

Avaliação da Utilidade da Aplicação Preliminar de Análise de Componentes Principais na Construção de Modelos de Redes Neurais Artificiais

Isaac L. S. Sacramento

Departamento de Informática e Estatística
Universidade Federal de Santa Catarina
Florianópolis, Brasil

Gueibi P. Souza

Departamento de Economia e Relações
Internacionais
Universidade Federal de Santa Catarina
Florianópolis, Brasil

Raul S. Wazlawick

Departamento de Informática e Estatística
Universidade Federal de Santa Catarina
Florianópolis, Brasil

Resumo—A previsão do consumo de energia elétrica no longo prazo é essencial para o planejamento do sistema de energia. O consumo de energia depende de variáveis econômicas e sociais, e a seleção destas variáveis é um dos pontos importantes na realização de previsões causais. Neste sentido, foi desenvolvido um método para seleção das variáveis de entrada para a previsão mensal do consumo de energia usando redes neurais artificiais. O método consiste na aplicação de uma análise de componentes principais para reduzir a dimensionalidade dos dados. As previsões obtidas com a aplicação da análise de componentes principais foram combinadas por redes neurais e comparadas com as previsões obtidas selecionando-se as variáveis por análise de correlação. A medida de erro percentual absoluto médio (MAPE) e a estatística U de Theil foram utilizadas e evidenciaram a capacidade preditiva do método proposto, com erros abaixo de 0,5%. As vantagens e limitações do método são discutidas neste artigo que amplia o horizonte de pesquisa na área de previsões.

Palavras-chaves—Análise de Componentes Principais; Previsão; Redes Neurais Artificiais; Consumo de Energia; Combinação

Abstract—The forecasting of long-term energy consumption is essential for planning the energy system. Energy Consumption depends on social and economic variables, and the selection of these variables is an important issue in causal forecasting. In this sense we have developed a method to select the input variables for monthly forecasting of energy consumption by artificial neural networks. The method consists on applying principal component analysis to reduce dimensionality of data. Forecastings obtained by applying principal component analysis were combined by neural network and compared to the forecastings obtained selecting variables by correlation analysis. The mean absolute percentage error (MAPE) and Theil's U statistic are used to evidence of predictive capability of proposed method, errors are below 0,5%. Advantages and limitations of the method are discussed in this paper and expands the horizon of research in forecasting.

Key-words—Principal Component Analysis; Forecasting; Artificial Neural Networks; Energy; Combining

I. INTRODUÇÃO

Estudar o consumo de energia elétrica no longo prazo é fundamental para administrar os riscos existentes no suprimento de energia. A segurança no fornecimento de energia impõe às concessionárias do setor elétrico a necessidade de administrar os riscos existentes, com o intuito de manter ou melhorar a qualidade na prestação do serviço. No Brasil as previsões de mercado para os cinco anos seguintes precisam ser informadas ao Ministério de Minas e Energia, de modo que as concessionárias estão sujeitas a penalidades decorrentes da contratação super ou subestimada na compra de energia. A realização de previsão no longo prazo configura-se como um instrumento na gestão do sistema elétrico, sua confiabilidade influencia na gestão do sistema como um todo e, portanto, pode ser responsável pela redução de custos ou mesmo, perdas de ordem elevada.

O estudo do consumo de energia é usualmente realizado com base no consumo histórico e em seu relacionamento com outras variáveis relevantes, a exemplo dos índices econômicos, demográficos, climáticos, preço da energia, dentre outros [1]. A seleção de variáveis, que costuma ser a etapa inicial na aplicação de métodos causais de previsão, é comumente realizada empiricamente, e deve ocorrer da forma mais ampla e irrestrita possível. A análise de correlação é amplamente utilizada para seleção de variáveis nos métodos de previsão de consumo ou demanda de energia elétrica [2][4][5][8]. Entretanto, este método de seleção pode ser uma atividade custosa quando se dispõe de uma base de dados com muitas variáveis [6].

Elias e Hatzigryriou [2] apresentaram um método para previsão de energia no médio prazo baseado em lógica *fuzzy*, cujas variáveis candidatas, transformadas em diferenças relativas, são selecionadas por meio de análise de correlação. Duan, Niu e Gu [8] propuseram um método baseado em regressão recursiva e aplicara correlação para identificar os fatores de influência na previsão de demanda elétrica na região da China. Tsekouras, Elias, Kavatza e Contaxis [4] estudaram a previsão de energia industrial e residencial a partir de um método regressivo, multivariado e não-linear que leva em consideração a análise de correlação entre as variáveis selecionadas. O mesmo método de seleção foi utilizado por

Tsekouras, Dyalinas, Hatzirygiou e Kavatzas [5] para limitar o conjunto de variáveis de entrada de funções não-lineares para previsão de energia na Grécia. Os autores encontraram modelos adequados para previsão em pequenas áreas metropolitanas. Mohamed e Bodger [10] aplicaram análise de correlação e selecionaram variáveis demográficas e econômicas na aplicação de regressão linear múltipla a fim de prever o consumo energético na Nova Zelândia. Os autores concluíram que a precisão das previsões realizadas por seus modelos, dependia fortemente das previsões, por regressão simples, realizadas para as variáveis explicativas.

