j,i}|$$

Sendo  $W_{j,i} \in \mathfrak{R}^2$  o peso da conexão entre o elemento de entrada  $p_j$  e o neurônio  $i$ .

O treinamento da rede é não supervisionado, portanto, não se conhece, a priori, qual neurônio será ativado para uma dada entrada. Inicialmente, os pesos são escolhidos aleatoriamente e durante a fase de treinamento, os pesos são ajustados de tal forma que vetores de entrada similares ativem sempre o mesmo neurônio de saída, ou seja, pertençam ao mesmo grupo.

O algoritmo proposto por Kohonen pode ser descrito nas seguintes etapas:

- (i) Inicializar os pesos  $W_{j,i}$  de forma aleatória, com zeros ou com valores previamente classificados;
- (ii) Definir os parâmetros da rede: taxa de aprendizagem  $\eta(t)$  e o número de épocas para o treinamento  $N$ ;
- (iii) Escolher os dados para treinamento  $p_j$ ;
- (iv) Cada neurônio na camada de saída computa uma medida de distância calculada pela eq. 4.1 entre o vetor de entrada  $p_j$  e os pesos das ligações  $W_{j,i}$ . Os pesos do neurônio vencedor, aquele que possui a menor distância, é otimizado juntamente com os pesos dos neurônios vizinhos através da eq. 4.2:

$$4.2 \quad W_{j,i}(t+1) = \begin{cases} W_{j,i}(t) + \eta(t)(p_j - W_{j,i}(t)), & \text{se } i \text{ pertencer a vizinhança } \Lambda_i \\ W_{j,i}(t), & \text{caso contrário} \end{cases}$$

Sendo  $W_{j,i}$  o peso entre o neurônio de entrada  $j$  e o neurônio de saída  $i$ ;  $\Lambda_i$  a vizinhança da unidade  $i$  vencedora;  $\eta(t)$  a taxa de aprendizagem variando de 0 a 1, geralmente é reduzida com o tempo pela expressão:

$$4.3 \quad \eta(t) = \eta(0)(1 - t/T)$$

Onde  $t$  é a iteração no tempo e  $T$  o número total de iterações. A vizinhança  $\Lambda_i$  é inicialmente grande, sendo diminuída ao longo do tempo até atingir o tamanho mínimo, ou seja, o próprio neurônio vencedor.

- (v) Repetir o processo até alcançar a convergência.

Esse tipo de rede neural artificial possui uma característica que a torna diferente dos outros classificadores (Zanini et al., 1999): a propriedade de manutenção da topologia do subespaço de saída. Em síntese, através do aprendizado competitivo, os neurônios especializam-se em responder a estímulos pertencentes a uma mesma classe, implicando no fato de que a topologia no espaço de saída reflete características semelhantes no espaço original, isto é, entradas com características parecidas serão mapeadas em regiões próximas no espaço de saída.

Essa rede será empregada na classificação dos IRP, seção 4.2, para a criação dos FRP, seção 4.3.

## 4.2. Indicadores de Redução de Previsão

Como foram mostradas no capítulo 3, as previsões de carga elétrica um passo à frente, feitas pelo sistema de previsão do ONS, possuem erro absoluto médio abaixo de 5%. Agora, o interesse volta-se para o desempenho das previsões combinadas do tipo múltiplos passos. A métrica utilizada para avaliação foi o MAPE (Mean Absolute Percent Error), percentual do erro médio absoluto, medido para previsões até 12 passos à frente:

$$4.4 \quad MAPE = 100 \times \sum_{i=1}^n \left( \left| \frac{\hat{y}_{i|t} - y_i}{y_i} \right| \right) / n$$

Onde  $\hat{y}_{i|t}$  é a previsão com origem em  $t$  e  $y_i$  é o valor observado do processo. A Tabela 4.1, apresenta os resultados da eq. 4.4, referentes às previsões com origem em abril de 2000 para 28 distribuidoras de energia do SIN.

