

Referências

ADYA, M. et al. Automatic identification of time series features for rule-based forecasting. **International Journal of Forecasting**, v. 17, p. 143-157, 2001.

ADYA, M.; COLLOPY, F. How effective are neural networks at forecasting and prediction? A review and evaluation. **Journal of Forecasting**, v. 17, p. 481-495, 1998.

ANP. **Agência Nacional do Petróleo, Gás Natural e Biocombustíveis**. Disponível em: <<http://www.anp.gov.br/>>. Acesso em: 1 abr. 2011.

ARINZE, B. Selecting appropriate forecasting models using rule induction. **Omega**, v. 22, p. 647-658, 1994.

BATES, J. M.; GRANGER, C. W. J. The combination of forecasts. **Operations Research quarterly**, v. 20, p. 451-468, 1969.

BFS. **Business Forecast Systems - Forecast Pro**. Disponível em: <<http://www.forecastpro.com>>. Acesso em: 16 nov. 2010.

BISHOP, C. M. **Neural networks for pattern recognition**. UK: Oxford University Press, 1995.

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time Series Analysis: Forecasting and Control**. 4. ed. [S.I.]: Wiley, 2008.

CHASE, C. W. **Demand-driven forecasting: a structured approach to forecasting**. [S.I.]: Wiley, 2009.

CHATFIELD, C.; YAR, M. Holt-Winters Forecasting: Some Practical Issues. **The statistician** (special issue), v. 37, n. 2, p. 129-140, 1988.

CLEMEN, R.T. Combining forecasts: a review and annotated bibliography. **International Journal of Forecasting**, v. 5, p. 559-581, 1989.

CORDEIRO, C.; NEVES, M. M. Boot.EXPOS in NNGC competition. In: 30TH INTERNATIONAL SYMPOSIUM ON FORECASTING, 2010, San Diego. **Proceedings of the 30th International Symposium on Forecasting**. [S.l.:s.n.], 2010. Disponível em <<http://forecasters.org/submissions10/CordeiroClaralSF2010.pdf>>. Acesso em: 1 nov. 2010.

CROMWELL, J. B.; LABYS, W. C.; TERRAZA, M. **Univariate Tests for Time Series Models**. [S.l.]: Sage Publications, 1994.

CRONE, S. F.; GRAFFEILLE, P. C. An evaluation framework for publications on artificial neural networks in sales forecasting. In: INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE, IC-AI'04, 2004, Las Vegas. **Proceedings of the IC-AI '04**. [S.l.]: CSREA Press, 2004.

CYBENKO, G. Approximations by superpositions of sigmoidal functions. **Mathematics of Control, Signals and Systems**, v. 2, p. 303-314, 1989.

DIEBOLD, F. X.; PAULY, P. The use of prior information in forecast combination. **International Journal of Forecasting**, v. 6, p. 503-508, 1990.

DONALDSON, R. G.; KAMSTRA, M. Forecast Combining with Neural Networks. **Journal of Forecasting**, v. 15, p. 49-61, 1996.

EFRON, B.; TIBSHIRANI, R. **An introduction to the bootstrap**. [S.l.]: Chapman & Hall, 1993.

FILDES, R. et al. Effective forecasting and judgmental adjustments: an empirical evaluation and strategies for improvement in supply-chain planning. **International Journal of Forecasting**, v. 25, p. 3-23, 2009.

FLORES, B. E. Use of the sign test to supplement the percentage better statistic. **International Journal of Forecasting**, v. 2, p. 477-489, 1986.

_____. The utilization of the Wilcoxon test to compare forecasting methods: A note. **International Journal of Forecasting**, v. 5, p. 529-535, 1989.

FRANSES, P. H. Do We Think We Make Better Forecasts Than in the Past? A Survey of Academics. **Interfaces**, v. 34, n. 6, p. 466-468, 2004.

GIBBONS, J. D. **Nonparametric Statistics: An Introduction**. [S.l.]: Sage Publications, 1992.

GILL, P. E. et al. Procedures for optimization problems with a mixture of bounds and general linear constraints. **ACM Transactions on Mathematical Software**, v. 10, p. 282-298, 1984.