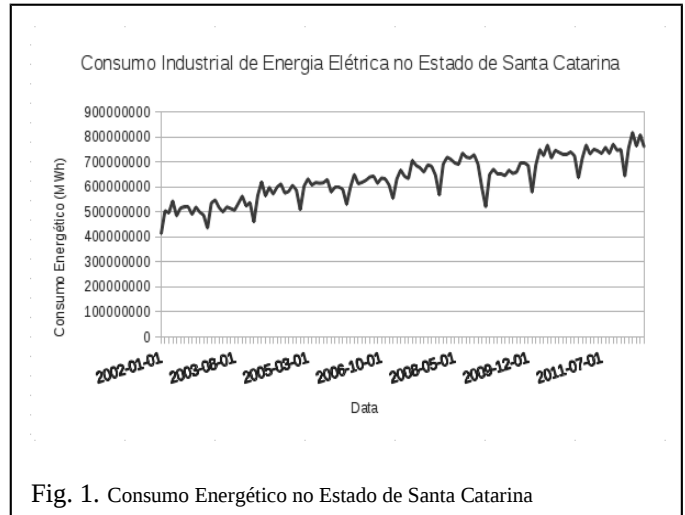
Souza, Samohyl e Pereira [6] apresentaram uma abordagem distinta das anteriores no que concerne a seleção das variáveis e a aplicação dos métodos de previsão. Os autores evidenciaram que a análise de componentes principais (ACP), para seleção das variáveis explicativas, pode melhorar a predição através da combinação de modelos regressivos, em comparação com a análise de correlação. Este estudo se referia ao fato de qual metodologia de seleção de variáveis se mostrava mais eficiente quando o número de parâmetros a serem estimados fosse relativamente superior ao tamanho da amostra. Neste sentido presume-se ser razoável questionar se esta mesma intenção se mostra igualmente eficiente quando aplicada a estudos que envolvam modelos baseados em redes neurais, uma vez que, baseado na sua capacidade de generalização e captura de possíveis relacionamentos não lineares, as redes neurais artificiais (RNA) são apresentadas como possível alternativa na solução de problemas de previsão [3][7][9].

Neste trabalho, portanto, apresentamos um método de previsão de consumo de energia, baseado na combinação de redes neurais, que tem como entrada um conjunto de dados pré-selecionados com a aplicação de análise de componentes principais (ACP). As variáveis selecionadas por correlação e ACP foram utilizadas no treinamento, validação e previsão de redes neurais com mesma configuração a fim de comparar seus resultados em termos de precisão. Isto é, analisar se as redes, com as variáveis retidas nos componentes principais de maior peso, são capazes de prever o consumo industrial de energia com menor erro do que a rede que conta com a seleção das variáveis por correlação. O restante deste artigo está organizado da seguinte forma: seção 2 apresenta a análise dos dados utilizados no estudo. Seção 3 busca familiarizar o leitor com os conceitos básicos da Análise de Componentes Principais. Seção 4 apresenta os modelos de redes neurais sugeridos para a previsão do consumo de energia industrial, baseada nas variáveis selecionadas por correlação e ACP. São apresentadas ainda duas estatísticas de comparação entre as redes com o uso de análise de correlação e ACP. A Seção 5 conclui o texto com as análises dos resultados.

II. DADOS

Os métodos de Análise de Componentes Principais, Correlação e Redes Neurais foram aplicados aos dados históricos do consumo industrial de energia e índices econômicos e industriais do Estado de Santa Catarina, Brasil. O período em estudo compreendeu os anos de 2004 a 2011. Na Fig. 1 é possível observar o comportamento assumido pelo consumo industrial ao longo do tempo. Por efeito da crise energética ocorrida no Brasil no ano de 2001, é possível notar que a partir de 2004 a curva assume um padrão de

comportamento diferente do período anterior, mantendo-se assim até 2011.



A indústria é responsável por cerca de 40% do consumo total de energia elétrica do Estado de Santa Catarina e a série contém dados mensais em Megawatt-hora (MW h). Os índices econômicos e industriais foram obtidos por meio do módulo público do Sistema Gerenciador de Séries Temporais (SGS), mantido pelo Banco Central do Brasil. Foram utilizadas todas as séries temporais que atenderam ao período em estudo, compreendendo um total de 30 variáveis, cada uma com 90 observações.

