

PREVISÃO DE DEMANDA POR ENERGIA ELÉTRICA: INCLUSÃO DO ATRIBUTO TEMPERATURA

José Vicente Canto dos Santos
PIPCA - UNISINOS
Av. Unisinos, 950, São Leopoldo, RS
jycanto@unisinos.br

João Francisco Valiati
PIPCA - UNISINOS
Av. Unisinos, 950, São Leopoldo, RS
jfvaliati@unisinos.br

Wilson Pires Gavião Neto
PIPCA - UNISINOS
Av. Unisinos, 950, São Leopoldo, RS
wgaviao@gmail.com

Resumo

Este trabalho apresenta as atividades de análise e desenvolvimento de um sistema baseado em Redes Neurais Artificiais para prever a demanda por energia elétrica para a região norte-nordeste do estado do Rio Grande do Sul. A arquitetura do sistema proposto é modular, facilitando a manutenção e evolução, com destaque para o módulo de redes neurais que realiza a previsão de demanda com baixos níveis de erro. Além disso, apresenta-se uma análise dos efeitos causados pela inclusão da temperatura no processo de previsão, bem como uma proposição de estruturação de dados provenientes de diferentes domínios (temperatura e consumo de energia) na forma de entrada para o modelo neural. Os testes demonstraram um desempenho adequado para o sistema proposto.

Palavras-chave: Previsão de Demanda por Energia Elétrica, Sistemas Elétricos de Potência, Redes Neurais Artificiais.

Abstract

This paper reports the analysis and development of an electric load forecast system, which is based on Artificial Neural Networks (ANN), for the north-northwest region of the Rio Grande do Sul State in Brazil. In order to make upgrades easier, the proposed system is designed to be modular. Also, we address the effects of taking into account the temperature for the load forecast process as well as the non-trivial combination of distinct sources of data (e.g. temperature and historical load data) as input into a neural model. Our experiments indicate that the proposed ANN model performs satisfactorily, since it produces low error rates.

Keywords: Electric Load Forecast, Power Systems Engineering, Artificial Neural Networks.

1. Introdução

Após a aprovação da Lei Federal nº 10.848 de 5/5/2004, o setor elétrico brasileiro passou por uma setorização das principais atividades relacionadas à energia elétrica: geração, transmissão e distribuição. Isto fez com que empresas exclusivamente de distribuição de energia elétrica fossem criadas, fornecendo serviços e cobrando tarifas coerentes com a geração e transmissão da energia elétrica. Tais empresas devem operar sob as regulamentações da Agência Nacional de Energia Elétrica (ANEEL). A Agência define, basicamente, que as empresas devem efetuar um contrato contendo a quantidade de energia a ser distribuída. Além disso, caso a energia distribuída seja menor que o estabelecido no contrato, a empresa deve pagar todo o valor contratado. Por outro lado, se a energia distribuída exceder o valor estabelecido, a empresa estará exposta a penalidades por lastro de energia elétrica. Assim, caso a empresa distribua energia em quantidades muito diferentes do valor contratado, essa estará sujeita a grandes prejuízos.

Vários métodos de previsão de demanda por energia elétrica têm sido propostos com o objetivo de solucionar problemas de enfoque comercial como o mencionado acima, assim como problemas de ordem técnica em uma empresa de energia elétrica (Ghods & Kalantar, 2008).

Esse trabalho apresenta um sistema de previsão de carga baseado em Redes Neurais Artificiais (RNAs) para a parte norte-nordeste do Estado do Rio Grande do Sul. Também é apresentada uma análise detalhada sobre os efeitos de incluir o atributo temperatura na arquitetura do sistema. Este trabalho é fruto de um projeto de Pesquisa e Desenvolvimento realizado em parceria entre a UNISINOS e a Rio Grande Energia S A (RGE).