GOODWIN, P. Integrating management judgment and statistical methods to improve short-term forecasts. **Omega**, v. 30, p. 127-135, 2002.

GORDON, T. J. Energy forecasts using a “Roundless” approach to running a Delphi study. **Foresight**, v. 9, n. 2, p. 27-35, 2007.

HAGAN, M.T.; MENHAJ, M. Training feed-forward networks with the Marquardt algorithm. **IEEE Transactions on Neural Networks**, v. 5, n. 6, p. 989–993, 1994.

HARVEY, A. C. **Forecasting, Structural Time Series Models and the Kalman Filter**. [S.l.]: Cambridge University Press, 1991.

HAYKIN, S. **Neural Networks: a Comprehensive Foundation**. 2. ed. USA: Prentice Hall, 1998.

HIBON, M.; EVGENIOU, T. To combine or not to combine: selecting among forecasts and their combinations. **International Journal of Forecasting**, v. 21, p. 5-24, 2005.

ICTFS. **1st International Competition of Time Series Forecasting**. Disponível em: <<http://www.caos.inf.uc3m.es/~jperalta/ICTSF/>>. Acesso em: 12 jan. 2012.

IJCNN. **IJCNN competition program**. Disponível em: <<http://www.ijcnn2011.org/competitions.php>>. Acesso em: 20 jan. 2011.

JACOBS, R. A. et al. Adaptive mixtures of local experts. **Neural Computation**, v. 3, p. 79-87, 1991.

JOHNSON, R. A.; WICHERN, D. W. **Applied Multivariate Statistical Analysis**. 6 ed. [S.l.]: Prentice Hall, 2007.

KACHIGAN, S. K. **Statistical Analysis: An Interdisciplinary Introduction to Univariate & Multivariate Methods**. [S.l.]: Radius Press, 1986.

KURRLE, M. A. **Método para previsão de demanda de veículos novos** - estudo de caso em uma concessionária de automóveis. Trabalho de conclusão do curso de mestrado profissionalizante em engenharia - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2004.

LEMKE, C.; GABRYS, B. Meta-learning for time series forecasting and forecast combination. **Neurocomputing**, v. 73, p. 2006-2016, 2010.

LEMONS, F. O.; FOGLIATTO, F. S. Integração de métodos qualitativos e quantitativos de previsão para desenvolvimento de um sistema de previsão de demanda de novos produtos. **Revista Gestão Industrial** (Universidade Tecnológica Federal do Paraná), v. 4, n. 3, p. 84-98, 2008.

MAKRIDAKIS, S. G.; HIBON, M. Exponential smoothing: The effect of initial values and loss functions on post-sample forecasting accuracy. **International Journal of Forecasting**, v.7, p. 317-330, 1991.

_____. The M3-competition: Results, conclusions and implications. **International Journal of Forecasting** (special issue), v. 16, p. 451-476, 2000.

MAKRIDAKIS, S. G.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. **Forecasting: methods and applications**. 3 ed. [S.l.]: Wiley, 1998.

MARCELLINO, M.; STOCK, J. H.; WATSON, M. W. A comparison of direct and iterated multistep AR methods for forecasting macroeconomic time series. **Journal of Econometrics**, v. 135, p. 499-526, 2006.

MATHWORKS. **MATLAB – Optimization Toolbox 4**. [S.l.:s.n.], 2009. Disponível em: <http://www.mathworks.com/access/helpdesk/help/pdf_doc/optim/optim_tb.pdf>. Acesso em: 3 mar. 2010a.

_____. **MATLAB – Neural Network Toolbox 6**. [S.l.:s.n.], 2009. Disponível em: <http://www.mathworks.com/access/helpdesk/help/pdf_doc/nnet/nnet.pdf>. Acesso em: 3 mar. 2010b.

_____. **MATLAB – The Language of Technical Computing**. Disponível em: <http://www.mathworks.com/access/helpdesk/help/pdf_doc/nnet/nnet.pdf>. Acesso em: 3 mar. 2010c.