EMPRESA	MAPE	EMPRESA	MAPE
CELPA	2,25%	LIGHT	4,30%
CEMAR	3,54%	CERJ	3,72%
CEPISA	3,10%	ELEKTRO	1,45%
COELCE	1,81%	CPFL	3,44%
COSERN	2,32%	BANDEIRANTE	4,57%
SAELPA	1,75%	CEMAT	4,27%
CELB	3,37%	CELG	4,03%
CELPE	1,46%	CEB	0,93%
CEAL	4,00%	COPEL	1,74%
ENERGIPE	1,87%	CELESC	2,27%
COELBA	2,54%	CEEE	2,16%
CHESF	4,76%	AES - SUL	4,17%
CEMIG	3,66%	RGE - R.G.ENERGIA	2,04%
ESCELSA	4,33%	ENERSUL	2,42%

Tabela 4.1 – MAPE de 28 distribuidoras do SIN

Como o sistema de previsão apresenta MAPE entre 0% e 5%, compara-se a magnitude do nível da carga observada em relação à série de carga que seria consumida se não houvesse o racionamento. Para isso, faz-se como premissa necessária para esse estudo considerar a série de previsões combinadas de energia com um horizonte de doze passos à frente,  $\hat{Y}_{t+i|t} = \{\hat{y}_{t+1|t}, \hat{y}_{t+2|t}, \hat{y}_{t+3|t}, \dots, \hat{y}_{t+12|t}\}$  como a verdadeira série de carga elétrica sem a intervenção do racionamento. A partir desse fato, determinou-se a série dos Indicadores de Redução de Previsão (IRP) por:

$$4.5 \quad I_{t+i|t} = \frac{y_{t+i}}{\hat{y}_{t+i|t}}$$

Onde  $y_{t+i}$  é o valor da série de carga elétrica efetivamente observado. Note que, como a tendência das previsões, durante o racionamento, é ser maior que o valor realizado, o  $I_{t+i|t}$  será menor que um, na maioria das vezes.

O racionamento de 2001 teve seu início em junho do mesmo ano (Cardoso, 2001). Porém, a origem escolhida para a construção dos IRP's foi abril

de 2001, já que o mês de maio já havia apresentado queda de consumo de energia em virtude dos novos hábitos dos consumidores brasileiros.

As concessionárias que atendem às regiões abastecidas pelo subsistema Norte e Sul devem possuir IRP's próximos da unidade, uma vez que não foram submetidas à redução de consumo de energia elétrica. Pela mesma linha de raciocínio, as empresas que atendem territórios dos demais sistemas que foram atingidas pelo racionamento devem possuir IRP's com valores inferiores à unidade.

Para exemplificar, na Figura 4.2 são apresentadas os vetores de IRP's para as concessionárias do subsistema Nordeste, no período de maio de 2001 a abril de 2002.

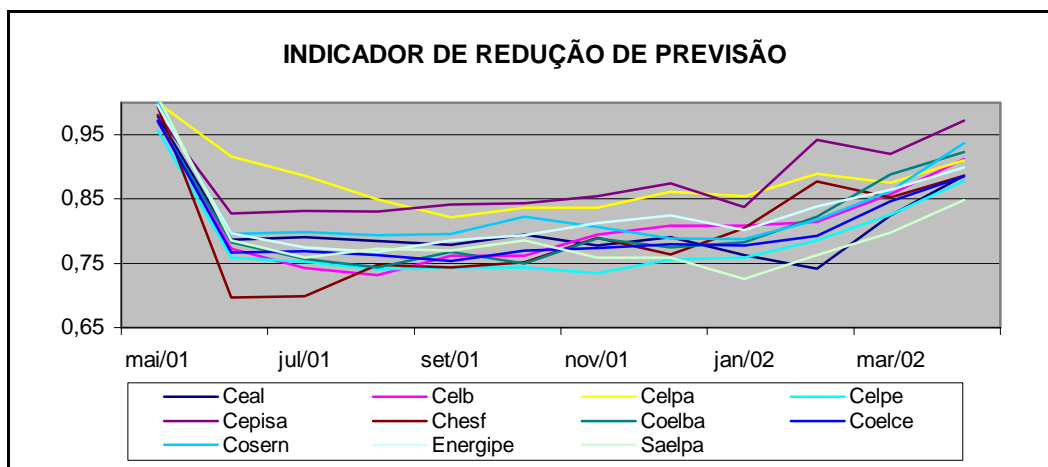


Figura 4.2 – IRP de empresas do subsistema Nordeste

Analisando os vetores de IRP da Figura 4.2, verifica-se que nos primeiros quatro meses de racionamento, todas têm uma redução acima de 20% nas previsões de carga elétrica. A partir do quinto mês os IRP's mantêm-se constante e nos últimos três meses apresentam uma indicação de crescimento. Dessas empresas, pode-se perceber que as distribuidoras de energia Celpa e Cepisa apresentam menores reduções nas previsões, isto é, as companhias com menor impacto diante da crise.