2. Previsão de demanda por energia elétrica

Como mencionado anteriormente, diferentes modelos de previsão de carga foram propostos pela academia. Em Ghods & Kalantar, (2008) é possível encontrar uma classificação desses modelos com base no prazo em que os mesmos devem realizar a previsão. Em um dos extremos dessa lista, encontram-se previsores de carga de curto prazo, realizando previsões para os próximos minutos, horas ou alguns dias à frente. Esses previsores são usados pelas empresas de distribuição de energia elétrica, principalmente no auxílio da compra e venda de quotas no mercado de energia; e também em sistemas de gestão de carga, para garantir que o suprimento de energia seja sempre capaz de suportar a demanda existente. No outro extremo, figuram previsores de muito longo prazo, onde a previsão de demanda é realizada para vários anos no futuro. Previsões desse tipo são usadas para agendar atividades de manutenção dos equipamentos nas empresas de distribuição de energia, para planejar a expansão do sistema de transmissão e para firmar contratos de distribuição de energia elétrica entre a empresa de distribuição e seus maiores clientes. Os previsores de curto prazo receberam grande atenção dos cientistas no passado e muitas abordagens foram propostas, sendo as mais notáveis: ARIMA (Mbamalu & El-Hawary, 1993), regressão linear (Papalexopoulos & Hesterberg, 1990), sistemas especialistas (Rahman & Hazim, 1990), RNAs (Park et al., 1991) e RNAs combinadas com lógica difusa (Srinivasan et al., 1999).

Dentre os trabalhos com foco em previsores de médio prazo, gerando previsões mensais, destaca-se o Romera et al. (2007). Trabalhos envolvendo previsões para prazos mais longos raramente são publicados, mas é possível mencionar Ghods & Kalantar, (2008).

Quando os dados sobre a demanda de energia são analisados ao longo do tempo, eles podem ser tratados como uma série temporal. Dessa forma, a previsão para os valores futuros de demanda por energia é realizada com base nos dados sobre a própria demanda registrados no passado (Romera et al., 2007). No entanto, a literatura coloca que é aconselhável utilizar dados

climáticos (Fan et al., 2008), tais como temperatura e umidade, em conjunto com os dados de consumo de energia.

3. Definição do problema

Atualmente, a RGE utiliza um método de previsão de carga baseado no consumo dos últimos três meses, em que também é analisado o comportamento da carga típico de dias de semana, fins de semana e feriados. No entanto, este método é realizado de forma não automática, consumindo tempo, recursos e gerando resultados não confiáveis. Dessa forma, o principal interesse da RGE consiste em um sistema capaz de automatizar ao máximo o processo de previsão, além de torná-lo mais preciso.

Após reuniões entre a equipe do projeto e a RGE, foi compilada uma listagem estável de requisitos do sistema. Os principais requisitos funcionais estão relacionados abaixo:

- previsão de carga de curto prazo: tem como objetivo informar a média da demanda por energia elétrica prevista para o mês corrente e para o mês seguinte. No sistema, o mês é tratado como tendo 30 dias;
- previsão de carga de longo prazo: deve informar a média da demanda por energia elétrica prevista para o ano corrente ou para o ano seguinte. Adotou-se como medida de ano um conjunto de 365 dias;

É importante destacar que a terminologia de horizontes de previsão empregada pela RGE difere daquela comumente utilizada pelos pesquisadores da área de previsão de carga. Neste artigo é utilizada a terminologia adotada no projeto, ou seja, previsões de curto e longo prazo referem-se, respectivamente a previsões mensais e anuais. O erro máximo definido para as RNAs constitui um importante requisito do sistema: definiu-se que as RNAs não devem apresentar um erro superior a 5% para cada região geo-elétrica considerada, tal como em Ardil et al. (2008). Deste modo, as previsões de curto e longo prazo devem ser realizadas para qualquer uma das sete regiões geo-elétricas que constituem a área de concessão da RGE, representadas pelas cidades de: Caxias do Sul, Erechim, Gravataí, Nova Prata, Passo Fundo, Santa Rosa e Taquara. Cada uma destas regiões compreende diversos municípios e suas denominações derivam dos principais municípios de cada uma delas.

4. Sistema de previsão

O sistema foi desenvolvido de acordo com o padrão de arquitetura MVC (*Model-View-Controller*). Essa abordagem propicia uma separação dos dados (*Model*) da interface (*View*), sendo o controlador (*Controller*) responsável por manipular os dados e realizar a submissão dos mesmos à RNA correspondente. Essa decomposição também garante maior facilidade de entendimento e manutenção do sistema. Os módulos da interface e controle foram desenvolvidos com a linguagem C#. Já as redes neurais foram construídas e treinadas com a plataforma estatística R. A ligação entre os diferentes módulos foi possível graças à tecnologia COM (*Component Object Model*), evitando a necessidade de codificar meios de comunicação entre módulos gerados em tecnologias diferentes. A Figura 1 mostra a interface gráfica do sistema.