MICROSOFT. **Microsoft Excel 2010**. Disponível em: <<http://office.microsoft.com/pt-br/excel/>>. Acesso em: 12 jan. 2011.

MUBWANDARIKWA, E. **Modality conditions and prior weights in the geometric combination of bayesian forecasting models**. Tese (PhD) - The Open University Walton Hall, UK, 2007.

NEWBOLD, P.; GRANGER, C. W. J. Experience with forecasting univariate time series and the combination of forecasts. **Journal of the Royal Statistical Society (A)**, v. 137, p. 131-146, 1974.

NN3. **NN3 Home**. Disponível em: <<http://www.neural-forecasting-competition.com/NN3/index.htm>>. Acesso em: 10 jan. 2011.

NEURAL-NETS FAQ. **Comp.ai.neural-nets FAQ by Warren S. Sarle**. [S.l.:s.n.], 1997. Disponível em: <<http://www.faqs.org/faqs/ai-faq/neural-nets/part1/preamble.html>>. Acesso em: 10 jan. 2011.

ORRELL, D. **Economyths: ten ways economics gets it wrong**. 1. ed. [S.l.]: Wiley, 2010.

PAI, P.; LIN, C. A hybrid ARIMA and support vector machines model in stock price forecasting. **Omega**, v. 33, p. 497 – 505, 2005.

PANKRATZ, A. **Forecasting with Dynamic Regression Models**. [S.l.]: Wiley-Interscience, 1991.

POLE, A.; WEST, M.; HARRISON, J. **Applied Bayesian forecasting and time series analysis**. [S.l.]: Chapman & Hall, 1994.

PRUDÊNCIO, R. B. C.; LUDERMIR, T. B. Learning weights for linear combination of forecasting methods. In: 9th BRAZILIAN SYMPOSIUM ON NEURAL NETWORKS, 2006, Ribeirão Preto. **Proceedings of the 9th Brazilian Symposium on Neural Networks**. [S.l.]: IEEE, p.113-118, 2006.

REED, R.; MARKS, R. J. **Neural Smothing**: Supervised Learning in Feedforward Artificial Neural Networks. [S.l.]: The MIT Press, 1999.

ROSS, S. M. **Simulation**. 4. ed. [S.l.]: Academic Press, 2006.

SÁNCHEZ, I. Adaptive combination of forecasts with application to wind energy. **International Journal of Forecasting**, v. 24, p. 679-693, 2008.

SHARKEY, A. J. C. **Combining artificial neural nets**: ensemble and modular multi-net systems. Perspectives in neural computing. [S.l.]: Springer, 1999.

SOUZA, R. C.; CAMARGO, M. E. **Análise e Previsão de Séries Temporais**: os modelos ARIMA. 2. ed. [S.l.:s.n.], 2004.

STEKLER, H. The M3-Competition: the need for formal statistical tests. **International Journal of Forecasting**, v. 17, p. 537-584, 2001.

STOCK, J. H.; WATSON, M. W. A comparison of linear and nonlinear univariate models for forecasting macroeconomic time series. In: ENGLE, R. F.; WHITE, H. (Eds.) **Festschrift in Honour of Clive Granger**. Cambridge: Cambridge University Press, p.1-44, 2001.

_____. Forecasting with many predictors. In: ELLIOTT, G.; GRANGER, C. W. J.; TIMMERMANN, A. (Eds.) **Handbook of economic forecasting**, volume 1. [S.I.]: North-Holland, p. 515-554, 2006.

TIMMERMANN, A. Forecast combination. In: ELLIOTT, G.; GRANGER, C. W. J.; TIMMERMANN, A. (Eds.) **Handbook of economic forecasting**, volume 1. [S.I.]: North-Holland, p. 135–196, 2006.

WANG, X.; SMITH-MILES, K.; HYNDMAN, R. Rule induction for forecasting method selection: Meta-learning the characteristics of univariate time series. **Neurocomputing**, v. 72, p. 2581-2594, 2009.

WEBBY, R.; O'CONNOR, M. Judgmental and statistical time series forecasting: a review of the literature. **International Journal of Forecasting**, v. 12, p. 91-118, 1996.

