XX Seminário Nacional de Distribuição de Energia Elétrica
SENDI 2012 - 22 a 26 de outubro
Rio de Janeiro - RJ - Brasil

Héber Henrique Selvo	Jeferson Meneguin Ortega
Empresa Energética do Mato Grosso do Sul S.A.	**Universidade Federal de Mato Grosso do Sul**
heber.selvo@enersul.com.br	jmortega3@gmail.com

COMBINAÇÃO DE PREVISÕES PARA O CONSUMO DE ENERGIA ELÉTRICA DA CLASSE COMERCIAL PELA APLICAÇÃO DE ANÁLISE DE COMPONENTE PRINCIPAL

Palavras-chave

Análise de Componente Principal
Combinação de Previsões
Distribuição de Energia Elétrica
Energia Elétrica
Mercado
Previsão

Resumo

O trabalho descreve a aplicação da técnica de Análise de Componente Principal (PCA) como método alternativo de combinação de previsões (FC) no planejamento de mercado da Enersul S.A.. O método de FC é proposto como solução para o problema de decisão enfrentado pelos gestores na escolha entre os cenários propostos pelos analistas por ocasião da elaboração do plano decenal da distribuidora. A classe comercial é eleita para realização dos testes por ser a segunda em participação no mercado de vendas da empresa e apresentar evolução arrojada, portanto, apresentar maior desafio de ajuste.

Na avaliação de erro do conjunto de projeções o cenáro resultante da aplicação da técnica proposta se mostrou a melhor opção, registrando um MAPE amostral de 1,99%. A utilização do método proposto se mostra a mais vantajosa na escolha entre as projeções para nortear a contratação de energia, pois além de obter a melhor performance em termos de avaliação do erro de projeção, garante antecipadamente um cenário que apresente desvios aceitáveis por congregar características de todos os demais métodos utilizados na combinação.

1. Introdução

A compra de energia para atendimento ao mercado consumidor compõe a maior parcela das despesas de uma concessionária de distribuição, cerca de 40% da receita autorizada da concessionária visa atender a esta

demanda, portanto, a assertividade no planejamento da compra implica em considerável impacto sobre o caixa da empresa. Não obstante a isto, o atual modelo de regulação do Setor Elétrico impõe as concessionárias de distribuição regras de contratação de energia elétrica que penalizam severamente os desvios entre a sua carteira de compra nos leilões (ANEEL, 2007), aonde os contratos de fornecimento são firmados por períodos de até 30 anos, e o mercado de energia realizado. Aliado a isto existe o fato de que, em geral, o mercado planejado é insumo para o planejamento estratégico da empresa como um todo; fluxo de caixa, expansão do sistema de distribuição, compra de equipamentos, políticas de atendimento ao consumidor, campanhas de combate a perdas, etc. Portanto, torna-se claro a importância de se ter boa assertividade na predição do mercado de consumo de energia da distribuidora.

Esta necessidade de assertividade tem promovido a busca por novos e diferentes modelos de predição de séries temporais a fim de diversificar a descrição das diversas classes de consumo e aumentar a confiabilidade entre os cenários. Entre os modelos de previsão mais aplicados estão o Auto Regressivo de Médias Móveis (ARIMA), Vetor Auto Regressivo Com Correção de Erros (STORCK, 2008), Suavização Exponencial de Holt Winters (SAMOHYL & SOUZA, 2005), Redes Neurais Artificiais (CONDE, G. et al, 2007), Modelos de Decomposição de Séries Temporais (SAPANKEVYCH, N.I. & SANKAR, R., 2009), Modelos Determinísticos, Meta Heurísticas, etc.

A aplicação desta gama de opções gera uma quantidade razoável de cenários de previsão, que refletem, por exemplo; as diferenças de aproximação entre os modelos, as possíveis composições de variáveis exógenas, o julgamento subjetivo do analista, etc. Esta diversidade de informações é interessante, tendo em vista que diversas possibilidades de comportamento estão descritas neste *set* de informações. Porém, para o gestor do negócio isto cria um problema de decisão; como extrair a melhor informação das previsões? Qual previsão deve ser escolhida como cenário base? Para apoio nesta tomada de decisão, usualmente, o gestor se orienta pelos desvios "dentro da amostra" de cada modelo. Entretanto diversos autores, entre eles ASHLEY (ASHLEY, 2003), afirmam que a aplicação deste tipo de metodologia só é conclusiva quando utilizados ao menos 100 dados fora da amostra, o que se torna impraticável no caso de séries mensalizadas, pois seria o equivalente a abrir mão de mais de oito anos de informação.

Neste contexto, este trabalho apresenta uma metodologia capaz de compor um novo cenário de previsão com base na saída dos diversos modelos de predição. De uma perspectiva teórica, a não ser que fosse possível identificar previamente um modelo individual que gerasse menores erros de predição que os seus competidores, a combinação de projeções (*forecast combination* – FC) oferece ganhos de diversificação que torna mais atrativo combinar cenários individuais a depositar a confiança nos resultados de um único modelo (TIMMERMANN, 2005). Isto é, a idéia principal em torno da aplicação deste método é traduzir, para o gestor, toda a informação contida nos cenários inicialmente propostos em uma nova série, que necessariamente apresenta maior confiabilidade na sua aplicação.

