

Previsão de Demanda de Energia Elétrica Utilizando Redes Neurais Artificiais e Support Vector Regression

Gabriel I. S. Ruas¹, Ticiano A. C. Bragatto¹, Marcus V. Lamar², Alexandre R. Aoki³, Silvio Michel de Rocco⁴

¹Departamento de Engenharia Elétrica – Universidade Federal do Paraná (UFPR)
Caixa Postal 19011 – 81531-990 – Curitiba – PR – Brazil

²Departamento de Ciências da Computação – Universidade de Brasília (UnB)
Caixa Postal 4466 - 70919-970 - Brasília – DF – Brazil.

³Instituto de Tecnologia para o Desenvolvimento (LACTEC)
Caixa Postal 19067 - 81531-980 - Curitiba – PR – Brazil.

⁴Copel Distribuição S/A (COPEL)
Rua José Izidoro Biazetto, 158 – Bloco C – 81200-240 – Curitiba – PR – Brazil.
{bragatto@ufpr.br, gabrielruas@gmail.com, lamar@unb.br,
aoki@lactec.org.br, rocco.silvio@copel.com}

Abstract. *This paper describes a short time electrical energy demand forecast system using two different techniques of Artificial Intelligence: Recurrent Artificial Neural Networks and Support Vector Regression. A brief analysis of the demand over the electrical energy network connection points is also done.*

Resumo. *Este artigo descreve um sistema de previsão da demanda de energia a curto prazo utilizando duas técnicas diferentes de inteligência artificial: Redes neurais artificiais recorrentes e support vector regression. Também foi feita uma breve análise do perfil de demanda dos pontos de conexão da rede de energia elétrica.*

1. Introdução

Com a privatização do setor de energia elétrica e a comercialização da energia entre as distribuidoras, torna-se importante para estas empresas a previsão de demanda, tanto a longo quanto a curto prazo. A previsão de demanda a longo prazo é necessária para a contratação da energia a ser comprada e a de curto prazo é importante para se garantir que o sistema de distribuição trabalhe dentro dos limites contratados, evitando pesadas multas. Um requerimento importante deste tipo de previsão é que o erro esteja abaixo da tolerância prevista nestes contratos, que é geralmente de cerca de 5%. As trocas de energia elétrica entre as diferentes distribuidoras são realizadas através dos pontos de conexão da rede elétrica, que são as subestações de uma distribuidora que estão diretamente conectadas ao restante do sistema elétrico nacional.

Neste trabalho é analisada a previsão de demanda em pontos de conexão da rede de energia a curto prazo utilizando-se dois métodos populares de previsão de séries temporais: redes neurais artificiais (RNA) recorrentes e *Support Vector Regression* (SVR). Primeiramente é feita uma breve análise do perfil de demanda típico destes pontos

de conexão. A seguir, as duas metodologias utilizadas são descritas, os resultados obtidos são analisados e conclusões sobre este trabalho são apresentadas.

2. Metodologia

2.1. Análise dos dados de demanda

Os dados de demanda de energia utilizados neste estudo consistem da potência ativa consumida integralizada em 15 minutos dos pontos de conexão de energia do estado do Paraná, entre os anos de 2004 e 2006. Exemplos destes dados podem ser vistos na Figura 1 e na Figura 2.

Analisando os dados nota-se padrões de repetição diários, relacionados aos horários de ponta e fora de ponta, e semanais, relacionadas às diferenças entre o consumo durante a semana e em fins de semana.




Figura 1-Demanda em três dias consecutivos

Através da Figura 1 percebe-se a sazonalidade diária, com picos de consumo próximo às 09:00, 14:00 e 20:00 horas, e baixo consumo durante a madrugada, entre 00:00 e 06:00 horas.




Figura 2-Demanda em duas semanas consecutivas

Na Figura 2 pode-se observar a sazonalidade semanal, com os domingos apresentando um perfil diferenciado dos outros dias.

A sazonalidade anual não pôde ser observada, uma vez que o período observado corresponde a cerca de um ano e meio.

Para permitir um melhor entendimento das séries temporais envolvidas, foi realizada uma análise da função de autocorrelação dos dados.




Figura 3. Autocorrelação dos dados de demanda, com até 4 semanas de atraso

Analisando a Figura 3, podemos concluir que a correlação dos dados diminui com a distância temporal entre os mesmos. É possível perceber que a correlação possui picos mais destacados em determinados atrasos. A Tabela 1 indica o atraso correspondente aos pontos nomeados na Figura 3.