WITTEN, I. H.; FRANK, E. **Data mining**: practical machine learning tools and techniques. 2. ed. [S.I.]: Morgan Kaufmann, 2005.

WOLPERT, D. Stacked generalization. **Neural Networks**, v. 5, p. 241-259, 1992.

WRIGHT, J. T. C.; GIOVINAZZO, R. A. Delphi – uma ferramenta de apoio ao planejamento prospectivo. **Caderno de Pesquisas em Administração** (Revista de Gestão USP), v.1, n. 12, p. 54-65, 2000.

YANG, Y. Combining forecasting procedures: some theoretical results. **Econometric Theory**, v.20, n.1, p. 176-222, 2004.

ZHANG, G. P. Time series forecasting using a hybrid ARIMA and neural network model. **Neurocomputing**, v. 50, p. 159-175, 2003.

ZHANG, G.; PATUWO, B. E.; HU, M. Y. Forecasting with artificial neural networks: The state of the art. **International Journal Of Forecasting**, v. 14, p. 35-62, 1998.

ZOU, H.; YANG, Y. Combining time series models for forecasting. **International Journal of Forecasting** v. 20, p. 69-84, 2004.

Apêndice A

Metodologias de previsão

A.1. Holt-Winters multiplicativo

O Holt-Winters multiplicativo (HW) é um método adaptativo, largamente utilizado em previsão de demanda (Chase, 2009). Considerando-se período sazonal de comprimento s e horizonte de previsão h , a equação de previsão do HW é escrita da seguinte maneira:

$$\hat{y}_{t+h|t} = (L_t + b_t h) I_{t-s+h} \quad (77)$$

onde

$$L_t = \alpha \frac{y_t}{I_{t-s}} + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (78)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (79)$$

$$I_t = \gamma \frac{y_t}{L_t} + (1 - \gamma)I_{t-s} \quad (80)$$

As equações (78) a (80) representam, respectivamente, os componentes da equação de previsão estimados em t : (i) nível, (ii) tendência e (iii) índices sazonais. As constantes α , β e γ são hiperparâmetros escolhidos na fase de projeto do modelo (Makridakis et al. 1998). Para a previsão múltiplos passos a frente, deve haver s índices sazonais calculados pela análise histórica da série, realizando o que se chama de correção sazonal. Em geral, os índices sazonais são normalizados (transformados) de maneira que a sua soma se iguale a s .

Há diversas variações na implementação do método HW (Chatfield & Yar, 1988). As principais diferenças ocorrem principalmente na iniciação dos componentes recursivos e na frequência de normalização dos índices sazonais (a todo instante, a cada período completo ou apenas no final do ajuste histórico). O

pacote Forecast Pro (BFS, 2010) por exemplo²², inicia valores com uma técnica inspirada no *backcasting* (Makridakis & Hibon, 1991; Box et al. 2008) e só normaliza índices sazonais ao final do ajuste histórico. Considerando-se sazonalidade mensal, i.e., $s = 12$, há exatamente 12 índices para correção sazonal.

A.2. Regressão harmônica

Considerando período sazonal de comprimento s e horizonte de previsão h , a equação de previsão da regressão harmônica (ou trigonométrica) é a seguinte:

$$\hat{y}_{t+h|t} = \beta_0 + \beta_1(t+h) + \sum_{j=1}^{\lfloor s/2 \rfloor} \beta_{1+j} \cos \lambda_j(t+h) + \beta_{\lfloor s/2 \rfloor + 1 + j} \sin \lambda_j(t+h) \quad (81)$$

onde

$$\lambda_j = \frac{2\pi \cdot j}{s} \quad (82)$$

$$\lfloor s/2 \rfloor = \begin{cases} s/2 & \text{para } s \text{ par} \\ (s-1)/2 & \text{para } s \text{ ímpar} \end{cases} \quad (83)$$