O passo seguinte foi encontrar semelhanças em 28 vetores de IRP's. Uma das formas de obter essa informação é através da utilização de mapas auto-organizáveis (SOM). Neste trabalho, serão utilizados os SOM's conhecidos como redes de *Kohonen*, apresentados na seção 4.1.

### 4.3. Classificação dos IRP's

Esta etapa do trabalho compreende o estudo dos vetores de Indicadores de Redução da Previsão, IRP, (definido na seção 4.2), das distribuidoras de energia que compõem o SIN. O objetivo é encontrar similaridades entre as IRP das empresas de forma a classificá-las em padrões típicos, em que cada grupo será caracterizado por um vetor definido como Fatores de Redução de Previsão (FRP). Para análise de agrupamento, foram utilizados mapas auto-organizáveis de *Kohonen*.

Todos os procedimentos da análise e classificação dos vetores IRP's foram efetuados no software Matlab 6.1.

#### 4.3.1. Empresas Analisadas

As empresas que participaram deste estudo são mencionadas na Tabela 4.2, bem como suas respectivas regiões de atuação.

<b>Empresa</b>	<b>Estado</b>	<b>Sub-Sist.</b>	<b>Empresa</b>	<b>Estado</b>	<b>Sub-Sist.</b>
Celpa	PA	NE	Cpfl	SP	SE/CO
Ceal	AL	NE	Copel	PR	S
Celpe	PE	NE	Celesc	SC	S
Cemar	MA	N	Energisa	MS	SE/CO
Cepisa	PI	NE	Cemat	MT	SE/CO
Coelce	CE	NE	Celg	GO	SE/CO
Cosern	RN	NE	Ceb	DF	SE/CO
Saelpa	PB	NE	Cerj	RJ	SE/CO
Celb	PB	NE	Elektro	SP	SE/CO
Energipe	SE	NE	R.G.Energia	RS	S
Coelba	BA	NE	Ceee	RS	S
Cemig	MG	SE/CO	Bandeirante	SP	SE/CO
Escelsa	ES	SE/CO	Eletropaulo	SP	SE/CO
Light	RJ	SE/CO	Aes - Sul	RS	S

Tabela 4.2 – Empresas de distribuição de energia que compõem o SIN

### 4.3.2. Arquitetura da Rede de Kohonen

O número adequado de classes, ou melhor, de tipologias que caracterizem o conjunto de concessionárias, não é conhecido previamente. Após várias simulações das redes de Kohonen com diversas classes, encontrou-se 6 grupos como resultado final de uma rede bi-dimensional que não concentrasse os padrões em poucas classes.

As variáveis de entrada foram os vetores de IRP's (12 indicadores de cada concessionária) e a rede um mapa bi-dimensional (3x2). O espaço de entrada (matriz de dados 28 x 12 encontrada no apêndice 7.4) será projetado em um espaço de menor dimensão (matriz de dados 6 x 12).

Utilizaram-se 100.000 iterações com arranjo original da rede mostrado conforme a Figura 4.3.




Figura 4.3 – Topologia da rede

Como uma das características do algoritmo de Kohonen é que a topologia no espaço de saída reflete características semelhantes no espaço original serão obtidos a priori, seis grupos de distribuidoras. Cada neurônio especializa-se em responder a estímulos pertencentes a uma mesma classe, lembrando que cada concessionária será representada por um vetor de entrada.

Após a aplicação do algoritmo de Kohonen, cada empresa passa a pertencer a um dos 6 neurônios da rede neural artificial. Ao final, a cada neurônio no espaço de saída, corresponde um vetor-peso  $W$  que pode ser visto como um protótipo de características do espaço original. Esses serão



denominados de Fatores de Redução de Previsão (FRP) de cada grupo de empresa.

A análise será feita, a partir deste momento, para seis concessionárias típicas, cujos vetores FRP são apresentados na Tabela 4.3.