2. Desenvolvimento

Com apoio da Enersul obtivemos acesso ao banco de dados de mercado com as séries históricas de consumo de energia elétrica da área de concessão, bem como os cenários utilizados para elaboração do plano decenal da empresa, que é realizado anualmente entre os meses de agosto e outubro. O resultado do plano decenal dá subsídios ao planejamento orçamentário da companhia e contempla atender, sobretudo, as demandas setoriais de planejamento elétrico e energético. Entre os principais clientes setoriais dos estudos estão a Empresa de Planejamento Energético (EPE) e o Operador Nacional do Sistema (ONS).

O banco de dados da série histórica está estruturado com informações de consumo medido e consumo faturado em kWh, com periodicidade mensal e abertura por classe de serviço. Devido ao fato de o consumo medido representar melhor o ponto de operação dos consumidores e também por ser este o parâmetro utilizado nos estudos da Enersul, optou-se trabalhar com esta informação. Uma análise prévia do consumo

medido por classe no período de janeiro a dezembro de 2011 nos mostra que a categoria com maior participação nas vendas da empresa é a classe residencial, com 35% do mercado de consumo de energia elétrica, logo em seguida vem a classe comercial com 24%, conforme demonstrado na figura 01.

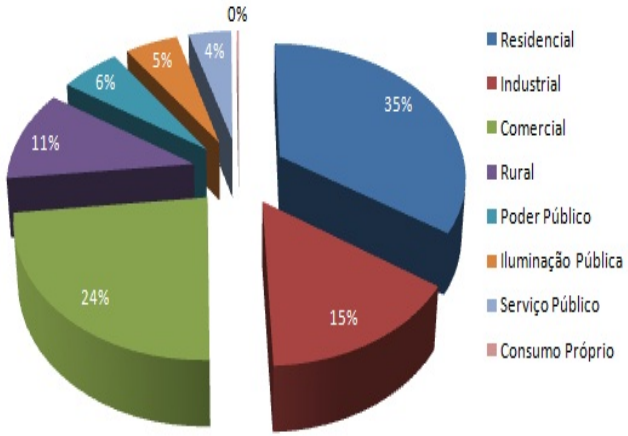

Figura 01 – Participação por classe de serviço no mercado de vendas da Enersul em 2011

Para definição da classe de serviço a ser analisada separamos, inicialmente, as três maiores classes em participação e expurgamos o efeito da migração de clientes para o Ambiente de Contratação Livre (ACL). As séries de consumo foram então normalizadas fazendo-se o consumo no ano de 1.996 igual a 100 a fim de possibilitar a sua análise comparativa em termos de evolução. Verifica-se que a classe industrial apresenta o desempenho mais pujante dentre as séries, porém com uma significativa "quebra estrutural" em 2009 causada pela crise do *subprime* que atingiu especialmente a produção industrial brasileira (CNI, 2009). A classe comercial apresenta o segundo melhor desempenho global, porém seu último período de expansão (2.009 a 2.011) é o mais robusto dentre os três. Da sua análise percebe-se três períodos distintos de evolução;

1. **1.996 a 2.000:** Evolução média de +7,9%. Interrompido pelo racionamento de 2.001,
2. **2.002 a 2.008:** Crescimento moderado, com taxa média de evolução anual de +3,6%,
3. **2.009 a 2.011:** Período de forte expansão. Taxa média de evolução de 9,6% ao ano.

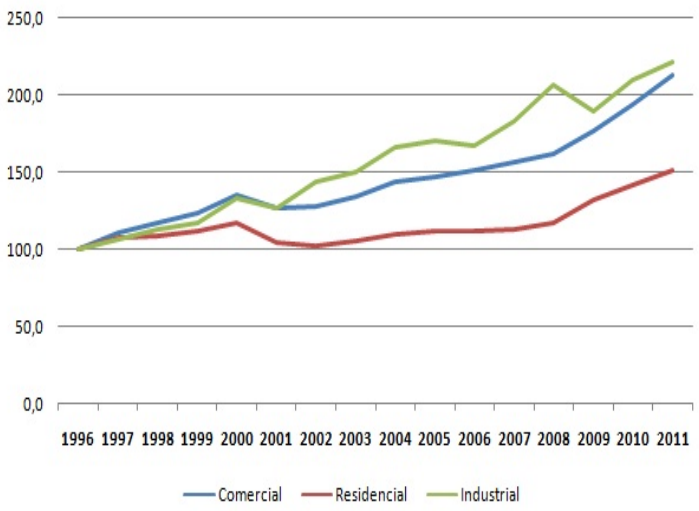

Figura 02 – Consumo anual normalizado das classes comercial e residencial com 1.996 = 100.