Tabela 1-Pontos de interesse na autocorrelação

Ponto	Atraso
A	24 h (1 dia)
B	168 h (1 semana)
C	336 h (2 semanas)
D	504 h (3 semanas)
E	672 h (4 semanas)

Como pode-se notar, a correlação da demanda é visivelmente maior no mesmo horário com um dia e uma semana de atraso, além das medidas imediatamente anteriores (15, 30 e 45 minutos de atraso).

Como o objetivo deste trabalho é a previsão dos picos de demanda diários, uma possibilidade é utilizar apenas estes pontos para realizar a previsão. A Figura 4 apresenta a característica da demanda quando apenas os picos diários são considerados.




Figura 4- Picos diários de seis semanas de demanda

Novamente, pode-se perceber na Figura 4 uma sazonalidade semanal nos dados.

A autocorrelação destes dados pode ser vista na Figura 5.




Figura 5 - Autocorrelação dos picos diários de demanda

Ao contrário do que ocorria com os dados integralizados em 15 minutos, na Figura 5 pode-se ver que o pico diário de demanda não apresenta uma correlação significativa com nenhum atraso em especial, ocorrendo apenas um pequeno pico para atraso múltiplos de uma semana.

2.2. Previsão utilizando Redes Neurais Artificiais

Inicialmente, avaliou-se o uso de Redes Neurais Artificiais (RNA), uma técnica já bem consolidada, para realizar a previsão.

Redes neurais artificiais são sistemas computacionais baseados em uma aproximação do modelamento do cérebro humano [Haykin 1998]. Unidades simples chamadas neurônios são interligadas para formar uma rede. As redes neurais, ao contrário das técnicas tradicionais de computação, não são programadas proceduralmente para resolver problemas. Elas aprendem a solução de um problema, e para tanto devem ser treinadas através da apresentação de exemplos dessa solução.

Para análise de dados correlatos temporalmente, é possível realimentar a rede de várias maneiras diferentes, criando redes cuja resposta variam não só com os dados

presentes na entrada, como também dos dados apresentados anteriormente. Dentre as diversas estruturas capazes de tratar com séries temporais, a configuração escolhida foi a rede parcialmente recorrente de Elman [Elman 1990]. A estrutura proposta por Elman é bastante simples, porém foi demonstrada sua capacidade de aprender qualquer série temporal, desde que tenha uma estrutura adequada, i.e. número de neurônios, e seja devidamente treinada, i.e. um algoritmo de aprendizado adequado [Kremer 1995]. Esta estrutura, apresentada na Figura 6, consiste basicamente de uma camada de contexto, que armazena as saídas da camada intermediária escondida, para então realimentar estes valores na rede na próxima iteração temporal.




Figura 6 – Estrutura geral da rede Elman

A estrutura apresentada na Figura 6, dada uma série temporal, permite a previsão de um passo de tempo à frente. Para que seja possível realizar a previsão vários pontos à frente, é necessário utilizar os valores já previstos, ou seja, a saída da rede, como entradas da mesma.

Primeiramente foi utilizada uma rede com apenas um neurônio de entrada e um neurônio na saída. Como não existe uma metodologia analítica para definir o número de neurônios na camada intermediária escondida, foram testados 10, 25 e 50 neurônios nesta camada.

Outra configuração testada foi utilizando várias medidas anteriores de demanda na entrada da rede, a fim de prever seu comportamento futuro. Na camada intermediária, novamente foram testados 10, 25 e 50 neurônios. Os pontos anteriores a serem utilizados na entrada foram escolhidos de acordo com a análise da função autocorrelação dos dados de demanda medidos.

Como será mostrado na seção 3, a previsão com os dados completos apresenta um erro considerável, devido à quantidade de pontos que devem ser previstos. Para resolver este problema, foram testadas configurações utilizando apenas os picos diários de demanda. Foram testadas as estruturas com um neurônio na entrada e com várias entradas relativas a medidas anteriores.

É possível obtermos resultados melhores com RNA, através do método de tentativa e erro para a definição da estrutura, iterações durante o treinamento, e ajustes dos parâmetros do algoritmo de treino utilizado, sendo que essa tarefa requer muito tempo de

simulação, para alcançarmos uma estrutura RNA que apresente resultado ótimo para a previsão de demanda para um determinado ponto de conexão da rede elétrica. No entanto devido ao grande número de pontos de conexão e suas particularidades, tal metodologia mostra-se inviável de ser aplicada em um tempo de treinamento adequado.