		Vetor-Peso Final											
		1	2	3	4	5	6	7	8	9	10	11	12
Neurônios	1	0,95	0,78	0,76	0,75	0,76	0,76	0,77	0,77	0,78	0,80	0,84	0,88
	2	0,96	0,79	0,79	0,79	0,79	0,79	0,79	0,78	0,79	0,81	0,85	0,91
	3	0,97	0,85	0,85	0,85	0,84	0,86	0,86	0,85	0,86	0,88	0,90	0,94
	4	0,93	0,76	0,74	0,74	0,74	0,74	0,78	0,78	0,79	0,80	0,85	0,89
	5	0,94	0,80	0,79	0,80	0,79	0,80	0,83	0,81	0,84	0,83	0,88	0,93
	6	0,96	0,90	0,90	0,91	0,88	0,91	0,93	0,90	0,93	0,92	0,95	0,98

Tabela 4.3 – Pesos Finais (FRP)

Os resultados do agrupamentos do SOM são mostrados na Tabela 4.4.

Grupo 1	Grupo 2	Grupo 3	Grupo 4	Grupo 5	Grupo 6
Cemar	Cosern	Celpe	Celb	Enersul	Copel
Coelce	Ceal	Cepisa	Cemig		Celesc
Saelpe	Energipe		Escelsa		Aes - Sul
Celpe	Cemat		Light		Ceee
Coelba	Celg		Cerj		R.G.Energia
	Bandeirante		Cpfl		
			Ceb		
			Elektro		
			Eletropaulo		

Tabela 4.4 - Agrupamento de empresas

Observando os vetores FRP mostrados na Tabela 4.4, pode-se perceber similaridade nos grupos 2 e 5 em dez meses (somente diferentes nos meses 7 e 9). Como o grupo 5 apresenta apenas uma empresa, a Enersul será incorporada no padrão típico do grupo 2. Ao torná-la membro deste grupo, o protótipo (vetor-peso  $W$ ) perderá sua utilidade passando a ser apresentado através do centróide  $C_j$  que calcula a média dos objetos da classe, ou seja:

$$4.6 \quad C_j = \frac{1}{n} \sum_{i, x_{ij} \in C_j} x_{ij}$$

Onde  $x_i$  representa os valores de IRP's da empresa  $i$  no mês  $j$ . Os grupos formados e seus respectivos IRP são mostrados na Figura 4.4.