O conjunto de dados foi padronizado por meio de (1), como consequência das diferentes unidades de medida das variáveis. Cada valor observado (X_i) foi subtraído da média da série temporal (μ) e dividido pelo desvio padrão (σ), esta medida evitou distorções no resultado da Análise de Componentes Principais. Todas as variáveis em estudo compreenderam o período estabelecido para o estudo, de modo que nenhum pré-processamento foi aplicado para lidar com a ausência de dados nas séries.

$$Z_i = (X_i - \mu) / \sigma \quad (1)$$

III. PRINCÍPIOS BÁSICOS DA ANÁLISE DE COMPONENTES PRINCIPAIS

A Análise de Componentes Principais (ACP) é um método matemático cujo objetivo é transformar um conjunto de variáveis originais em outro conjunto chamado de Componentes Principais. Os componentes apresentam as seguintes características: cada componente principal é uma combinação linear de todas as variáveis originais, os componentes são independentes entre si e retém, em ordem de estimação, o máximo de informação relacionada à variação dos dados originais. A análise permite a redução dimensional de um grande número de variáveis, a partir da rotação do eixo original dos dados, transformando-os em um novo sistema de coordenadas.

Com base em um conjunto de η variáveis X_1, X_2, \dots, X_η , deseja-se obter índices Z_1, Z_2, \dots, Z_η não correlacionados na ordem de sua importância. A não correlação dos índices implica na medição de dimensões diferentes dos dados e a variância total é representada pela variância de cada um dos componentes, de modo que $var(Z_1) \geq var(Z_2) \geq \dots \geq var(Z_\eta)$. O primeiro componente Z_1 é a combinação linear das variáveis X_1, X_2, \dots, X_n , assim o primeiro componente é dado por (2).

$$Z_1 = \alpha_{11} X_1 + \alpha_{12} X_2 + \dots + \alpha_{1n} X_n \quad (2)$$

Z_1 representa a maior variabilidade possível dos dados, com autovetor $\alpha_{11}, \alpha_{12}, \dots, \alpha_{1n}$. O segundo componente principal Z_2 é apresentado a seguir (3):

$$Z_2 = \alpha_{21} X_1 + \alpha_{22} X_2 + \dots + \alpha_{2n} X_n \quad (3)$$

Igualmente, o segundo componente representa a maior variabilidade possível restante, com autovetor $\alpha_{21}, \alpha_{22}, \dots, \alpha_{2n}$, de modo que Z_1 e Z_2 não são correlacionados. Igualmente, o n -ésimo componente principal é dado por (4).

$$Z_n = \alpha_{n1} X_1 + \alpha_{n2} X_2 + \dots + \alpha_{nn} X_n \quad (4)$$

A aplicação da ACP pode ser resumida nos passos citados a seguir:

- Padronização das variáveis para que adquiram média zero e variâncias unitárias.
- Cálculo da matriz de covariância.
- Cálculo dos autovalores e autovetores correspondentes.
- Descarte dos componentes que expliquem uma pequena proporção da variabilidade dos dados. Foram descartadas as variáveis com contribuições menores que a média dos componentes.

Os três primeiros passos foram realizados de forma automatizada no aplicativo MatLab e o último é considerado etapa da interpretação da ACP. Previsão do Consumo Industrial de Energia

O método em estudo foi aplicado com o intuito de selecionar o conjunto de variáveis mais adequado para a previsão de consumo industrial de energia elétrica no Estado de Santa Catarina. Inicialmente foi construído um banco de dados com o maior número possível de observações de cada uma das variáveis. O período em estudo foi de abril de 2004 a novembro de 2010, tendo sido previsto o período de 1 ano à frente, compreendendo dezembro de 2010 a novembro de 2011.

O mesmo conjunto de dados foi submetido à análise de correlação e análise de componentes principais de onde foram extraídos dois subconjuntos de variáveis. Cada subconjunto foi então submetido a redes neurais com mesma configuração e as previsões e previsões obtidas foram utilizadas como variáveis de entrada de um novo modelo de rede neural criada para combinar os resultados obtidos com os componentes. O método é ilustrado na Fig. 2.

