



Rafael de Olivaes Valle dos Santos

Ponderação Neural de Experts

Tese de Doutorado

Tese apresentada ao Programa de Pós-graduação em Engenharia Elétrica da PUC-Rio como requisito parcial para obtenção do título de Doutor em Engenharia Elétrica.

Orientadora: Marley Maria Bernardes Rebuszi Vellasco



Rafael de Olivaes Valle dos Santos

Ponderação Neural de Experts

Tese apresentada como requisito parcial para obtenção do grau de Doutor pelo Programa de Pós-Graduação em Engenharia Elétrica do Departamento de Engenharia Elétrica do Centro Técnico Científico da PUC-Rio. Aprovada pela Comissão Examinadora abaixo assinada.

Prof^a. Marley Maria Bernardes Rebuzzi Vellasco
Orientadora
Departamento de Engenharia Elétrica - PUC-Rio

Prof. Ricardo Bastos Cavalcante Prudêncio
UFPE

Prof. Ricardo de Melo e Silva Accioly
UERJ

Prof. Reinaldo Castro Souza
Departamento de Engenharia Elétrica - PUC-Rio

Prof^a. Karla Tereza Figueiredo Leite
UEZO

Prof^a. Luciana Conceição Dias Campos
UFJF

Prof. José Eugenio Leal
Coordenador Setorial do Centro Técnico Científico - PUC-Rio

Rio de Janeiro, 19 de abril de 2012

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, do autor e da orientadora.

Rafael de Olivaes Valle dos Santos

Graduou-se em Engenharia de Computação pela PUC-Rio em 1999. Obteve o título de Mestre em Engenharia Elétrica com ênfase em Métodos de Apoio à Decisão pela mesma universidade em 2001. Trabalhou como Engenheiro de Pesquisa na PUC-Rio entre 2001 e 2003 e desde 2004 é funcionário da Petrobras, atuando no setor de Pesquisa Operacional.

Ficha Catalográfica

Valle dos Santos, Rafael de Olivaes

Ponderação Neural de Experts / Rafael de Olivaes Valle dos Santos; orientador: Marley Maria Bernardes Rebuszi Vellasco. – 2012.

181 f. il. (color.) ; 30 cm

Tese (doutorado) – Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Elétrica, 2012.

Inclui referências bibliográficas.

Combinação de previsores/previsões; redes neurais; séries temporais; previsão múltiplos passos a frente.

CDD: 621.3

Agradecimentos

À prof^a. Marley Vellasco, por ter acreditado neste trabalho. Sem o seu suporte e contribuição, ele não aconteceria.

À PUC-Rio, pelos auxílios concedidos, sem os quais esta pesquisa não poderia ter sido realizada.

Aos profs. Reinaldo Castro Souza e Mônica Barros, meus mentores na ciência estatística.

A todos os membros da Comissão Examinadora, em particular aos profs. Ricardo Prudêncio e Ricardo Accioly, pelas sugestões à época em que esta tese ainda era uma proposta.

Aos meus pais, Helio e Margaret, grandes responsáveis por eu estar aqui, a quem devo tudo.

À minha esposa Maria Celina, pelo amor e por todas as contribuições que estiveram ao seu alcance. Te amo.

Aos meus sogros Antônio e Carolina, por todo o apoio prestado, principalmente no início do curso.

Às pessoas que estão (e estarão) sempre comigo: Fernanda, Gustavo, Henrique, Luisa, Sérgio, Roberto, Marisa, Fabiana, Juliana, Thiago, Gabriela e Fábio.

Aos funcionários do Departamento de Engenharia Elétrica da PUC-Rio, aos meus colegas da Petrobras e a todos aqueles que de uma forma ou de outra contribuíram para realização deste projeto.

