

Centro de Pesquisas de Energia Elétrica - CEPEL

Relatório Técnico



Nº/Ano: 11627/2018	Nº de Páginas: 69	Nº de Anexos: 1
---------------------------	--------------------------	------------------------

Título: Modelo de Previsão de Carga para o Plano Mensal da Operação PrevCargaPMO

Departamento: Departamento de Otimização Energética e Meio Ambiente - DEA
--

Área de Responsabilidade: B200	Conta de Apropriação: 1600
---------------------------------------	-----------------------------------

Cliente: OPERADOR NACIONAL DO SISTEMA ELÉTRICO - ONS Rua Júlio do Carmo, 251 - Cidade Nova Rio de Janeiro - RJ, CEP: 20211-160 Atenção: Maria Helena Teles de Azevedo
--


Resumo: Manual de metodologia, instalação e operação do programa de previsão de carga para o Plano Mensal da Operação, PrevCargaPMO e relatório de desempenho.
--

Autores: José Francisco Moreira Pessanha - Cepel Victor Andrade de Almeida - Cepel

Palavras-Chave: Previsão de carga Plano Mensal da Operação Máquinas de vetores de suporte Classificação: CONTROLADO

Gerente de Projeto  José Francisco Moreira Pessanha Tel.: 2598-6066 E-mail: francisc@cepel.br

Chefe do Departamento de Otimização Energética e  André Luiz Diniz Souto Lima Tel.: 2598-6046 E-mail: diniz@cepel.br
--

Aprovação  Raul Balbi Sollero Diretor de Pesquisa, Desenvolvimento e Inovação 27/12/2018

CEPEL

Centro de Pesquisas de Energia Elétrica

MANUAL DO MODELO DE PREVISÃO DE CARGA GLOBAL PARA O PMO

- PrevCargaPMO -

2018

ÍNDICE:

1	Introdução	6
2	Máquinas de Vetor de Suporte (Support Vector Machines – SVM).....	8
2.1	Introdução	8
2.2	Máquinas de Vetor de Suporte para problemas de classificação.....	8
2.2.1	Caso linearmente separável	9
2.2.2	Caso não linearmente separável.....	11
2.2.3	Classificadores de margem flexível	12
2.3	Máquinas de Vetor de Suporte para regressão	15
2.4	Validação Cruzada	16
3	Modelagem da previsão de carga no PrevCargaPMO	18
3.1	Introdução	18
3.2	Metodologia de tratamento de dados	18
3.2.1	Tratamento dos dados de temperatura	18
3.2.2	Tratamento dos dados da parcela supervisionada da carga.....	19
3.2.2.1	Identificação dos perfis diários típicos.....	19
3.2.2.2	Identificação do perfil diário para dias sem dados de carga.....	19
3.2.2.3	Estimativa da demanda média diária para os dias sem dados de carga verificados	20
3.2.2.4	Correção de valores discrepantes	20
3.2.3	Tratamento dos dados da geração não supervisionada	21
3.3	Modelos de Previsão.....	21
3.3.1	Modelo 1 - Modelo para previsão da carga média diária (parcela supervisionada).....	21
3.3.2	Modelo 2 - Modelo para previsão da média diária da geração não supervisionada.....	22
3.3.3	Modelos 3 e 4 – Modelo para previsão da carga média semanal (carga global)	22
3.3.4	Modelo 5 – Modelo para previsão da carga média mensal (carga global).....	24
3.4	Compatibilização das previsões no caso da REV0.....	24
3.4.1	Coordenação das previsões no caso da REV0	24
3.4.2	Compatibilização das previsões no caso das revisões semanais	26
4	Programa PrevCargaPMO	28
4.1	Instalação.....	28
4.2	Entrada de Dados.....	28

4.3	Execução.....	33
4.4	Resultados gerados pelo Modelo.....	36
	Referências bibliográficas	42
	Apêndice A – Relatório de Desempenho.....	45
	A1. Resultados para o subsistema Norte	46
	A1.1 Resultados para REV0	46
	A1.2 Resultados para demais revisões semanais.....	50
	A2. Resultados para o submercado Nordeste	52
	A2.1 Resultados para REV0	52
	A2.2 Resultados para demais revisões semanais.....	55
	A3. Resultados para o submercado Sul.....	58
	A3.1 Resultados para REV0	58
	A3.2 Resultados para demais revisões semanais.....	61
	A4. Resultados para o submercado Sudeste.....	64
	A4.1 Resultados para REV0	64
	A4.2 Resultados para demais revisões semanais.....	67
	A5. Conclusões	70

1 Introdução

As previsões de carga média até dois meses à frente, com resolução temporal semanal (semana operativa¹) para o primeiro mês, são informações fundamentais para o Plano Mensal de Operação (PMO) realizado pelo Operador Nacional do Sistema (ONS). As previsões semanais são atualizadas semanalmente com base nos registros mais recentes da carga e o ONS tem empreendido esforços no sentido de agilizar o processamento das previsões e promover maior transparência da formulação das previsões aos agentes. Ciente deste desafio o ONS e o CEPEL desenvolveram o PrevCargaPMO, um programa computacional em ambiente R (R CORE TEAM, 2017) para previsão de carga média que atenda às necessidades do PMO, cabendo ao CEPEL a formulação metodológica de previsão.