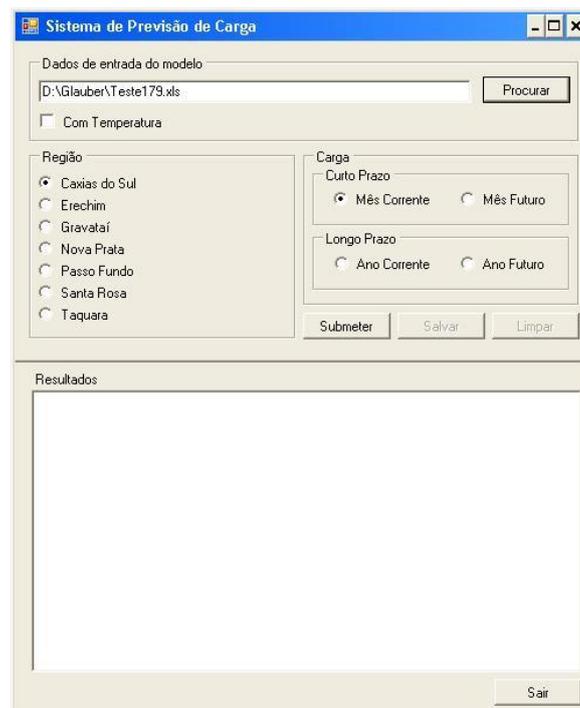


Figura 1: Interface gráfica do sistema

O funcionamento básico do sistema pode ser descrito do seguinte modo: o usuário informa ao sistema para qual região geo-elétrica deseja obter a previsão, se esta deve ou não considerar o fator temperatura e também envia um arquivo contendo os dados de entrada para a RNA. O módulo de controle então submete os dados informados pelo usuário para a RNA responsável por prever a demanda para a região selecionada. Após, o módulo de controle atualiza a interface gráfica com a resposta estimada pela RNA. O usuário pode salvar o resultado encontrado, caso julgar necessário. Com base nos padrões adotados na maioria dos trabalhos relacionados à previsão de carga na literatura Ardil et al., (2008) Botha & Vermaak, (1998) e Charytoniuk & Chen, (2000), optou-se pela utilização de RNAs do tipo *feedforward* com uma camada oculta. Todas as RNAs foram treinadas com o algoritmo *backpropagation*. Os parâmetros de taxa de aprendizagem e momento para o algoritmo de treinamento foram definidos, respectivamente, como 0,01 e 0,5.

A base de dados usada para elaborar a RNA é constituída pelo consumo diário de energia elétrica, registrado no período de março de 1999 até dezembro de 2008, para cada uma das regiões consideradas. No que se refere ao horizonte de curto prazo, a série temporal foi processada para gerar os dados de saída do conjunto de treinamento: a série foi percorrida por uma janela de trinta dias. A cada posição da janela foi gerado um novo dado correspondendo à média dos trinta dias dentro da janela. Procedimento semelhante foi adotado para o horizonte de longo prazo, porém com uma janela de 365 dias, conforme é apresentado na próxima seção. Como de hábito, em sistemas de previsão, os dados foram normalizados.

Durante a fase de desenvolvimento do sistema, foram testadas diversas configurações para as RNAs desenvolvidas. Assim, propriedades como número de neurônios ocultos, utilização ou não de *Shortcut connections*, número de épocas de treinamento, e valores para semente para inicialização dos pesos foram intensivamente simuladas e avaliadas. Como métrica para avaliação do desempenho das redes utilizou-se o Erro Quadrático Médio Normalizado (EQMN) obtido. Essa métrica pode ser calculada através da equação (1):

$$EQMN = \frac{EQM}{V - v}, \quad (1)$$

onde EQM é o Erro Quadrático Médio, V e v correspondem respectivamente ao maior e menor valor da série temporal de carga. O EQM é obtido conforme abaixo (2):

$$EQM = \frac{\sqrt{(vr - ve)^2}}{\sqrt{n}}, \quad (2)$$

onde vr é o valor real (presente na base de dados), ve é o valor estimado pela RNA e n é o número total de dados.