Resumo

Valle dos Santos, Rafael de Olivaes; Vellasco, Marley Maria Bernardes Rebutzi (Orientadora). **Ponderação Neural de Experts**. Rio de Janeiro, 2012. 181p. Tese de Doutorado – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

Diversos resultados empíricos na área de séries temporais indicam que combinar previsores (*experts*) é, em média, melhor que tentar selecionar um único modelo de previsão. Na medida em que se decide por um esquema de combinação linear, há vários métodos disponíveis para determinar o quanto cada previsor deve contribuir para a resposta consensual, ou em outras palavras, quais devem ser os pesos dos previsores envolvidos. Em um primeiro momento, este trabalho explora o uso prático de diversos métodos tradicionais de ponderação para combinação linear de previsores. Em seguida, propõe um novo sistema para geração de pesos, especialmente projetado para a melhoria do desempenho nas previsões múltiplos passos a frente. O sistema, batizado de Ponderação Neural de Experts (NEW – *Neural Expert Weighting*), gera modelos de ponderação dinâmica baseados em redes neurais. As redes neurais oferecem a robustez necessária para a simulação de funções de ponderação de alto desempenho, derivadas de um ou mais métodos tradicionais de geração de pesos. O sistema NEW foi avaliado em diversos experimentos comparativos, contemplando 13 séries temporais divididas em dois estudos de casos – derivados do petróleo e competição NN3, uma competição entre metodologias de previsão baseadas em inteligência computacional. Os resultados obtidos foram considerados promissores.

Palavras-chave

Combinação de previsores/previsões; redes neurais; séries temporais; previsão múltiplos passos a frente.

Abstract

Valle dos Santos, Rafael de Oliveira; Vellasco, Marley Maria Bernardes Rebutzi (Advisor). **Neural Expert Weighting**. Rio de Janeiro, 2012. 181p. DSc Thesis – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

Several empirical results on the time series field indicate that combining forecasting models (*experts*) is, on average, better than selecting a single forecasting model. Once the linear combination framework is chosen, there are many ways to define the amount of contribution of each combining model to the consensual response; in other words, there are many possible weighting methods. At first, the present work explores the usage of traditional weight generation schemes for the linear combination of forecasters. Afterwards, it proposes a new weight generation framework, specially designed to improve multistep ahead forecasting. The framework, called Neural Experts Weighting (NEW), generates dynamic weighting models based on neural networks. The neural networks provide the desired robustness for the simulation of high performance weighting functions, derived from one or more traditional weighting methods. The NEW framework was assessed with several comparative experiments, encompassing 13 time series divided into two case studies – downstream and NN3 competition, a forecasting competition for computational intelligence methodologies. Results were considered to be promising.

Keywords

Forecast/forecasting combination; neural networks; time series; multistep ahead forecasting.

Sumário

1	Introdução	13
1.1.	Contexto	13
1.2.	Sistemas multi-previsores: seleção versus combinação	14
1.3.	Combinação de previsores	15
1.4.	Motivação	16
1.5.	Objetivo	17
1.6.	Descrição do trabalho e contribuição	18
1.7.	Notação básica	19
1.8.	Organização da tese	20
2	Sistemas multi-previsores	21
2.1.	Introdução	21
2.2.	Taxonomia	22
2.2.1.	Combinação modular	23
2.2.2.	Combinação por comitê (<i>ensembles</i>)	24
2.3.	Modelos de comitê	24
2.3.1.	Linear	24
2.3.2.	Não linear	26
2.3.3.	Outros	26
2.4.	Métodos tradicionais para estimação de pesos lineares	29
2.4.1.	Média simples	29
2.4.2.	Mínimos quadrados irrestritos	30
2.4.3.	Mínimos quadrados restritos	31
2.4.4.	Bates & Granger simples (BG1)	33
2.4.5.	Bates & Granger correlacionado (BG2)	33
2.4.6.	AFTER	35
2.4.7.	Shrinkage	36
3	Ponderação Neural de Experts (NEW)	38
3.1.	Fundamentos	38