Em complemento, no período 2.007 a 2.011, seis clientes saíram do mercado cativo da classe comercial da Enersul para o Ambiente de Contratação Livre, representando um consumo médio de 2GWh/mês. O consumo cativo destes clientes, no período em que sua energia era adquirida da concessionária, foi expurgado da série de consumo total afim de que esta refletisse apenas a informação do comportamento dos clientes cativos da empresa.

A ausência de quebras no comportamento desta classe e também o desafio de conceber um modelo que se ajuste corretamente a uma expansão arrojada no último período foi motivador para a sua escolha na aplicação da técnica de FC através de PCA.

ELABORAÇÃO DAS PROJEÇÕES

Para dar início ao processo de predição da série residencial a base de dados foi estruturada com informações apenas a partir de janeiro de 2003, evitando-se assim a quebra estrutural provocada pelo racionamento de energia elétrica ocorrido de junho de 2001 a julho de 2002. Este tipo de consideração já foi aplicado em outros estudos (STORCK, 2008) e diversos trabalhos foram realizados a respeito do impacto do racionamento sobre o comportamento do consumidor (FALCO, 2004), em especial o residencial, que per forma um novo comportamento em relação ao período pré-crise.

Decomposição de Séries Temporais (DST)

A primeira rodada de projeção é elaborada através da técnica de decomposição de séries temporais, que consiste em realizar a descrição probabilística da série através da análise dos seus dados passados para inferir o seu comportamento futuro. Segundo MORETTIN e TOLOI (MORETTIN, P. A. & TOLOI, C. M. C., 2006) considera-se que uma série temporal Z_t pode ser descrita como a soma de três componentes não observáveis;

$$Z_t = T_t + S_t + a_t \quad (1)$$

Onde T_t e S_t representam a tendência e a sazonalidade, respectivamente, enquanto a_t é uma componente aleatória de média zero e variância constante.

A série de consumo é então decomposta pela análise de sua tendência através do pacote estatístico do software Excel. Após a extração da tendência é analisada a sazonalidade, ano a ano, do consumo. Com base na média aritmética dos pesos sazonais uma curva de sazonalidade média é então formada. O próximo passo depende exclusivamente da sensibilidade do analista, que com base na análise da tendência da taxa de evolução do consumo residencial e a sua percepção dos cenários futuros, determina uma nova trajetória de evolução anual. Esta trajetória anual é então mensalizada com base nos pesos calculados para a nova curva de sazonalidade.

Hilbert Spaces (Plataforma Engenho)

A empresa utiliza um software desenvolvido pela consultoria Engenho (Rio de Janeiro) como um trabalho de previsão de mercado iniciado em 2003 e que foi implantado com sucesso em diversas empresas do Setor Elétrico. A sua máquina de projeção é baseada análise funcional evolutiva e Espaços de Hilbert, aonde a previsão é realizada a partir da projeção das variáveis explicativas e de seu impacto na explicada (consumo). Pode-se referir-se aos membros do Espaço de Hilbert, como vetores, seqüências de dados, como cargas, temperaturas, índices econômicos, ou até mesmo as próprias componentes da série temporal. Idealmente o Espaço de Hilbert considerado é um espaço métrico completo, e sua solução ótima satisfaz a Condição de

Ortogonalidade e o Teorema da Projeção, conforme mostrado na Figura 03 (PINTO, 2008).

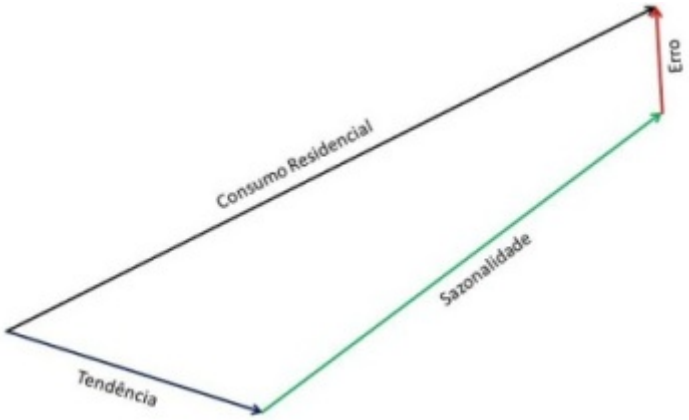

Figura 03 – Representação gráfica do teorema da projeção

Neste ciclo de projeções, devido à escassez de cenários futuros para as variáveis explicativas, a empresa pautou-se pela aplicação do método univariado, utilizando as próprias componentes da série como os vetores de decomposição.

Suavização Exponencial de Holt Winters (Minitab)

O método de Holt-Winters é uma técnica determinística de previsão que faz parte de um conjunto de modelos abrangido pelo Método de Amortecimento Exponencial (MAE), empregado para modelar tendência e sazonalidade existentes na série temporal. O MAE se distingue dos modelos de regressão linear, pois o seu objetivo não é ajustar uma reta aos dados. A todo instante busca-se determinar a melhor reta, ou seja, é uma reta para cada instante de tempo, enquanto, no problema de regressão, pretende-se definir a melhor reta que passa por todos os pontos.