5. Experimentos sem o fator temperatura

Primeiramente, os experimentos foram conduzidos com base em dados históricos de demanda por energia. Para tanto, empregaram-se técnicas de janelamento como forma de estruturar os dados para o processamento nas redes neurais.

A aplicação de técnicas de janelamento se fez necessária em virtude de tratar-se de dois horizontes de previsão, sendo considerada uma janela temporal de 30 dias para previsão de curto prazo e outra janela de 365 dias para propósitos em longo prazo. Por exemplo, considerando o horizonte de curto prazo, a janela é posicionada no primeiro dia, no caso 01/03/1999, estendendo-se até o trigésimo dia, isto é, 31/03/1999. Cada amostra foi construída pelo movimento da janela discretizado em dias, tendo como limite o antepenúltimo mês da seqüência, no caso 31/10/2008. Os dois meses restantes da série foram reservados para testes. Além disso, associado a cada amostra, inclui-se ao seu final a média dos 30 dias subseqüentes, representando o valor de previsão que é entendido como correto para a amostra em questão, isto é, representando a saída desejada da rede neural. O mesmo procedimento foi aplicado para o horizonte de longo prazo, considerando, contudo, um tamanho de janela de 365 dias.

Com base em regiões geo-elétricas e horizontes de previsão definiu-se a organização do módulo neural do sistema. A arquitetura de rede neural adotada foi do tipo *feedforward*, com uma camada escondida e o algoritmo de treinamento *backpropagation*. Estas escolhas justificam-se pelo sucesso verificado na literatura quando trata-se de aprendizado supervisionado e tarefas de previsão, alguns exemplos estão nos trabalhos de Park et al. (1991) e Charytoniuk & Chen, (2000). Um conjunto de parâmetros padrões foi determinado a fim de realizar o processo de treinamento para cada conjunto de dados. A Tabela 1 mostra os parâmetros de treinamento para cada horizonte. O número de neurônios escondidos e épocas são definidos experimentalmente com o objetivo de encontrar a melhor configuração dos modelos.

Tabela 1 - Lista de parâmetros para o modelo de treinamento

Parâmetros	Horizontes	
	Curto prazo	Longo prazo
Nº de entradas	30	365
Nº de saídas	1	1
Nº de nós escondidos	30	150
Nº de épocas	4000,10000,15000	5000,15000, 20000

O processo de treinamento inicia com um baixo número de neurônios, sendo que, a cada modelo, o número de neurônios escondidos foi incrementado em um neurônio até atingir-se a

quantidade máxima de neurônios estabelecida. O modelo que apresentou a menor percentagem de erro foi escolhido para a realização de testes. Como resultado foram gerados 14 modelos neurais, correspondentes as 7 regiões geo-elétricas e 2 horizontes.

6. Experimentos com o fator temperatura

A soma dos erros obtida para cada região geo-elétrica foi considerada não satisfatória segundo as metas de erro esperadas pela RGE, como apresentado a seguir. Este fato conduziu à necessidade de agregar outras fontes de informação, que não apenas dados de demanda, no sentido de melhorar a base de conhecimento para propósitos de previsão de demanda por energia elétrica. Entre vários fatores que influenciam o consumo elétrico, aspectos meteorológicos são considerados importantes, sendo o fator temperatura um dos mais acessíveis e importantes.

A possibilidade de incluir dados sobre temperatura diária em cada região geo-elétrica abre uma perspectiva de melhores resultados, porém faz surgir o desafio de encontrar uma boa maneira de associar dados distintos em um modelo neural: consumo de energia, em Megawatt/hora e temperatura, em graus Celsius.

Partindo-se de dois cenários de consumo, curto e longo prazo, adaptou-se a informação de temperatura. Nesse sentido, como os dados disponíveis de temperatura estão na forma de registros horários, se fez necessário o cálculo da média diária de temperatura, que foi tomada com base em valores diários de temperatura máxima e mínima. Deste modo, obteve-se uma discretização de dados de temperatura em acordo com as informações diárias de consumo de energia. O próximo passo consta no desafio de associar diferentes domínios de informação (séries temporais de temperatura e consumo) para propósitos de previsão. Para tanto, optou-se por experimentação empírica com base nos seguintes passos:

- (1) Antes de estruturar o conjunto de dados para treinamento das redes neurais, ambos os fatores foram normalizados.
- (2) Este passo consta da organização dos dados para treinamento. Neste sentido, foram estruturados dois conjuntos de dados para cada região geo-elétrica, rotulados como Ordenado e Alternado, como mostrado nas Figuras 2 e 3:
 - a. **Ordenado:** Nesta formatação faixas de dados de energia são intercaladas por faixas de dados de temperatura, onde faixas de 30 dias contemplam horizontes de curto prazo e faixas de 365 dias contemplam horizontes de longo prazo, conforme ilustrado na Figura 2;
 - b. **Alternado:** Nesta formatação os dados de energia são intercalados por dados de temperatura em faixas diárias, como ilustrado na Figura 3.

dias		dias	
1	carga1	1	carga1
2	carga2	2	carga2
⋮	⋮	⋮	⋮
30	carga30	365	carga365
1	temp1	1	temp1
2	temp2	2	temp2
⋮	⋮	⋮	⋮
30	temp30	365	temp365

Figura 2 - Organização dos dados de temperatura e energia no formato Ordenado. (a) Horizonte de curto prazo. (b) Horizonte de longo prazo

dias		dias	
1	carga1	1	carga1
1	temp1	1	temp1
2	carga2	2	carga2
2	temp2	2	temp2
⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮
30	carga30	365	carga365
30	temp30	365	temp365

Figura 3 - Organização dos dados de temperatura e energia no formato Alternado. (a) Horizonte de curto prazo. (b) Horizonte de longo prazo

Após a preparação dos dados procedeu-se com a etapa de treinamento do modelo neural. Para tanto, seguiram-se as mesmas configurações resumidas na Tabela 1. Entretanto, devido a indisponibilidade de dados de temperatura para duas regiões, foram gerados 20 modelos neurais, correspondentes as 5 regiões geo-elétricas em dois horizontes e dois formatos de dados (Ordenado e Alternado).

7. Resultados

Os valores apresentados para cada horizonte correspondem ao cálculo da métrica representada pela Equação 1. A Tabela 2 mostra os resultados obtidos para cada região geo-elétrica sem considerar o fator temperatura. Embora verifiquem-se bons resultados para algumas regiões, a soma do erro, como meio de avaliação geral do previsor, não foi satisfatória. Assim, com o objetivo de contornar esse problema, procedeu-se com a inclusão do fator temperatura conforme descrito anteriormente.

Tabela 2 - Resultados obtidos sem considerar o fator temperatura (erro).

Região	Curto Prazo	Longo Prazo
Caxias	0,72	3,83
Erechim	4,32	2,04
Gravataí	0,44	5,04
Passo Fundo	4,66	0,21
Santa Rosa	4,16	0,39
Soma	14,3	11,51

A Tabela 3 mostra os resultados obtidos considerando-se o fator temperatura no formato Ordenado. Pode-se verificar uma considerável redução na porcentagem de erro quando compara-se com os resultados obtidos sem a inclusão da temperatura.

Tabela 3 - Resultados obtidos considerando-se o fator temperatura no formato Ordenado.

Região	Curto Prazo	Longo Prazo
Caxias	1,776	1,956
Erechim	3,028	0,004
Gravataí	0,205	1,557
Passo Fundo	1,651	0,243
Santa Rosa	0,409	0,309
Soma	7,069	4,069

A Tabela 4 mostra os resultados obtidos considerando-se o fator temperatura no formato Alternado, como descrito na Seção 4.2. Verifica-se pequena redução na porcentagem de erro no horizonte de curto prazo e maior redução do erro para o horizonte de longo prazo, quando compara-se com resultados obtidos na formatação Ordenada dos dados.

Tabela 4 - Resultados obtidos considerando-se o fator temperatura no formato Alternado.