A frequência $\lambda_1 = 2\pi/s$ é a frequência fundamental da regressão, enquanto as demais frequências são as (frequências) **harmônicas** (Harvey, 1991). Os parâmetros $\beta_0, \beta_1, \beta_2, \dots, \beta_{s+1}$ são lineares e podem ser estimados com mínimos quadrados ordinários (irrestritos). Considerando-se sazonalidade mensal, i.e., $s = 12$, a equação de previsão da regressão harmônica assume a seguinte forma:

$$\hat{y}_{t+h|t} = \beta_0 + \beta_1(t+h) + \sum_{j=1}^6 \beta_{1+j} \cos \lambda_j(t+h) + \beta_{7+j} \sin \lambda_j(t+h) \quad (84)$$

onde

$$\lambda_j = \frac{\pi \cdot j}{6} \quad (85)$$

²² Segundo *e-mail* enviado por seus autores.

A.3. Decomposição clássica

Os métodos de decomposição estão entre as abordagens mais antigas para análise de séries temporais (Makridakis et al. 1998). A assunção básica é a seguinte: **série = padrão + erro**; a partir daí pode-se representar o padrão observado combinando, de forma aditiva ou multiplicativa, os elementos básicos nível, tendência e sazonalidade.

Neste trabalho, utiliza-se uma forma clássica de decomposição, em que a série observada é primeiro desazonalizada e depois submetida a um modelo de regressão simples, com nível e tendência linear (Kachigan, 1986). Uma vez ajustado, o modelo desazonalizado pode ser usado para gerar previsões múltiplos passos a frente; estas previsões devem então ter sua sazonalidade reintroduzida (corrigida), de acordo com o índice sazonal para a respectiva posição no ciclo de tempo (e.g., mês do ano). Considerando-se período sazonal de comprimento s e horizonte de previsão h , a equação (86) reproduz a equação de previsão da decomposição clássica.

$$\hat{y}_{t+h|t} = (\beta_0 + \beta_1(t+h))I_{t-s+h} \quad (86)$$

onde

I_t o índice sazonal correspondente

Considerando-se sazonalidade mensal, i.e., $s = 12$, há exatamente 12 índices a serem calculados no histórico e utilizados para correção sazonal das previsões. Há diferentes métodos para este cálculo (Makridakis et al. 1998; Kachigan, 1986); neste trabalho, os índices sazonais são calculados pelas médias, ao longo de todos os períodos completos no histórico (e.g. anos), das razões entre os quantitativos em uma posição do ciclo (e.g. mês) e a média do respectivo período (e.g. ano).

A.4. ARIMA Box & Jenkins

A metodologia ARIMA Box & Jenkins (BJ) encontra sua base na teoria dos processos estocásticos (Harvey, 1991; Souza & Camargo, 2004; Box et al. 2008).

Usando notação adaptada dos modelos de regressão, a equação de previsão dos modelo BJ assume a forma da equação (87).

$$\hat{y}_{t+h|t} = \alpha_1 \hat{y}_{t+h-1|t} + \alpha_2 \hat{y}_{t+h-2|t} + \dots + \alpha_m \hat{y}_{t+h-m|t} + \beta_1 \varepsilon_{t+h-1|t} + \beta_2 \varepsilon_{t+h-2|t} + \dots + \beta_n \varepsilon_{t+h-n|t} \quad (87)$$

onde

$$\varepsilon_{t+h|t} = (y_{t+h|t} - \hat{y}_{t+h|t}) \quad (88)$$

$$\alpha_i = f^{\text{não linear}}(\phi_1, \phi_2, \dots, \phi_p, \theta_1, \theta_2, \dots, \theta_q, \Phi_1, \Phi_2, \dots, \Phi_P, \Theta_1, \Theta_2, \dots, \Theta_Q) \quad (89)$$

$$\beta_i = f^{\text{não linear}}(\phi_1, \phi_2, \dots, \phi_p, \theta_1, \theta_2, \dots, \theta_q, \Phi_1, \Phi_2, \dots, \Phi_P, \Theta_1, \Theta_2, \dots, \Theta_Q) \quad (90)$$

O fato dos parâmetros $\alpha_1, \alpha_2, \dots, \alpha_m, \beta_1, \beta_2, \dots, \beta_n$ dependerem de maneira não linear de outros $p+q+P+Q$ parâmetros²³ torna inviável a sua estimação com métodos exatos, forçando a utilização de métodos iterativos. Ainda, o processo de otimização (não linear) dos parâmetros BJ é restrito: deve-se cuidar para que a equação do modelo especificado atenda às características de **inversibilidade** e **estacionariedade** (Souza & Camargo, 2004).