No método de Holt Winters, a modelagem é feita utilizando valores discretos, via fatores sazonais, que caracterizam o período sazonal. Estes fatores podem ser incorporados aos modelos de forma aditiva ou multiplicativa. O primeiro caso retrata séries bem comportadas cuja variabilidade dos fatores é constante. Nos modelos multiplicativos a variância dos fatores sazonais aumenta ou decresce com o nível implícito da série.

ARIMA - (Eviews)

Os modelos Autoregressivo Integrado de Médias móveis (Autoregressive Integrated Moving Average) são baseados na teoria de que o comportamento da própria variável deve responder por seu comportamento futuro (BOX & JENKINS, 1970).

Os parâmetros estimados são usualmente alçados através da aplicação do método de mínimo ou máximo erro quadrático. São realizados testes de probabilidade e análise de resíduos para validar o modelo e utilizá-lo para predição.

ANÁLISE DA COMPONENTE PRINCIPAL

A análise de componente principal (Principal Component Analysis – PCA) foi desenvolvida por Karl Pearson em 1901, e consiste em aplicar, sobre um determinado conjunto de variáveis possivelmente correlacionadas, uma transformação ortogonal a fim de se obter um conjunto de variáveis linearmente independentes chamadas de componentes principais. Pode se dizer ainda que é um modelo fatorial no qual os fatores são baseados na variância total (ARAÚJO, W.O. & COELHO, C. J., 2009).

A transformação é definida de forma que a primeira componente principal possa explicar a maior parte da variância do conjunto original e as componentes posteriores possuam a maior variância possível de forma que mantenham a restrição de ortogonalidade com as componentes anteriores. A ausência de correlação entre as componentes significa que os índices estão medindo diferentes dimensões dos dados.

Para se garantir que as componentes principais sejam linearmente independentes, o conjunto de informações a ser analisado deve ser normalizado (com média zero) (JOLLIFFE, 2002).

A idéia central do método é reduzir a dimensão do conjunto de informações para análise, especialmente quando o banco de dados é composto por uma grande quantidade de variáveis correlacionadas.

Neste trabalho utiliza-se a técnica de PCA para extrair os autovalores de um conjunto de cenários de predição a fim de utilizá-los como pesos relativos formando um novo cenário composto por todas as diferentes especificações dos modelos de predição utilizados na geração destes. Desta forma, é utilizada uma função aditiva ponderada aonde os pesos seriam os percentuais explanatórios dos autovalores de cada componente (ver equação 01). Este método será aqui chamado de FC_{PCA} (equação 02).

$$FC_{PCA} = \sum_{i=1}^{n} \left(\frac{\lambda_i}{\sum_{i=1}^{n} \lambda_i} PC_i \right) \quad (02)$$

$$\text{Onde; } \lambda_i = \text{Autovalor } i$$

APLICAÇÃO E RESULTADOS

Na elaboração do plano decenal a equipe de mercado da Enersul utiliza 5 softwares para elaborar as projeções, dentre estes dois são comerciais, dois foram desenvolvidos via P&D e um foi desenvolvido internamente. Conforme demonstra a tabela 01, exceto pelo softwares “Proj” e “Predict” que geraram apenas um cenário cada, cada software deu origem a seis diferentes cenários de predição de consumo, totalizando um universo de 32 cenários para proceder a aplicação da técnica de FC.

Na elaboração do plano decenal a equipe de mercado da Enersul utiliza 5 softwares para elaborar as projeções, dentre estes dois são comerciais, dois foram desenvolvidos via P&D e um foi desenvolvido internamente. Conforme demonstra a tabela 01, exceto pelo softwares “Proj” e “Predict” que geraram apenas um cenário cada, cada software deu origem a seis diferentes cenários de predição de consumo, totalizando um universo de 32 cenários para proceder a aplicação da técnica de FC.

Tabela 01 – Softwares/modelos utilizados na elaboração dos cenários.

Sorftware	Origem	Modelo	Cenários
Eviews	Comercial	ARIMA	6
		Holt Winters Aditivo	6
		Holt Winters Multiplicativo	6
Minitab	Comercial	Holt Winters Aditivo	6
Engenho	Desenvolvido via P&D	Hilbert Spaces	6
Predict	Desenvolvido via P&D	Redes Neurais Artificiais (RNA)	1
Proj	Desenvolvimento Interno	Decomposição de ST	1
Total de Cenários			**32**

A eleição dos cenários é aqui tratada como o principal problema a ser resolvido. Atualmente a escolha do cenário é feita por um *board* de gestores que utiliza a sua expertise para avaliar de forma empírica qual proposta possui maior probabilidade de realização. Percebe-se que a tomada de decisão atual é baseada em "quanto" o comportamento futuro de um determinado cenário esta aderente ao seu comportamento passado. Esta análise é feita, usualmente, sobre os dados de consumo integralizados anualmente, conforme demonstrado na Figura 04.