Região	Curto Prazo	Longo Prazo
Caxias	1,777	2,003
Erechim	2,995	0,068
Gravataí	0,242	0,325
Passo Fundo	1,659	0,262
Santa Rosa	0,197	0,156
Soma	6,870	2,814

Em termos gerais de avaliação de desempenho, adotou-se a soma dos erros de previsão em cada região. No entanto, deve-se observar que, na comparação das abordagens que considera ou não o fator temperatura, eliminou-se duas regiões (Nova Prata e Taquara) em virtude da ausência de dados de temperatura para estas localidades. Sendo assim, para o mesmo conjunto de regiões (isto é, Caxias, Erechim, Gravataí, Passo Fundo e Santa Rosa), a abordagem sem o fator temperatura resultou em um erro total de 14,30% para o horizonte de curto prazo e 11,51% para o horizonte de longo prazo. Deste modo, com base nas Tabelas 3 e 4, pode-se notar a importância do fator temperatura no processo de previsão, uma vez que verificou-se um desempenho superior a 100% quando compara-se a abordagem que considera a temperatura contra a abordagem que não inclui o fator temperatura. Adicionalmente, os experimentos conduzidos com a formatação de dados Alternada, sobretudo em relação ao horizonte de longo prazo, mostraram um erro quatro vezes menor em relação à abordagem que não inclui o fator temperatura.

8. Considerações finais

Esse trabalho apresentou um sistema de previsão de demanda por energia elétrica baseado em RNAs, desenvolvido no contexto de um projeto de Pesquisa e Desenvolvimento entre UNISINOS e RGE. Inicialmente a construção do sistema baseou-se em dados históricos de consumo de energia, sendo que os resultados não se mostraram satisfatórios. Em um segundo momento, incluiu-se dados de temperatura na construção do modelo neural. Verificou-se então uma considerável melhora de desempenho para horizontes de previsão distintos, confirmando a importância do fator temperatura no processo de previsão de demanda por energia elétrica. Destaca-se ainda a organização dos dados no sentido de integrar informações de domínios distintos (temperatura e consumo de energia) para propósitos de previsão e também a possibilidade de previsões para dois horizontes temporais distintos, algo difícil de encontrar na literatura especializada.

Como trabalhos futuros, pretende-se investigar aspectos de sazonalidade, bem como a inserção de outros fatores que possam contribuir para melhores previsões de consumo, tais como variáveis macroeconômicas e outras.

Referências

ARDIL, C., MANJUNATH, T., MEHTA, H. (2008). A multi-layer artificial neural network architecture design for load forecasting in power systems. *International Journal of Applied Mathematics and Computer Sciences*, 4 (4), 228-241.

BOTHA, E. & VERMAAK, J. (1998). Recurrent neural networks for short-term load forecasting. *IEEE Transactions on Power Systems*, 13 (1), 126-132.

CHARYTONIUK, W. & CHEN, M. (2000). Very short-term load forecasting using artificial neural networks. *IEEE Transactions on Power Systems*, 15 (1), 263-268.

FAN, S., CHEN, L., LEE, W. J., (2008). Short-term load forecasting using comprehensive combination based on multi- meteorological information, *IEEE/IAS Industrial and Commercial Power Systems Technical Conference*, 1-7. Clearwater Beach, FL, USA.

GHODS, L. & KALANTAR, M. (2008). Methods for long-term electric load demand forecasting; a comprehensive investigation. *IEEE International Conference on Industrial Technology*, 1-4.

MBAMALU, G. & EL-HAWARY, M. (1993). Load forecasting via suboptimal seasonal autoregressive models and iteratively reweighted least squares estimation. *IEEE Transactions on Power Systems*, 8 (1), 343-348.

PAPALEXOPOULOS, A. & HESTERBERG, T. (1990). A regression-based approach to short-term load forecasting. *IEEE Transactions on Power Systems*, 5 (4), 1535-1547.

PARK, D., EL-SHARKAWI, M., MARKS, R., ATLAS, L., DAMBORG, M. (1991). Electric load forecasting using an artificial neural network. *IEEE Transactions on Power Systems*, 6 (2), 442-449.

RAHMAN, S. & HAZIM, O. (1993). A generalized knowledge-based short-term load-forecasting technique. *IEEE Transactions on Power Systems*, 8 (2), 508-514.

ROMERA, E., MORÁN, M., FERNÁNDEZ, D. (2007). Forecasting of the electric energy demand trend and monthly fluctuation with neural networks. *Elsevier Computers and Industrial Engineering*, 2007, 52 (3), 336-343.

SRINIVASAN, D., TAN, S., CHENG, C., CHAN, E. (1999). Parallel neural network-fuzzy expert system strategy for short-term load forecasting: system implementation and performance evaluation. *IEEE Transactions on Power Systems*, 14 (3), 1100-1106.