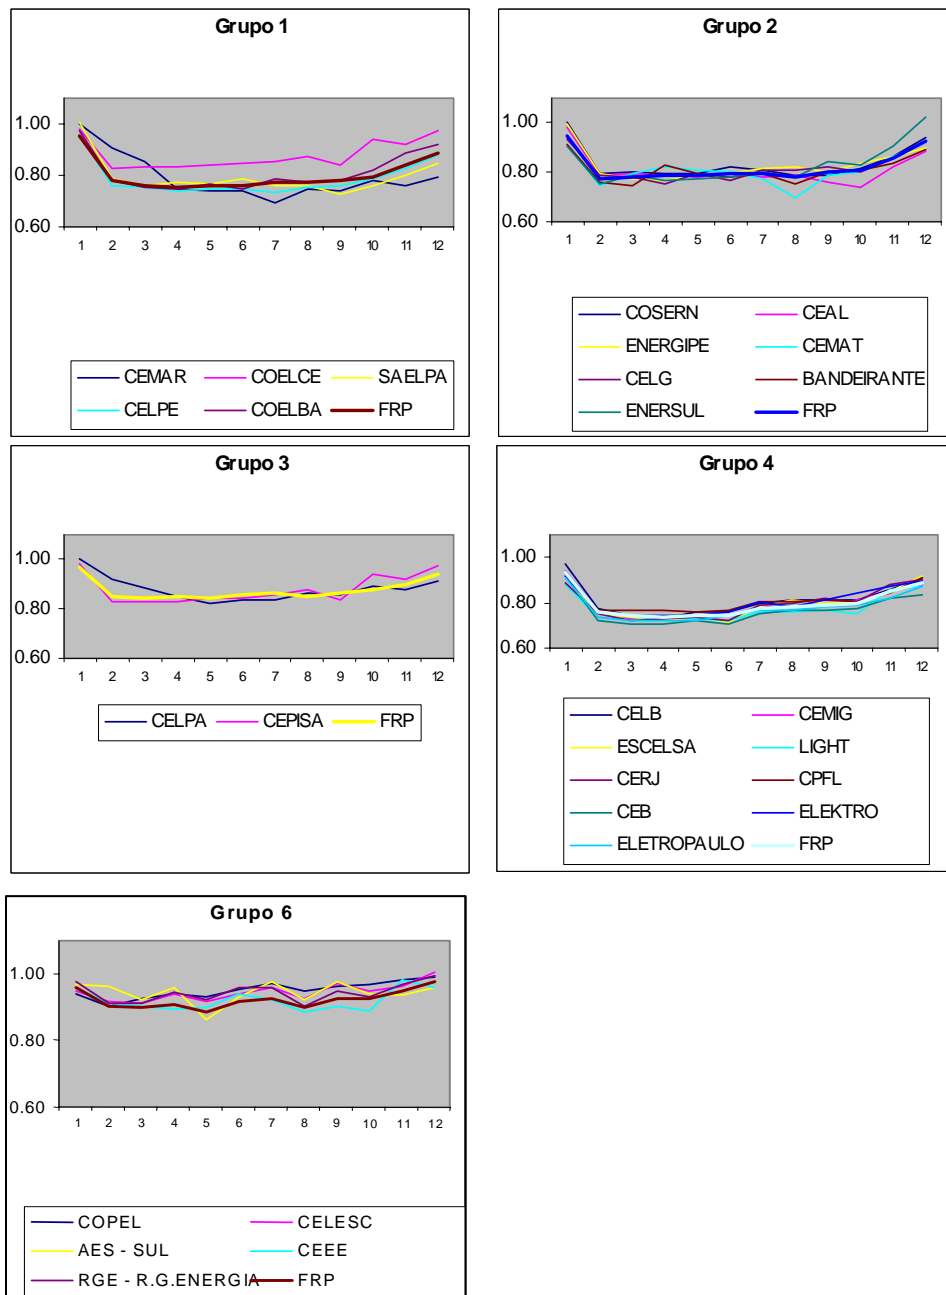


Figura 4.4 – IRP das empresa por grupo

### 4.3.3. Análise dos Agrupamentos

Analisando os cinco gráficos da Figura 4.4, vê-se a caracterização de cada um dos grupos. É importante analisar os vetores FRP juntamente com a visualização da disposição dos neurônios no mapa. Os valores para cada agrupamento representam o último vetor ajustado pelo algoritmo de *Kohonen*, podendo ser utilizado para caracterizar, em uma primeira análise, cada padrão.

#### **Grupo 1: Impacto Alto (IA)**

É formado por empresas predominantemente do Subsistema Nordeste, exceto a distribuidora CEMAR que atende ao Subsistema Norte. Analisando os vetores de IRP referentes às empresas desse grupo, percebe-se um comportamento não homogêneo dos vetores IRP.

#### **Grupo 2: Impacto Médio (IM)**

É formado por empresas representantes do Subsistema Nordeste e Sudeste / Centro-Oeste e possuem junto com o neurônio quatro os menores valores de vetor FRP. Este grupo mostrou-se bem homogêneo com os vetores de IRP, apresentando características semelhantes. Observa-se também que os vetores IRP's das empresas que compõem esse grupo apresentam a menor variação para todos os meses.

#### **Grupo 3: Impacto Baixo (IB)**

Sobre o neurônio três, verifica-se a participação de regiões atendidas pelo Subsistema Nordeste e Norte. Das 28 distribuidoras atingidas diretamente pela medida provisória imposta pelo governo federal Cardoso (2001), essas mostraram ser as menos afetadas, com fator e redução de aproximadamente 15% exceto nos meses 11 e 12. Esse resultado guarda coerência com a forma com que a medida provisória foi implementada nestas regiões.

#### **Grupo 4: Impacto Muito Alto (IMA)**

No que tange ao neurônio quatro, pelos resultados do algoritmo, verifica-se a participação de regiões atendidas pelo Subsistema Sudeste. Representa o grupo com menores valores de vetor FRP. Devem-se ressaltar as suas particularidades, quais sejam: a) redução acima dos 20% estabelecidos pelo governo, caracterizando o grupo que mais reduziu a série de carga elétrica esperada e b) Similaridade com as empresas do neurônio dois. É formado por empresas representantes do Subsistema Sudeste em companhia das empresas Ceb e Celb. Esse grupo mostrou-se bem homogêneo com vetores de IRP apresentando características semelhantes.

#### **Grupo 6: Impacto Muito Baixo (IMB)**

É formado por empresas representantes do Subsistema Sul, o neurônio 6 apresenta os valores para os indicadores mais próximos da unidade (acima de 0,9 com exceção do mês 5). Isso significa que, nesse grupo as previsões do PREVCAR comportaram-se próximo do valor observado. Nesse neurônio encontram-se todas as distribuidoras do sul do país. Tal grupo mostrou-se bem homogêneo com vetores de IRP apresentando características semelhantes.