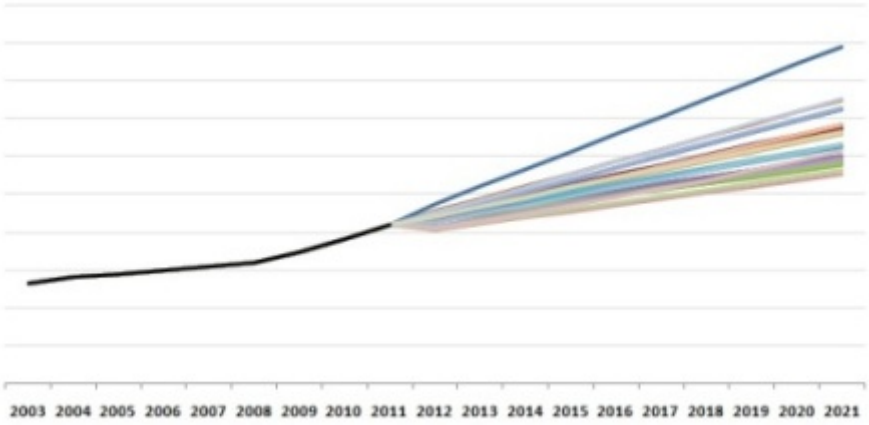

Figura 04 – Consumo anual da classe comercial e os 31 cenários previstos.

Freqüentemente, durante estas reuniões, o preditor é questionado quanto à possibilidade da elaboração de um "novo cenário" que congregue características de dois ou mais cenários apresentados a fim de potencializar a sua possibilidade de ocorrência. Esta sugestão do gestor reflete, na realidade, a sua aversão ao risco e a preocupação de, escolhendo entre cenários diferentes de previsão, não possuir informações sobre o futuro ou sobre qual cenário, por mais que se apresente consistente no momento atual, apresentará a melhor performance.

Frente a esta necessidade a metodologia de *forecast combination* (FC), que já vem sendo aplicada através de diversas técnicas diferentes (ARMSTRONG, 1989), pode ser utilizada de forma a captar o comportamento (variância) dos diversos cenários propostos e concatená-los em uma nova série numérica.

A opção pela aplicação de PCA se faz pela vocação de crítica estatística desta técnica, que utiliza a análise de covariância entre os cenários para extrair informações sobre a sua relevância para descrever a informação da série de consumo.

O sistema de suporte para a aplicação de PCA sobre o conjunto de previsões foi desenvolvido no software MATLAB e apresentou os autovalores e variância explicada conforme a Tabela 02;

Tabela 02 – Autovalores e % da variância explicada do conjunto de cenários

Software	Modelo	Eingenvalues	% da Variância Explicada
Eviews	ARIMA2007	843.120,00	98,0116
Eviews	ARIMA2008	110.020,00	1,6691
Engenho	comc_2008	35.730,00	0,1760
Minitab	ACOM2007	26.670,00	0,0981
Minitab	ACOM2008	11.510,00	0,0183
Eviews HW	ADD2007	8.830,00	0,0107
Minitab	ACOM2006	6.550,00	0,0059
Eviews HW	ADD2006	5.470,00	0,0041
Eviews HW	MULT2007	4.980,00	0,0034
Eviews HW	ADD2008	3.140,00	0,0014
Eviews	ARIMA2005	2.270,00	0,0007
Eviews HW	MULT2006	1.500,00	0,0003
Eviews	ARIMA2004	1.050,00	0,0002
Eviews HW	MULT2008	890,00	0,0001
Eviews	ARIMA2006	530,00	0,0000
Eviews	ARIMA2003	450,00	0,0000
Minitab	ACOM2004	330,00	0,0000
Eviews HW	ADD2004	260,00	0,0000
Minitab	ACOM2005	240,00	0,0000
Eviews HW	ADD2003	150,00	0,0000
Eviews HW	ADD2005	100,00	0,0000
Minitab	ACOM2003	60,00	0,0000
Engenho	comc_2007	30,00	0,0000
Proj	Decomp	10,00	0,0000
Eviews HW	MULT2004	0,00	0,0000
Eviews HW	MULT2005	0,00	0,0000
Eviews HW	MULT2003	0,00	0,0000
Engenho	comc_2006	0,00	0,0000
Engenho	comc_2005	0,00	0,0000
Predict	RN	0,00	0,0000
Engenho	comc_2004	0,00	0,0000
Engenho	comc_2003	0,00	0,0000

É possível avaliar que ao considerar apenas um dos cenários a maior parte da variância (98%) é contemplada, isto pode ser explicado pelo fato de que o conjunto de previsões aqui estudado é composto unicamente por modelos univariados, diferentes entre si, mas que utilizam apenas o seu comportamento passado para descrever o futuro. Desta forma, ao examinarmos a equação 01, percebemos que as componentes T_t e S_t pouco podem se diferenciar entre os modelos, pois, apesar da aplicação de diferentes técnicas para descrevê-las, estas são oriundas de uma mesma série de dados. Assim, a diferença entre a informação de variância extraída pela aplicação de PCA é oriunda, basicamente, da componente aleatória a_t. Na prática verifica-se que apesar da pouca variância explicada ao se incluir os demais cenários, esta informação é importante e não deve ser descartada, pois possibilita que o novo cenário agregue a informação dos demais cenários impedindo que este se baseie apenas na informação de uma única série, que pode estar equivocada para um dado período do tempo.