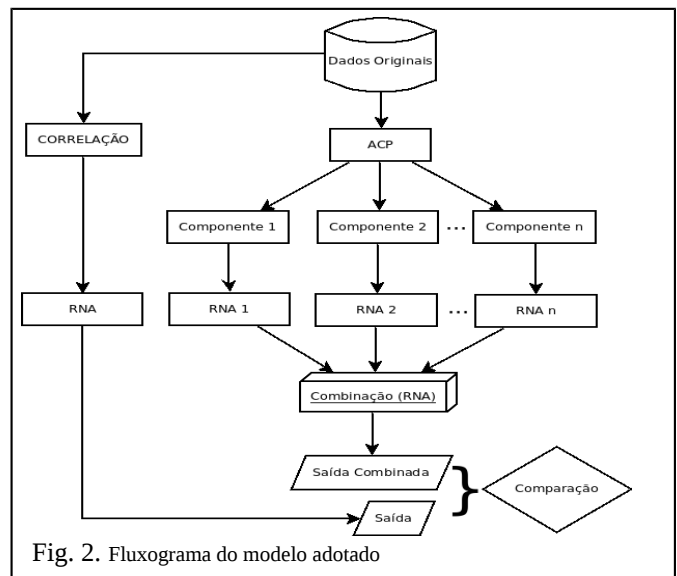


Fig. 2. Fluxograma do modelo adotado

As redes neurais adotadas neste trabalho são do tipo *feed forward* e consistem em uma camada de entrada de dados, uma camada de saída e uma ou mais camadas intermediárias, conhecidas como camadas ocultas Fig. 3. Cada camada oculta é composta por neurônios, conectados aos neurônios das camadas seguintes. Os parâmetros das redes neurais são os pesos das conexões entre os neurônios e os *biases* dos nós.

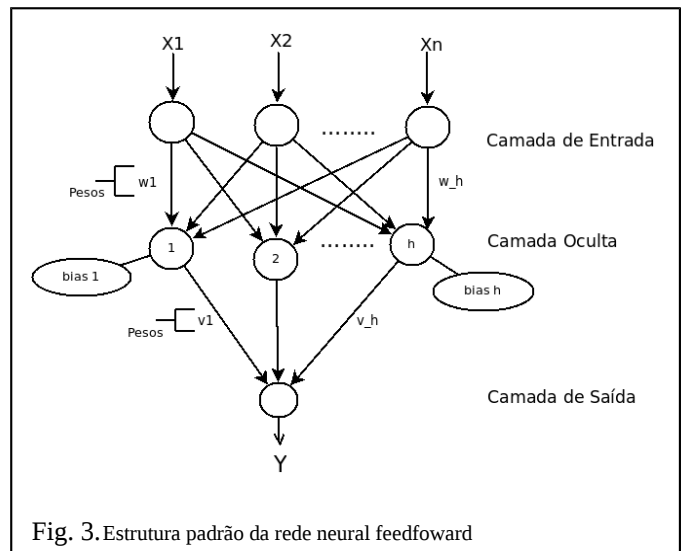


Fig. 3. Estrutura padrão da rede neural feedforward

Foram implementadas redes neurais com diferentes arquiteturas, variando de 1 a 2 o número de camadas ocultas e variando de 1 a 30 o número de neurônios em cada camada oculta da rede. As redes neurais foram treinadas com um conjunto de dados mensais de abril de 2004 a junho de 2009, sendo validadas com dados de julho de 2009 a setembro de

2010. As previsões foram realizadas em termos de teste da aderência da mesma para um ano à frente, ou seja, até setembro de 2011.

O nível de precisão obtido com o método é calculado a partir do tamanho da série prevista n , do valor real do consumo industrial Y_i e do consumo industrial previsto \hat{Y}_i . Como critério de validação das redes neurais, foi utilizado o erro percentual absoluto médio, MAPE, para a avaliação da precisão dos resultados. Esta medida é calculada da seguinte forma (5):

$$MAPE = 100 \times \frac{1}{n} \sum_{i=1}^n \frac{y_i - \hat{y}_i}{y_i} \quad (5)$$

Embora o MAPE seja uma estatística amplamente aplicada na avaliação da precisão dos métodos de previsão, neste trabalho optou-se por utilizar adicionalmente a estatística U de Theil, que permite avaliar a heurística de previsão utilizada na medida em que compara sua precisão com a do método ingênuo. A Eq. (6) expressa a medida U de Theil, com a qual é possível eliminar os métodos com maiores erros.

$$U = \sqrt{\frac{\sum_{i=1}^{n-1} \left[\left(\frac{\hat{Y}_{t+1} - Y_t}{Y_t} \right)^2 + \left(\frac{Y_{t+1} - Y_t}{Y_t} \right)^2 \right]}{\sum_{i=1}^{n-1} \left(\frac{Y_{t+1} - Y_t}{Y_t} \right)^2}} \quad (6)$$

Para efeitos deste trabalho, as medidas de erro MAPE e U de Theil permitem a avaliação comparativa que embasa esta proposta.