²³ A forma desta dependência varia de acordo com o modelo ARIMA especificado.

Apêndice B

Parâmetros dos previsores para DIESEL e GLP

As Tabelas 120 a 123 exibem os parâmetros estimados nos previsores individuais para vendas de DIESEL e GLP, sempre com base na notação utilizada no Apêndice A.

Tabela 120 – Parâmetros *Holt-Winters* (HW)

<i>Parâmetro</i>	<i>DIESEL</i>	<i>GLP</i>
L_{τ}	1677724	480632
b_{τ}	3262	-223.5
I_{τ}	0.9532	1.0230
$I_{\tau-1}$	1.0120	0.9724
$I_{\tau-2}$	1.1040	1.0320
$I_{\tau-3}$	1.0650	1.0190
$I_{\tau-4}$	1.0900	1.0660
$I_{\tau-5}$	1.0460	1.0730
$I_{\tau-6}$	1.0340	1.0360
$I_{\tau-7}$	1.0230	1.0280
$I_{\tau-8}$	0.9773	0.9630
$I_{\tau-9}$	0.9963	0.9822
$I_{\tau-10}$	0.8611	0.8955
$I_{\tau-11}$	0.8731	0.9269

Tabela 121 – Parâmetros da *regressão harmônica* (REG)

<i>Parâmetro</i>	<i>DIESEL</i>	<i>GLP</i>
β_0	1276500	517390
β_1	3100	-380
β_2	-115300	-24240
β_3	-47000	
β_4	-21200	-5430
β_6	1276500	10940
β_8	-66500	-19840
β_9	-27900	5890
β_{10}		6890
β_{11}		6410
β_{12}		9710

Células em branco ou omitidas indicam parâmetros *não significativos*.

Tabela 122 – Parâmetros da *decomposição clássica* (DEC)

<i>Parâmetro</i>	<i>DIESEL</i>	<i>GLP</i>
β_0	1280100	517280
β_1	3000	-380
I_{τ}	0.9613	1.0130
$I_{\tau-1}$	1.0207	0.9741
$I_{\tau-2}$	1.1101	1.0266
$I_{\tau-3}$	1.0667	1.0168
$I_{\tau-4}$	1.0985	1.0646
$I_{\tau-5}$	1.0422	1.0729
$I_{\tau-6}$	1.0258	1.0303
$I_{\tau-7}$	1.0118	1.0331
$I_{\tau-8}$	0.9619	0.9567
$I_{\tau-9}$	0.9810	0.9891
$I_{\tau-10}$	0.8533	0.8974
$I_{\tau-11}$	0.8667	0.9253

Tabela 123 – Parâmetros *Box & Jenkins* (BJ)

<i>Parâmetro</i>	<i>DIESEL</i>	<i>GLP</i>
α_1	1	0.5324
α_2		0.4607
α_{12}	1	1
α_{13}	-1	-0.5324
α_{14}		-0.4607
β_1	-0.7447	-0.6303
β_{12}	-0.8711	-0.8876
β_{13}	0.6487	0.5595

Células em branco ou omitidas indicam parâmetros *não significativos*.

Na notação tradicional dos modelos ARIMA, o previsor para DIESEL é ARIMA(1,0,1)*(0,1,1)₁₂, enquanto para GLP é ARIMA(2,0,1)*(0,1,1)₁₂.

Apêndice C

Séries da competição NN3

As Figuras 54 a 64 exibem as 11 séries utilizadas neste trabalho (NN3, 2011).




Figura 54 – Série 1




Figura 55 – Série 2




Figura 56 – Série 3




Figura 57 – Série 4




Figura 58 – Série 5




Figura 59 – Série 6




Figura 60 – Série 7




Figura 61 – Série 8




Figura 62 – Série 9




Figura 63 – Série 10




Figura 64 – Série 11