Portanto o objetivo deste trabalho, com a aplicação de PCA, não é realizar a opção por um determinado cenário, mas sim conceber um novo cenário que agregue as características de todos os modelos propostos.

A equação 02 foi aplicada sobre o conjunto de cenários propostos e os autovalores encontrados para calcular a proporção total de variância explicada por cada CP. A fim de simplificar a demonstração dividimos cada autovalor por 100.000, desta forma temos a seguinte expressão (equação 03) para o cenário resultante (FC_{PCA});

$$FC_{PCA} = \frac{8,4312}{10,6389} * ARIMA2007 + \frac{1,1002}{10,6389} * ARIMA2008 + \frac{0,3573}{10,6389} * comc_{2008} + \frac{0,2667}{10,6389} * ACOM2007 + \frac{0,1151}{10,6389} * ACOM2008 + \frac{0,0823}{10,6389} * ADD2007 + \frac{0,0655}{10,6389} * ACOM2006 + \frac{0,0547}{10,6389} * ADD2006 + \frac{0,0498}{10,6389} * MULT2007 + \frac{0,0314}{10,6389} * ADD2008 + \frac{0,0227}{10,6389} * ARIMA2005 + \frac{0,0150}{10,6389} * MULT2006 + \frac{0,0105}{10,6389} * ARIMA2004 + \frac{0,0089}{10,6389} * MULT2008 + \frac{0,0053}{10,6389} * ARIMA2006 + \frac{0,0045}{10,6389} * ARIMA2003 + \frac{0,0033}{10,6389} * ACOM2004 + \frac{0,0026}{10,6389} * ADD2004 + \frac{0,0024}{10,6389} * ACOM2005 + \frac{0,0015}{10,6389} * ADD2003 + \frac{0,0010}{10,6389} * ADD2005 + \frac{0,0006}{10,6389} * ACOM2003 + \frac{0,0003}{10,6389} * comc_{2007} + \frac{0,0001}{10,6389} * Decomp + \frac{0,0000}{10,6389} * MULT2004 + \frac{0,0000}{10,6389} * MULT2005 + \frac{0,0000}{10,6389} * MULT2003 + \frac{0,0000}{10,6389} * comc_{2006} + \frac{0,0000}{10,6389} * comc_{2005} + \frac{0,0000}{10,6389} * RN + \frac{0,0000}{10,6389} * comc_{2004} + \frac{0,0000}{10,6389} * comc_{2003} \quad (03)$$

O cálculo desta equação, para cada amostra das séries do conjunto de previsões e sua posterior integralização em período anual resultou no cenário exposto pela figura 05. A curva resultante da aplicação da equação 03 está em vermelho, é possível notar a sua alocação parcimoniosa, próxima ao cenário ARIMA2007 (Eviews), descrevendo uma trajetória compatível com a expectativa de evolução da classe.

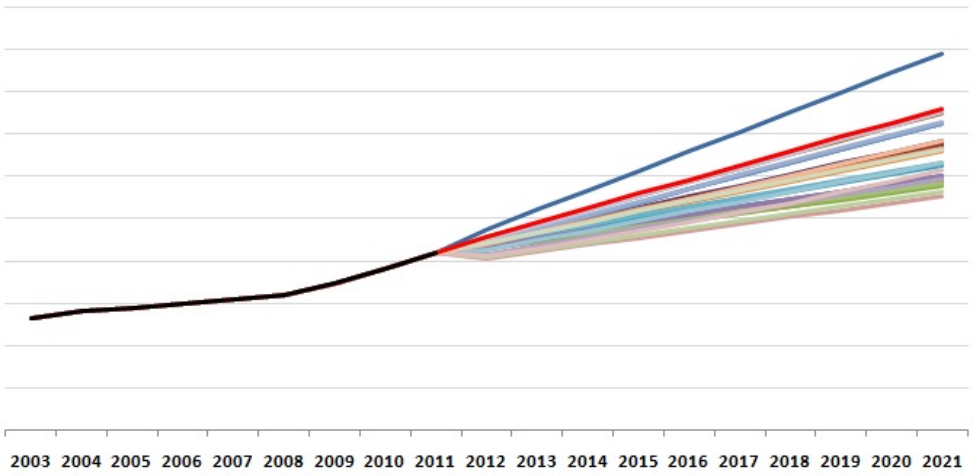

Figura 05 – Cenários previstos, realizado, e resultado da aplicação da FC_{PCA} (vermelho).