A. Análise de Correlação

A análise de correlação permitiu a seleção de 20 variáveis consideradas fortemente correlacionadas com o Consumo Industrial. A Tab. I apresenta os índices de correlação obtidos para cada uma das variáveis.

TABLE I. TABELA DE VARIÁVEIS

Variáveis	C P 1	C P 2	C P 3	Correlação com CI
100 - Consumo Industrial (CI)	✓	✓		1,000
102 - Utilização da Capacidade Instalada		✓		0,5539
1477 - Índice do Volume de Vendas no Varejo - Total - (SC)	✓			0,5603
1492 - Índice de Volume de Vendas no Varejo - Combustíveis	✓			0,6014
1505 - Índice de Vol. de Vendas no Varejo - Alimentos, Bebidas e Fumo	✓			0,5130
1518 - Índice de Vol. de Vendas no Varejo - Tecidos				0,4127
1531 - Índice de Vol. de Vendas no Varejo - Móveis	✓			0,3782
1557 - Índice de Vol. de Vendas no Varejo - Automóveis	✓	✓		0,7775

Variáveis	C P 1	C P 2	C P 3	Correlação com CI
100 - Consumo Industrial (CI)	✓	✓		1,000
1570 - Índice de Vol. de Vendas no Varejo - Hipermercados e Supermercados	✓			0,5034
4348 - Receita dos Estados e Municípios - Arrecadação ICMS	✓	✓	✓	0,6875
4375 - Receita dos Estados e Municípios - Transferências da União	✓			0,4803
7429 - Pessoal Ocupado Assalariado		✓		-0,1108
7646 - Arrecadação ICMS - Setor Primário		✓		0,5771
7701 - Arrecadação ICMS - Outras Fontes		✓		0,1360
14025 - Saldo Operações de Crédito do Sistema Financeiro - Pessoa Física	✓	✓	✓	0,7577
14052 - Saldo Operações de Crédito do Sistema Financeiro - Pessoa Jurídica	✓	✓	✓	0,7360
14079 - Saldo Operações de Crédito do Sistema Financeiro - Total	✓		✓	0,7468
15383 - Índice de Atividade Econômica Regional	✓	✓		0,8028
15884 - Taxa de Inadimplência do Sistema		✓	✓	0,4464
15916 - Taxa de Inadimplência do Sistema Financeiro - Pessoa Jurídica		✓	✓	0,0808
15948 - Taxa de Inadimplência do Sistema Financeiro - Total		✓	✓	0,3400
17742 - Índice de Atividade Econômica Regional - Com Ajuste Sazonal	✓	✓	✓	0,7872
20199 - Índice de Vol. de Vendas no Varejo - Ampliado	✓			0,7082
20200 - Índice de Vol. de Vendas no Varejo - Artigos Farmacêuticos	✓	✓	✓	0,7486
20201 - Índice de Vol. de Vendas no Varejo - Livro e Jornais			✓	0,0143
20202 - Índice de Vol. de Vendas no Varejo - Materiais para Escritório	✓	✓	✓	0,6546
20203 - Índice de Vol. de Vendas no Varejo - Outros Artigos	✓			0,4446
20204 - Índice de Vol. de Vendas no Varejo - Materiais para Construção	✓	✓		0,7986
20442 - Índice de Atividade Econômica Regional - Nova Metodologia	✓			0,7390
20455 - Índice de Atividade Econômica Regional - Nova Metodologia - Com Ajuste Sazonal	✓	✓		0,7840

As variáveis selecionadas por análise de correlação foram utilizadas para a previsão do consumo energético por redes neurais. Os resultados considerados relevantes foram aqueles com menor MAPE e também o U de Theil abaixo de 1. O gráfico de caixa da Fig. 4 mostra a evolução dos erros durante a execução das redes. Nas extremidades de cada caixa aparecem os MAPE's inferior e superior, os sinais "+" representam os valores discrepantes obtidos pelas redes. Gráfico obtido por meio do aplicativo MatLab.