#### **4.4. Utilização dos vetores FRP para Previsão**

Os procedimentos de previsão, apresentados no capítulo 3, para períodos de intervenção, foram desenvolvidos visando a melhorar a previsão um passo à frente (no instante após o início da intervenção). Em aplicações em que o interesse abrange horizontes mais longos, procedimentos alternativos que possam melhorar a previsão em todo o horizonte tornam-se necessários.

A Figura 4.5 ilustra uma série de carga elétrica em MW Médio e a sua previsão no horizonte de 12 meses realizada no início do racionamento, ocorrido em junho de 2001.




Figura 4.5 – Previsão doze passos à frente feita em maio de 2001

Como se pode observar nessa figura, os modelos analisados apresentaram erros de previsão consideravelmente alto neste período, fato que ocorreria quaisquer que fossem os modelos empregados.

A proposta, no caso, é aplicar os vetores de redução de previsão, FRP, definidos na seção anterior, nos valores previstos, de acordo com a classificação da série nos grupos estabelecidos: Impacto Alto (IA), Impacto Médio (IM), Impacto Baixo (IB), Impacto Muito Alto (IMA) e Impacto Muito Baixo (IMB). O procedimento consiste de:

1. Classificar a série em um dos grupos.
2. Realizar a previsão por quaisquer métodos.
3. Aplicar o vetor FRP do grupo correspondente à série na previsão realizada, segundo a eq. 4.7, para obter a previsão corrigida.

$$4.7 \quad \hat{y}c_i = w_i \hat{y}_i$$

Onde:

$\hat{y}c_i$  - Previsão corrigida para o instante  $i$  do horizonte;

$w_i$  - Componente  $i$  do vetor FRP

$\hat{y}_i$  - Previsão realizada para o instante  $i$  do horizonte;

Desse modo, caso o governo federal decreta nova intervenção no consumo de energia, uma estimativa para as previsões em médio prazo de doze meses podem ser obtidas com base nos vetores FRP. Isto é, a previsão de

carga elétrica de cada concessionária deverá ser reduzida em  $(100 - w_i)\%$ . Onde  $w_i$  representa o componente  $i$  do vetor FRP. Após repetir esse procedimento para todos os doze meses, usando sempre os componentes relativos a cada mês, a previsão estará concluída.

Vale ressaltar que tal procedimento é válido somente para previsões com origem fixa no mês anterior ao início do racionamento. A utilização dos vetores FRP para a realização de previsão em médio prazo mostra-se mais adequada do que fosse empregado somente os IRP's de cada concessionária. Isso ocorre pelo fato das componentes do FRP minimizarem possíveis pontos discrepantes na série de carga elétrica.

#### **4.4.1. Previsão para outros níveis de racionamento**

A metodologia para definir fatores de redução com outros níveis de racionamento, parte de uma transformação no vetor FRP original. Segue, então, o procedimento:

Primeiramente, define-se a dimensão  $X\%$  da redução de consumo de energia elétrica. O vetor original de redutores de previsão FRP foi estabelecido a partir de um racionamento de 20%. Assim, temos a série a partir do racionamento como segue:

$$4.8 \quad FRP' = \frac{(1 - X\%)}{(1 - 20\%)} FRP$$

Onde  $FRP'$  representa o novo vetor de fatores de redução de previsão a ser aplicado nas previsões para uma redução de  $X\%$ .

### **4.5. Estudo de Caso**

#### **4.5.1. Estudo de Caso 1**

A série temporal examinada, nesse primeiro estudo, foi predita com o auxílio do sistema de previsão PREVCAR. Nessa simulação foram analisados

valores referentes à já citada Série 1, constituída de dados de carga elétrica mensal, no período compreendido entre o mês de janeiro de 1983 a dezembro de 2002, totalizando 240 observações.

Visando a facilitar a obtenção e a avaliação dos resultados, foi definido um nível de racionamento de energia hipotético, iniciando em *fevereiro de 2003*, com as mesmas características que a ocorrida na construção da FRP original. Ou seja, metas de redução de carga elétrica de 20% em todas as concessionárias integradas ao SIN (Cardoso, 2001), exceto as empresas que abastecem a região sul do país.