Para avaliar o desempenho do cenário proposto pela FC_{PCA} foram levantadas duas das mais populares formas de avaliação de erro na literatura (DIEBOLD, F. X. & LOPEZ, J. A., 1996); o Erro Percentual Médio Absoluto (*Mean Absolute Percentage Error* - MAPE) (equação 04), e a Raiz Quadrada do Erro Médio (*Root Mean Square Error* – RMSE) (equação 05).

$$MAPE = \frac{1}{n}\sum_{i=1}^{n}\left|\frac{x_i - \hat{x}_i}{x_i}\right| * 100 \quad (04)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^{n}(x_i - \hat{x}_i)^2}{n}} \quad (05)$$

Enquanto o MAPE fornece uma orientação relativa (%) sobre o quanto o modelo está errando o RMSE

mostra o desvio absoluto (em kWh). O RMSE apresenta uma propriedade interessante; devido a sua característica quadrática, este é mais sensível aos desvios com maior amplitude, penalizando a série de predição quando esta apresenta pontos com ajuste deficiente. O MAPE é possivelmente mais aplicado neste tipo de avaliação por realizar uma análise totalizada da série, o que é interessante nos casos em que as penalizações por desvio de projeção são realizadas em prazos maiores, como no caso da compra de energia elétrica, onde a avaliação do desvio é anual.

Buscando obter um índice que incluísse os dois aspectos citados definiu-se um novo método de avaliação do erro, que chamaremos aqui de MASE (*Mean Absolute Squared Error*).

$$MASE = MAPE * RMSE \quad (06)$$

Como as séries de predição tem início em julho de 2011, foram utilizados os dados realizados de consumo do período de julho de 2011 a dezembro de 2012 para a avaliação do erro. A figura 06 demonstra o comportamento mensal dos 10 cenários com melhor desempenho de MAPE e da FC_{PCA} (vermelho) frente ao consumo realizado da classe comercial (preto).

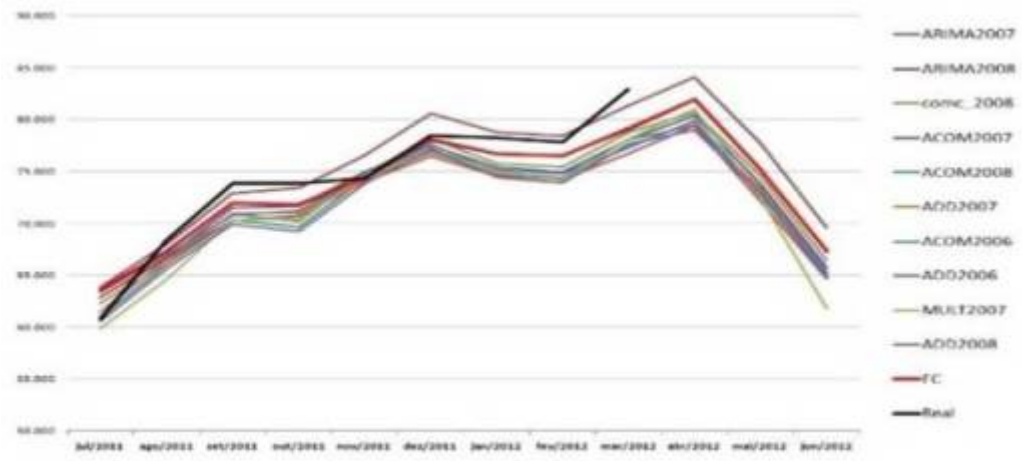

Figura 06 – Consumo realizado mensal e modelos de predição, inclusive FC_{PCA}.

Com base no MASE os cenários foram ranqueados do melhor para o pior resultado. A tabela 03 demonstra o resuldado dos modelos qu apresentaram os 10 melhores desempenhos. É possível verificar que o método aqui proposto, FC_{PCA} atingiu o melhor desempenho nas três avaliações de erro propostas, MASE, MAPE e RMSE.

Tabela 03 – Rank do desempenho MASE dos cenários.

Rank	Software	Modelo	MASE	MAPE	RMSE
1	FC_{PCA}	FC_{PCA}	32,921	1,99	1.655
2	Eviews	ARIMA2007	36,113	2,10	1.719
3	Eviews	ARIMA2008	38,929	2,15	1.807
4	Minitab	ACOM2007	40,980	2,33	1.757
5	Engenho	comc_2008	48,136	2,30	2.092
6	Holt Winters	ADD2007	53,919	2,59	2.084
7	Minitab	ACOM2006	56,461	2,67	2.114
8	Minitab	ACOM2008	62,094	2,54	2.447
9	Eviews	ARIMA2005	70,741	3,10	2.284
10	Holt Winters	ADD2006	71,909	3,01	2.386

Na figura 07, é demonstrado graficamente o comportamento do erro de cada modelo, pode-se notar a diferença apresentada por alguns modelos (no caso ACOM2008) entre o MAPE e o RMSE;