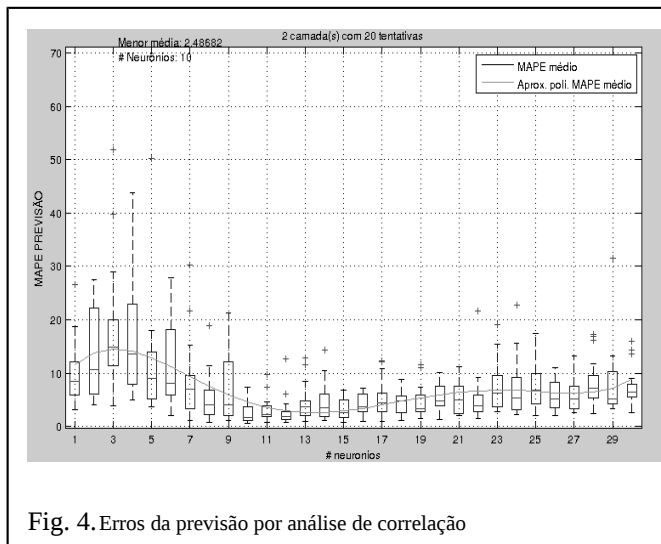


Fig. 4. Erros da previsão por análise de correlação

Na Tab. II são apresentados os erros obtidos com as redes com uma camada oculta 15 neurônios. Na previsão a rede com 10 neurônios apresentou MAPE mínimo igual a 0,2790% e, na previsão, o desempenho foi 0,5035%. Já a estatística U de Theil na previsão foi igual a 0,0648, enquanto que na previsão foi 0,0925. As redes com 15 neurônios na camada escondida apresentaram a menor variação entre o menor e maior MAPE e por isso foram mais estáveis na previsão, embora tenham obtido MAPE e U de Theil maiores que a configuração com 10 neurônios.

TABLE II. TABELA DE DESEMPENHO DAS REDES NEURAIS NA CORRELAÇÃO

Configuração	Predição		Previsão	
	MAPE (%)	U de Theil	MAPE (%)	U de Theil
[1 - 15]	0,45478	0,1003	0,8447	0,1545

a. Fonte: MatLab

B. Análise de Componentes Principais

Os dados padronizados por (1) foram submetidos a uma análise de componentes principais. A Tab. III apresenta os autovalores e seus percentuais explicativos, tanto individuais quanto cumulativos. Nela é possível observar que os três primeiros componentes são responsáveis por 80,30% da variabilidade total dos dados, e por isso, foram selecionados para análise, ou seja, gerarem as redes.

TABLE III. TABELA DE VALORES DA ANÁLISE DE COMPONENTES PRINCIPAIS

Compo nente	Autovalores	Percentual Explicativo	Cumulativo
1	19,1991	63,9970	0,639970
2	2,7375	9,1250	0,7312
3	2,1558	7,1858	0,8031
4	1,3614	4,5380	0,8485
5	1,2275	4,0918	0,8894

Compo nente	Autovalores	Percentual Explicativo	Cumulativo
1	19,1991	63,9970	0,639970
6	0,9057	3,0191	0,9196
7	0,5198	1,7327	0,9369
8	0,3922	1,3072	0,9500
9	0,2896	0,9655	0,9596
10	0,2714	0,9046	0,9687
11	0,2031	0,6770	0,9754
12	0,1881	0,6269	0,9817
13	0,1178	0,3927	0,9856
14	0,1068	0,3561	0,9892
15	0,0814	0,2713	0,9919
16	0,0621	0,2070	0,9940
17	0,0454	0,1515	0,9955
18	0,0333	0,1111	0,9966
19	0,0328	0,1093	0,9977
20	0,0239	0,0797	0,9985
21	0,0230	0,0767	0,9993
22	0,0098	0,0327	0,9996
23	0,0072	0,0239	0,9998
24	0,0032	0,0107	0,9999
25	0,0017	0,0055	1,0000
26	2,34E-4	7,81E-4	1,0000
27	7,33E-05	2,44E-04	1,0000
28	2,52E-05	8,40E-05	1,0000
29	3,98E-06	1,33E-05	1,0000
30	1,85E-10	6,18E-10	1

b. Fonte: MatLab

Uma vez observados os componentes principais relevantes, a etapa seguinte consistiu em selecionar as variáveis de maior influência por meio da média de cada autovetor Tab. IV, conforme adotado por Souza, Samohyl e Pereira [6]. Foram selecionadas as variáveis cuja contribuição para o componente estava acima da média dos seus autovetores. Desta maneira, no primeiro componente principal foram retidas 21 variáveis, do segundo componente se reteve 19 variáveis, e do terceiro componente principal foram retidas 11 variáveis. Estas variáveis selecionadas compuseram o conjunto de entrada de cada uma das três redes neurais testadas.