3.2. Formulação básica	40
3.3. Séries de referência	46
3.4. Pesos históricos	48
3.5. Conjuntos de treinamento	50
3.6. Pré-processamento	56
3.6.1. Normalização padrão	57
3.6.2. Normalização soma-1	57
3.7. Pós-processamento	59
3.8. Redes neurais	60
3.9. Política de treinamento	63
4 Estudo de casos	66
4.1. Introdução	66
4.2. Previsores disponíveis (<i>experts</i>)	66
4.3. Metodologia de avaliação dos resultados	67
4.3.1. Métricas de desempenho	67
4.3.2. Testes de hipótese	68
4.4. CASO 1: Derivados do petróleo	68
4.4.1. Previsores individuais	70
4.4.2. Combinações tradicionais	73
4.4.2.1. Experimentos	73
4.4.2.2. Análise individual	77
4.4.3. Combinações limiaries	83
4.4.3.1. Experimentos	83
4.4.3.2. Análise individual	88
4.4.4. Combinações NEW	94
4.4.4.1. Experimentos	94
4.4.4.2. Análise individual	101
4.4.5. Análise comparativa	108
4.4.5.1. Comparação dirigida	108
4.4.5.2. Comparação livre	114
4.4.5.3. Tempo de processamento	119
4.4.5.4. Resumo	121

4.5. CASO 2: Competição NN3	121
4.5.1. Previsores individuais	123
4.5.2. Combinações tradicionais	126
4.5.2.1. Experimentos	126
4.5.2.2. Análise individual	128
4.5.3. Combinações limiares	131
4.5.3.1. Experimentos	131
4.5.3.2. Análise individual	133
4.5.4. Combinações NEW	137
4.5.4.1. Experimentos	137
4.5.4.2. Análise individual	142
4.5.5. Análise comparativa	146
4.5.5.1. Comparação dirigida	146
4.5.5.2. Comparação livre	152
4.5.5.3. Tempo de processamento	157
4.5.5.4. Resumo	157
4.5.6. Resultados da competição	158
5 Considerações finais	160
Referências	164
Apêndice A Metodologias de previsão	171
A.1. Holt-Winters multiplicativo	171
A.2. Regressão harmônica	172
A.3. Decomposição clássica	173
A.4. ARIMA Box & Jenkins	173
Apêndice B Parâmetros dos previsores para DIESEL e GLP	175
Apêndice C Séries da competição NN3	178

Lista de símbolos e abreviações

AFTER	Aggregated Forecast Through Exponential Re-weighting
ANP	Agência Nacional do Petróleo, Gás Natural e Biocombustíveis
ARIMA	Autoregressive Integrated Moving Average
AVG	Média simples
BG1	Bates & Granger simples
BG2	Bates & Granger correlacionado
BJ	Box & Jenkins
BJ-	Previsor limiar BJ inferior
BJ+	Previsor limiar BJ superior
DEC	Decomposição clássica
DEC-	Previsor limiar DEC inferior
DEC+	Previsor limiar DEC superior
DIESEL	Vendas de óleo diesel
GLP	Vendas de gás liquefeito de petróleo
HW	Holt-Winters
HW-	Previsor limiar HW inferior
HW+	Previsor limiar HW superior
Limiar1	Experimento limiar com 2 previsores
Limiar2	Experimento limiar com 4 previsores
MAD	Mean Absolute Deviation
MLP	Multilayer Perceptron
MQI	Mínimos Quadrados Irrestritos
MQR	Mínimos Quadrados Restritos
MSE	Mean Squared Error
NEW	Neural Expert Weighting
NEW1	Experimento NEW com 2 previsores
NEW2	Experimento NEW com 4 previsores
NN3	Competição NN3
POOL	Pool de métodos tradicionais de ponderação
RAE	Relative Absolute Error

REG	Regressão harmônica
REG-	Previsor limiar REG inferior
REG+	Previsor limiar REG superior
SAFTER	AFTER com shrinkage
SALY	Same As Last Year
SALY1	SALY sem sazonalidade
SALY2	SALY com sazonalidade recente
SALY3	SALY com sazonalidade média
SBG1	BG1 com shrinkage
SBG2	BG2 com shrinkage
SMAPE	Symmetric Mean Absolute Percentage Error
SMQI	MQI com shrinkage
SMQR	MQR com shrinkage
<i>srh0</i>	Saldo de rejeição da hipótese nula
<i>srh0+</i>	<i>srh0</i> acumulado
UTHEIL	Coeficiente UTHEIL

*No fim tudo dá certo.
Se não deu certo, é porque ainda não chegou ao fim.*

Fernando Sabino