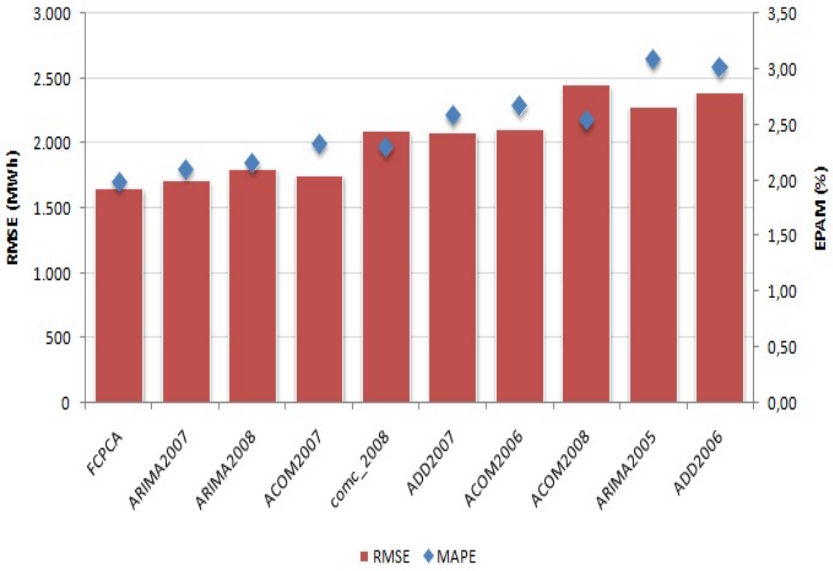

Figura 07 – EPAM e RMSE de cada modelo.

3. Conclusões

Este trabalho apresentou uma metodologia que traz luz a um dos maiores problemas de decisão para os gestores responsáveis pelo planejamento de mercado das distribuidoras de energia elétrica; "Como determinar a projeção, do conjunto de projeções de mercado propostas, para ser utilizado como cenário base?".

A opção pela utilização do método FC_{PCA} se mostra mais vantajosa na escolha entre as projeções para a composição do "cenário base" que irá nortear a contratação de energia da companhia, pois além de obter a melhor performance em termos de avaliação do erro de projeção, garante antecipadamente um cenário que apresente desvios aceitáveis por congregar características de todos os demais métodos utilizados na combinação. Conforme demonstrado, a aplicação da técnica de PCA produz um novo cenário com confiabilidade superior aos demais por carregar toda a informação do conjunto de projeções elaboradas.

Uma proposta para desdobramento deste trabalho seria estender esta metodologia para as demais classes de fornecimento da empresa a fim de compor o mercado de vendas totais da empresa e, conseqüentemente, a sua carga própria.

4. Referências bibliográficas

ANEEL. (28 de Agosto de 2007). Resolução Normativa 277.

ARAÚJO, W.O. & COELHO, C. J. (2009). *Análise de Componentes Principais (PCA).* Anápolis: UniEVAGÉLICA.

ARMSTRONG, J. (1989). Combining Forecasts: The End of the Beginning or the Beginning of the End? *International Journal of Forecasting* .

ASHLEY, R. (2003). Statistically significant forecasting improvements: how much out-of sample data is likely necessary? *International Journal of Forecasting* .

CNI, Confederação Nacional da Indústria (15 de junho de 2009). Crise Global: Impacto nos BRICs Foi Intenso e Diferenciado. *Notas Econômicas* .

CONDE, G. et al. (2007). Performance Evaluation of Short and Long Term Load Forecasting Models: a Case Study in the Amazonian Power Suppliers. *Proceedings of SPIE Optics East* .

DIEBOLD, F. X. & LOPEZ, J. A. (Mar de 1996). Forecast evaluation and combination. *National Bureau of Economic Research (NBER) Working Paper n. T0192* . Cambridge: Available at: http://ssrn.com/abstract=225136.

FALCO, G. P. (2004). O Perfil Econômico do Consumidor Residencial de Energia Elétrica no Período Entre 1994-2003. *Revista das Faculdades Integradas Vianna Júnior, Volume 01 Número 01*.

JOLLIFFE, I. (2002). *Principal Component Analysis - II Edition.* Aberdeen: Springer.

MORETTIN, P. A. & TOLOI, C. M. C. (2006). *Análise de Séries Temporais - II Edição Revista e Ampliada.* São Paulo: Edgard Blucher.

PINTO, L. (2008). Previsão Evolutiva de Carga Incluindo a Análise de Riscos. *X EDAO – Encontro Para Debates de Assuntos de Operação.* São Paulo.

SAMOHYL & SOUZA. (2005). Combinação de previsões em séries temporais do consumo industrial de energia elétrica em Santa Catarina. *XXV Encontro Nac. de Eng. de Produção.* Porto Alegre.

SAPANKEVYCH, N.I. & SANKAR, R. (2009). Time Series Prediction Using Support Vector Machines: A Survey. *IEEE Computacional Inteligence Magazine* .

STORCK, M. C. (2008). Projeção Mensal da Demanda de Emergia Utilizando VEC e Estimativa BOX –JENKINS Para os Parâmetros. *Dissertação de Mestrado* . Vitória, Espírito Santo: FUCAPE.

TIMMERMANN, A. (2005). Forecast Combinations. *University of California* .