TABLE IV. TABELA DE AUTOVETORES DOS COMPONENTES PRINCIPAIS RETIDOS

Componente 1	Componente 2	Componente 3
0,1683	0,2908	-0,1229
0,0273	0,4437	-0,3322
0,2151	-0,1756	-0,0363

Componente 1	Componente 2	Componente 3
0,1683	0,2908	-0,1229
0,2049	-0,0507	-0,0262
0,2082	-0,1953	-0,0078
0,1567	-0,2444	-0,1773
0,1800	-0,2779	-0,0748
0,2118	0,0819	-0,1054
0,2071	-0,2019	-0,0085
0,2124	0,0923	0,0390
0,1877	-0,1844	-0,0727
-0,0925	0,1381	-0,2201
0,1511	0,1597	-0,1054
0,0357	0,1234	-0,1912
0,2185	0,1090	0,0727
0,2172	0,0936	0,0768
0,2181	0,1007	0,0750
0,2240	0,0742	-0,0453
0,1282	0,0661	0,2889
0,0374	0,1354	0,5180
0,1045	0,1511	0,5326
0,2190	0,1182	0,0144
0,2234	-0,0383	-0,0766
0,2220	0,0625	0,0643
0,1008	-0,3700	0,1495
0,2013	0,0895	0,0119
0,1774	-0,2681	-0,1605
0,2058	0,1561	-0,0916
0,2073	0,0144	-0,0055
0,2134	0,1327	-0,0116

C. Fonte: MatLab

Cada conjunto de variáveis selecionadas nos componentes foi testado em diferentes redes neurais. Se observou que, a rede com melhor desempenho tende a piorar do primeiro até o terceiro componente, o que é esperado, pois se sabe (SEÇÃO III) que a variabilidade dos dados é decrescente na ordem dos componentes. A Tab. V apresenta os valores do MAPE e U de Theil obtidos nos testes com as variáveis retiradas de cada componente principal selecionado.

TABLE V. TABELA DE DESEMPENHO DAS REDES NEURAIAS NA ANÁLISE DE COMPONENTES PRINCIPAIS

Redes	Predição		Previsão	
	MAPE (%)	U de Theil	MAPE (%)	U de Theil
(Componente 1)				
[1 - 13]	0,4165	0,1016	1,0767	0,1707
(Componente 2)				
	MAPE (%)	U de Theil	MAPE (%)	U de Theil

Redes	Predição		Previsão	
	MAPE (%)	U de Theil	MAPE (%)	U de Theil
(Componente 1)				
[1 - 11]	0,3564	0,0707	0,9868	0,1366
(Componente 3)				
[1 - 1]	2,5635	0,6704	3,7482	0,6927

d. Fonte: MatLab

C. Combinação de Previsões do Consumo Industrial de Energia Elétrica

Os resultados obtidos com os componentes principais motivaram a investigação do consumo elétrico por meio da combinação das suas previsões. A combinação busca fazer com que uma rede neural utilize o potencial da variabilidade de cada componente (explorada por uma rede individual para cada um deles). A combinação das previsões dos componentes principais individuais foi o método que viabilizou os menores erros na estimação do consumo de energia dentro e fora da amostra. Isto ocorre, pois cada componente principal agrega informações relevantes à rede neural.

As proporções dos conjuntos de entrada (treino, validação e teste) para a rede de combinação foram mantidas iguais às utilizadas nas redes da correlação. A Fig. 5 apresenta o desempenho das redes testadas para a combinação de previsões.

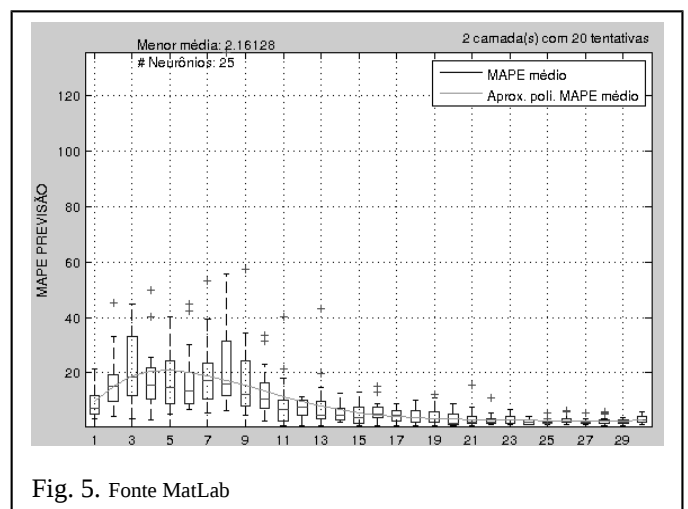


Fig. 5. Fonte MatLab

A combinação das previsões permitiu obter os erros mais baixos em relação à correlação. A rede neural de combinação apresentou MAPE na predição igual 0,3274% e na previsão igual 1,0034%. Estes valores são, respectivamente, menores que os valores das redes por correlação (predição: 0,45478%, previsão: 0,8447%) e por componentes principais (predição: 0,3564%, previsão: 0,9868%). Os valores do U de Theil ficaram abaixo de 1 na predição e previsão, o que significa que, por combinação das previsões dos componentes, é possível obter um modelo aplicável e, inclusive, mais preciso. Os valores são exibidos na Tab. VI.