Dada a dificuldade de obter resultados satisfatórios com redes neurais, foram procuradas novas metodologias para resolver o problema de previsão da demanda elétrica.

2.3. Previsão utilizando Support Vector Regression

A *Support Vector Regression* (SVR), é uma técnica de regressão não-linear baseada em *Support Vector Machines* (SVM) proposta por [Smola 1998]. Ambas as técnicas estão firmemente baseadas na teoria de aprendizado estatístico, ou teoria VC, que tem sido desenvolvida nas últimas três décadas por Vapnik, Chervonenkis, entre outros. A teoria VC caracteriza as propriedades das máquinas aprendizes de modo a permitir a generalização ótima de dados não vistos.

Foi observado durante os testes com redes neurais que é desnecessário trabalhar com os dados completos integralizados de 15 em 15 minutos, então, nestes experimentos foram utilizados apenas os picos diários. Os dados foram normalizados entre -1 e 1, para evitar trabalhar com os valores relativamente grandes de demanda. A função kernel escolhida foi a função de base radial (RBF), que é a mais complexa entre as funções normalmente usadas em SVMs, mas também a mais geral. A margem ϵ escolhida foi de 0,05, o que, após a normalização, representa um erro de 2,5% acima ou abaixo dos dados de treino. Para simplificar a previsão, também foram codificadas informações sobre o dia da semana nas entradas, de acordo com a Tabela 2 [Chen, Chang e Lin 2004].

Tabela 2- Codificação dos dias da semana

Dia da Semana	Código
Domingo	000000
Segunda	100000
Terça	010000
Quarta	001000
Quinta	000100
Sexta	000010
Sábado	000001

O parâmetro custo foi aumentado gradualmente até não haver mais uma diminuição significativa do erro.

Observando-se que os dados correspondem a uma sazonalidade de longo atraso (anual, mensal) e uma de baixo atraso (semanal), propomos dividir os dados por filtragem em duas partes, uma de baixa frequência, representando a sazonalidade mensal, anual e a tendência, e outra de alta frequência, representando a sazonalidade semanal. Um filtro digital FIR passa-baixas de ordem 100, foi projetado pela técnica de Janelamento com uma janela de Hamming, para uma frequência de corte normalizada de cerca 1/14, o que representaria fisicamente um ciclo periódico completo a cada duas semanas. A alta

freqüência foi obtida através da subtração entre o sinal original e a componente de baixa freqüência. Para que não houvesse atraso e perda de dados durante a filtragem, foi necessário espelhar os 50 pontos iniciais e os 50 pontos finais dos dados, antes de se realizar a filtragem.

A Figura 7 apresenta dados reais, a componente de baixa freqüência obtida por filtragem e a componente de alta freqüência. A soma do sinal de baixa freqüência como sinal de alta freqüência, reconstrói perfeitamente o dado original, técnica esta baseada em análise de sinais por sub-bandas.




Figura 7 - Separação dos dados em sub-bandas

3. Resultados Obtidos

Como medida de desempenho da previsão, é adotado o Erro Médio Absoluto Percentual (MAPE), definido por

$$E_{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{V_{previsto} - V_{real}}{V_{real}} \right| \times 100\% \quad (1)$$

onde $V_{previsto}$ corresponde ao valor previsto e V_{real} o valor de demanda medido real, em N instantes de tempo. O período de tempo no qual o erro é medido, em todos os casos, corresponde a uma semana de previsão.

A rede neural com apenas uma entrada não foi capaz de modelar satisfatoriamente os dados integralizados em 15 minutos. Utilizando as 26 entradas anteriores com a melhor correlação com o ponto atual (atrasos de 15 minutos a 2:30 horas, 24 horas e entre 6 dias e 22 horas e 7 dias e 1:30 hora), com 25 neurônios na camada escondida, obteve-se um MAPE de 5,76%, com um desvio padrão de 7%.

Utilizando apenas uma entrada para prever os picos diários de demanda, com 10 neurônios na camada intermediária, obteve-se um erro de 2,49%, com desvio padrão de 2%, porém, é possível notar na Figura 8 uma tendência de atraso de um dia nos dados previstos. Realizando a previsão para a semana seguinte, o erro passa a ser de 7,10%, mostrando que a rede não se adaptou bem aos dados.




Figura 8 - Resultado da previsão dos picos de demanda com 10 neurônios na camada intermediária

Utilizando como entradas os 28 dias anteriores ao dia a ser previsto, o erro médio de previsão é de 5,67% com desvio padrão de 5%.