O primeiro passo para aplicar os fatores de redução na previsão é apontar em qual dos cinco grupos de FRP, a Série 1 está inserida. Visto que a série temporal participa do neurônio 4, os fatores de redução mensal são identificados na Tabela 4.5.

		Peso Final de cada Neurônio											
		1	2	3	4	5	6	7	8	9	10	11	12
Neurônios	1	0,95	0,78	0,76	0,75	0,76	0,76	0,77	0,77	0,78	0,80	0,84	0,88
	2	0,95	0,78	0,78	0,79	0,79	0,79	0,80	0,78	0,80	0,81	0,86	0,92
	3	0,97	0,85	0,85	0,85	0,84	0,86	0,86	0,85	0,86	0,88	0,90	0,94
	4	0,93	0,76	0,74	0,74	0,74	0,74	0,78	0,78	0,79	0,80	0,85	0,89
	5												
	6	0,96	0,90	0,90	0,91	0,88	0,91	0,93	0,90	0,93	0,92	0,95	0,98

Tabela 4.5 - FRP estimada para cada grupo

Considerando que o horizonte de previsão a ser adotado no estudo de caso foi definido como sendo de 12 meses, foram geradas, a partir do sistema PREVCAR, previsões combinadas doze passos à frente de carga elétrica para o período de janeiro de 2003 a dezembro de 2003. Lembra-se que, tanto os vetores FRP quanto as previsões são gerados a partir do mês anterior ao racionamento.

Em seguida, os valores previstos são ajustados pelo vetor FRP do grupo 4, isto é, as previsões são reduzidas conforme é mostrado na Tabela 4.6.

Data	Previsão Combinada	Redutor (FRP)	Previsão para Racionamento
jan-03	4.821	0,93	4.485
fev-03	4.954	0,76	3.769
mar-03	5.047	0,74	3.749
abr-03	5.078	0,74	3.748
mai-03	5.129	0,74	3.806
jun-03	5.100	0,74	3.789
jul-03	5.120	0,78	3.972
ago-03	5.176	0,78	4.042
set-03	5.225	0,79	4.124
out-03	5.185	0,80	4.143
nov-03	5.075	0,85	4.296
dez-03	4.970	0,89	4.421

Tabela 4.6 – Previsão doze passos à frente utilizando FRP

O gráfico da Figura 4.6 ilustra como se comportariam as previsões de carga com horizonte de até doze meses à frente em duas situações distintas: previsões em períodos com ausência de intervenções e previsões com a presença de racionamento. Observa-se que, embora a intervenção tenha iniciado em fevereiro de 2003, no mês que antecede ao evento, isto é, em janeiro desse mesmo ano, já é previsto uma redução de carga elétrica devido aos novos hábitos que os consumidores irão adquirir.

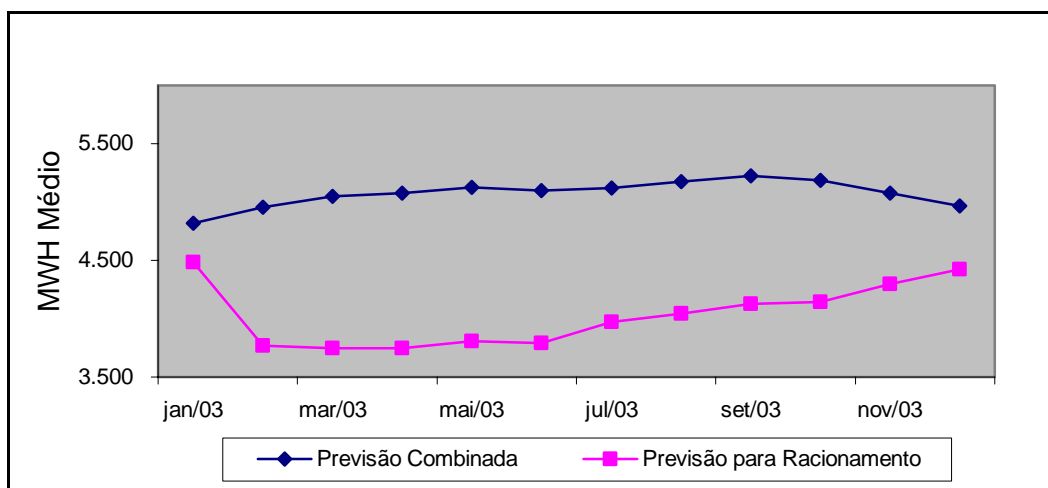


Figura 4.6 - Previsão doze passos à frente utilizando FRP

A simulação acima ilustra de forma simples e clara, a forma pela qual as informações provenientes do racionamento ocorrido em 2001 poderiam ser



utilizadas como estimativas iniciais de previsões revistas quando da ocorrência no futuro de um racionamento com características similares. No caso, assumiu-se que o racionamento hipotético teve a mesma meta de redução de 20%.