TABLE VI. TABELA DE RESULTADOS DA COMBINAÇÃO POR REDES NEURAIAS

Método	Predição		Previsão	
	MAPE (%)	U de Theil	MAPE (%)	U de Theil
Correlação	0,45478	0,1003	0,8447	0,1545
Componente 1	0,4165	0,1016	1,0767	0,1707
Componente 2	0,3564	0,0707	0,9868	0,1366
Componente 3	2,5635	0,6704	3,7482	0,6927
Combinação	0,3274	0,0755	1,0034	0,1613

e. Fonte: MatLab

IV. CONCLUSÕES

Um método para previsão do consumo industrial de energia no Estado de Santa Catarina foi apresentado, o qual leva em consideração a redução dimensional dos dados de entrada por meio de uma análise de componentes principais, em detrimento da análise de correlação para seleção das variáveis de entrada. A ACP permitiu a seleção de um conjunto de variáveis apropriado para proceder à previsão por redes neurais. Os resultados da previsão de consumo industrial de energia foram obtidos por meio da submissão dessas variáveis aos diferentes conjuntos de redes com o intuito de obtermos a melhor condição possível para previsão. As redes neurais com os dados do primeiro componente principal apresentaram melhor desempenho quando comparadas às redes com conjunto de selecionadas por análise de correlação. Os resultados motivaram a combinação das previsões, realizadas com os três primeiros componentes principais, em uma nova estrutura de rede. O modelo combinado apresentou previsões ainda menores do que com os componentes principais individualmente mostrando que o método proposto é uma alternativa real na solução de problemas práticos de previsão.

AGRADECIMENTOS

Os autores gostariam de agradecer ao Laboratório de Sistemas de Conhecimento pela disponibilização de recursos para realização de experimentos. Os autores agradecem a Companhia Elétrica de Santa Catarina pela disponibilização

dos dados de consumo industrial. Os autores desejam ainda agradecer ao Programa de Pós-Graduação em Ciência da Computação (PPGCC).

REFERÊNCIAS

- [1] C. N. Elias and N. D. Hatzigiorgiou, "An annual midterm energy forecasting model using fuzzy logic," *IEEE Transactions on Power Systems*, vol. 24, num. 1, pp. 469-478, February 2009.
- [2] H. Pao, "Comparing linear and nonlinear forecast for Taiwan' electricity consumption," *Energy*, vol. 31, num. 12, pp. 2129-2141, September 2006.
- [3] M. A. Farahat, "Long term industrial load forecasting and planning using Neural Networks technique and fuzzy inference method," *39th International Conference on Power Engineering*, vol. 1, p. 4, September 2004.
- [4] G. J. Tsekouras, Ch. N. Elias, S. Kavatza and G. C. Contaxis., "A hybrid non-linear regression midterm energy forecasting method using data mining," *Power Tech Conference Proceedings*, vol. 1, pp. 6, June 2003.
- [5] G. J. Tsekouras, E. N. Dyalinas, N. D. Hatzigiorgiou and S. Kavatza, "A non-linear multivariable regression model for midterm energy forecasting of power system," *Electric Power System Research*, vol. 77, num. 12, pp. 1560-1568, 2007.
- [6] G. P. Souza, R. W. Samohyl and R. C. Pereira, "Avaliação da utilidade da aplicação preliminar de análise de componentes principais em um grande conjunto de dados quando se visa construir modelos de regressão," *17º Simposio Nacional de Probabilidade e Estatística-SINAPE*, Caxambu-MG, Brasil, 2006.
- [7] H. Liu, L. Cai and X. Wu, "Grey-RBF neural network prediction model for city electricity demand forecasting," *International Conference on wireless Communications, Network and Mobile Computing*, pp. 1-5, October 2008.
- [8] L. Duan, D. Niu and Z. Gu, "Long and medium term power load forecasting with multi-level recursive regression analysis," *International Symposium on Intelligent Information Technology Application*, vol. 1, pp. 514-518, December 2008.
- [9] T. Q. D. Kahoa, L. M. Phuong, P. T. T. Binh and N. T. H. Lien, "Application of wavelet and neural network to long-term load forecasting," *International Conference on Power System Technology*, vol. 1, pp. 840-844, November 2004.
- [10] Z. Mohamed and P. Bodger, "Forecasting electricity consumption in the New Zeland using economic and demographic variables," *Energy*, vol. 30, num. 10, pp. 1833-1843, July 2005.