Utilizando a SVR, com as entradas correspondentes aos 7 dias anteriores, obteve um MAPE de 4,59% com desvio padrão de 3%. Porém, observando-se a Figura 9 pode-se notar que a previsão é apenas um padrão repetido, não sendo portanto confiável.




Figura 9 - Resultado da predição da SVR com 7 pontos de entrada

Utilizando 28 pontos como entrada, o erro foi de 8,72%, com desvio padrão de 6%. Com 84 dias anteriores como entrada o erro na primeira semana de previsão é de 3,32%, com desvio padrão de 3%. Realizando a previsão uma semana depois, o erro médio é de 3,02%, e duas semanas depois o erro é de 3,17%. Pode-se ver pela Figura 10 que a SVR não se adaptou completamente aos picos dos dados de treinamento.




Figura 10 - Resultado da previsão utilizando 84 pontos

Realizando-se a divisão em sub-bandas, utilizando 84 pontos anteriores em cada SVR, o MAPE na primeira semana de previsão é de 3%, com desvio de 2%. Realizando a previsão na semana seguinte, o erro é de 2,42%, e na próxima semana o erro é de 3,27%. Pode-se ver pela Figura 11 que neste caso a SVR adaptou-se melhor aos dados de treino, alcançando os picos.




Figura 11 - Resultado da previsão utilizando a divisão dos dados em sub-bandas

A Tabela 3 apresenta os resultados obtidos. A coluna MAPE indica o erro obtido na previsão da semana logo após o fim dos dados de treinamento, e a coluna “MAPE na semana seguinte” indica os resultados da previsão uma semana após o fim dos dados de treinamento.

Tabela 3- Resultados para a previsão dos picos diários de demanda

Estrutura	MAPE	MAPE na semana seguinte
Rede Neural, 1 entrada	2,49%	7,10%
Rede Neural, 28 entradas	5,67%	-
SVR, 7 dias de entrada	4,59%	-
SVR, 28 dias de entrada	8,72%	-
SVR, 84 dias de entrada	3,32%	3,02%
SVR, 84 dias de entrada, com sub-bandas	3,00%	2,42%

Para comparação, os resultados em [Chen Chang e Lin 2004] indicam um erro de 1,95% para a previsão de um mês inteiro. Deve-se levar em conta que o previsor foi

desenhado para prever o mês que era objetivo da competição, e não para previsões gerais ao longo do ano.

4. Conclusões

Apresentamos neste artigo duas metodologias de previsão de demanda de potência elétrica utilizando Redes Neurais Artificiais e *Support Vector Regression*.

O uso de RNA obteve resultados satisfatórios, comparáveis com os publicados na literatura, porém sua grande desvantagem é a definição automática da estrutura da rede, que envolve um grande número de testes, e muita experiência por parte do projetista.

Uma forma de aliviar esses requerimentos, é a adoção da técnica SVR, no qual o único parâmetro a ser ajustado é o custo C , que pode ser feita de forma automática de busca completa em um universo real, facilitando muito a sua automatização.

A divisão em sub-bandas dos dados de demanda, com base nas sazonalidades de longo prazo e sazonalidade de curto prazo, apresentou-se eficiente, melhorando ainda mais o desempenho do previsor baseado em SVR. Tal alternativa poderia ser testada também com RNA, porém devido ao seu inerente elevado tempo de treinamento, isso não foi realizado neste trabalho.

Referências

- Chen, B.J., Chang, M.W. and Lin, C.J., (2004) "Load Forecasting Using Support Vector Machines: A Study on EUNITE Competition 2001", In: *IEEE Transactions on Power Systems*, Vol. 19, No. 4, Nov. 2004, pp. 1821-1830.
- Kremer, S.C. (1995) "On the Computational Power of Elman-Style Recurrent Networks", In: *IEEE Trans. On Neural Networks*, vol. 6, pp.1000-1004.
- Smola, A.J., and Schölkopf, B., (1998) "A Tutorial on Support Vector Regression", *NeuroCOLT2 Technical Report Series TR NC-TR-98-030*, Royal Holloway College, University of London, UK.
- Elman, J.L. (1990) "Finding Structure in Time", In: *Cognitive Science*, vol. 14, pp.179-221.
- Haykin, S. (1998) *Neural Networks: a Comprehensive Foundation*, Prentice Hall PTR Upper Saddle River, NJ, USA.