Esse mesmo estudo foi feito para outras cinco séries, cujo percentual de redução e o período de racionamento foram os mesmos. Os FRP's utilizados e as previsões, durante esse período para essas séries, podem ser encontradas no apêndice 7.5.

#### 4.5.2. Estudo de Caso 2

Para a avaliação das previsões múltiplos passos, com origem no início do racionamento proposto neste trabalho, também foram simuladas séries de carga elétrica para outros níveis de intervenções, acrescidas de variáveis aleatórias em forma de um ruído. Posteriormente, são calculados os erros percentuais médios absolutos (MAPE) das previsões obtidas.

A metodologia proposta para a construção de cenários de racionamento de energia, parte de transformação na Série 1 consumida no período de maio de 2001 a abril de 2002, descrito conforme a seguir:

Primeiro, define-se a dimensão geral  $X\%$  da redução de consumo de energia elétrica que se deseja assumir. Como a série de carga elétrica observada  $y_t$  foi estabelecida a partir de um racionamento imposto pelo governo de 20% (Cardoso, 2001), tem-se que a nova série de carga elétrica  $y'_t$  é definida pela eq. 4.9:

$$4.9 \quad y'_t = \frac{(1 - X\%)}{(1 - 20\%)} y_t$$

Porém, além de alteração do nível da série de carga elétrica, acrescentou-se um distúrbio aleatório  $\eta_t$ , com o intuito de representar uma série diferente da original. Nessas condições, tanto o crescimento quanto o comportamento sazonal da série  $y'_t$ , são considerados semelhantes ao da série observada  $y_t$ .

Agora, considere-se a série de carga elétrica do estudo de caso anterior, Série 1, para um cenário de redução de carga elétrica de 15 %:

$$4.10 \quad y'_t = \frac{(1-15\%)}{(1-20\%)} y_t + \eta_t$$

A componente ruído  $\eta_t$  deve ser aleatório, portanto, foi determinada e calculada a partir de uma distribuição  $N(0, Q)$ , cujo valor  $Q$  é denotado como a variância dos erros de previsão um passo à frente  $e_t = y_t - \hat{y}_{t-1}(1)$  da carga elétrica nos últimos 36 meses. Como ilustração, a Figura 4.7 mostra o comportamento desses erros.




Figura 4.7 – Erros de previsão um passo à frente

A seguir mostra-se a aplicação dos fatores de redução nas previsões nessa série a partir de maio de 2001, a qual será comparada aos valores simulados anteriormente pela série  $y'_t$ . A Figura 4.8 mostra a simulação do sistema sobre os valores criados artificialmente.




Figura 4.8 – Previsão doze passos à frente para série simulada

Com base na Tabela 4.7 pode-se concluir que a aplicação do FRP possui um bom desempenho.

Data	Série com Racion de 15%	Previsão com FRP	APE
mai/01	5.075	5.015	1,18%
jun/01	4.610	4.404	4,46%
jul/01	4.423	4.330	2,11%
ago/01	4.214	4.309	2,25%
set/01	4.294	4.385	2,12%
out/01	4.295	4.371	1,77%
nov/01	4.325	4.385	1,39%
dez/01	4.278	4.357	1,83%
jan/02	4.735	4.522	4,49%
fev/02	4.919	4.663	5,21%
mar/02	4.969	5.003	0,67%
abr/02	5.166	5.255	1,72%

Tabela 4.7 - Previsão doze passos à frente utilizando FRP para série simulada

Essa simulação ilustra que se houvesse um racionamento com as características da série simulada  $y'_t$ , as previsões com o auxílio dos vetores FRP ajustar-se-iam a série de carga elétrica no período de racionamento. No caso, assumiu-se que o racionamento hipotético tivesse uma meta de redução de 15%.

Também foram realizados para outras cinco séries, cujo percentual de redução e o período de racionamento foram os mesmos. Os resultados para essas séries podem ser encontrados no apêndice 7.6.