A previsão de carga constitui uma área de intensa pesquisa e conta com uma vasta literatura técnica (GROSS & GALIANA, 1987; LOTUFO & MINUSSI, 1999; HAHN et al, 2009) contendo uma variedade de métodos. Tal fato reflete a busca dos operadores de redes elétricas por métodos capazes de gerar previsões mais precisas e que permitam fazer um melhor uso dos recursos disponíveis e, portanto, contribuam para a otimização da operação do sistema elétrico (FORTUNATO et al, 1990).

A opção pela implementação computacional em ambiente R foi motivada pelo grande número de funções (pacotes), gratuitamente disponibilizadas, nas quais podem ser encontrados diversos métodos estatísticos e de aprendizagem de Máquina (*machine learning*) para pronta aplicação na previsão de carga.

Embora não exista um consenso acerca da superioridade de um determinado método de previsão de carga em particular, ressalta-se a grande quantidade de publicações que ilustram a aplicação de métodos de aprendizagem de Máquina na previsão de carga horária e mensal, entre os quais se destacam as redes neurais artificiais (ZHANG et al, 1998; KODOGIANNIS & ANAGNOSTAKIS, 1999; HIPPERT et al, 2001; PARK et al, 2017), as Máquinas de Vetor de Suporte (*Support Vector Machine – SVM*) (XU et al, 2005; NIU & WANG, 2007; WANG et al, 2007; HONG, 2009; BOZIC & STOJONAVIC, 2011; TURKAY et al, 2011; CEPERIC et al, 2013, BAGHEL et al, 2016) e a lógica fuzzy (MASTOROCOSTAS et al, 1999; LIAO & TSAO, 2004; PESSANHA & JUSTINO, 2014). Entre os três métodos citados, o SVM é o mais recente, inclusive conquistando premiações em competições internacionais² em previsão de carga (CHEN et al, 2004).

Proposto por Vapnik (1992), o algoritmo denominado Máquinas de Vetor de Suporte (SVM) pode ser usado tanto em problemas de classificação de padrões quanto em problemas de regressão. A ideia de um SVM é produzir um hiperplano como superfície de decisão de forma que a margem de separação entre as classes do problema seja máxima, por esta razão o SVM pode ser entendido como uma espécie de rede neural artificial (DOMINGOS, 2015). As considerações acima, acompanhadas de análises comparativas entre diversos métodos de previsão disponibilizados no ambiente R, apontaram para a escolha do SVM como um bom método para iniciar o desenvolvimento do PrevCargaPMO.

O presente relatório técnico tem por objetivo descrever a metodologia de previsão de carga adotada no PrevCargaPMO e fornecer instruções básicas para sua utilização. O PrevCargaPMO fornece previsões semanais da carga média global para até seis semanas à frente e previsões mensais da carga média global até dois meses à frente por subsistema. Adicionalmente, o programa fornece previsões das médias diárias da carga global para os dias que completam a semana operativa corrente.

Conforme ilustrado na Figura 1, o modelo de previsão é alimentado com dados das parcelas que compõem a carga global: geração supervisionada em base horária, intercâmbio (dados horários) e geração não supervisionada (dados horários e diários), além de dados de temperatura horária, datas de início e fim do horário de verão e a lista de feriados e dias especiais elencados na Tabela 1. Ainda na Figura 1, observa-se que todos os modelos de previsão são precedidos por uma etapa de tratamento de dados com a finalidade de corrigir eventuais lacunas de dados e valores discrepantes. A montagem da série histórica da carga global em bases semanal e mensal é realizada internamente pelo PrevCargaPMO ($Carga\ Global_{por\ Subsistema} = \text{geração supervisionada} - \text{intercâmbio} + \text{geração não supervisionada}$). Na sequência por meio do algoritmo de Máquinas de Vetor de Suporte são geradas as previsões. Ao final, o modelo faz a compatibilização das previsões semanais com a previsão mensal para o primeiro mês.

¹A semana operativa tem duração de 7 dias e inicia-se sempre no sábado

²<http://neuron.tuke.sk/competition/index.php>

Todas as etapas do modelo de previsão são descritas ao longo deste relatório, bem como são apresentadas instruções para execução do modelo e visualização dos resultados.

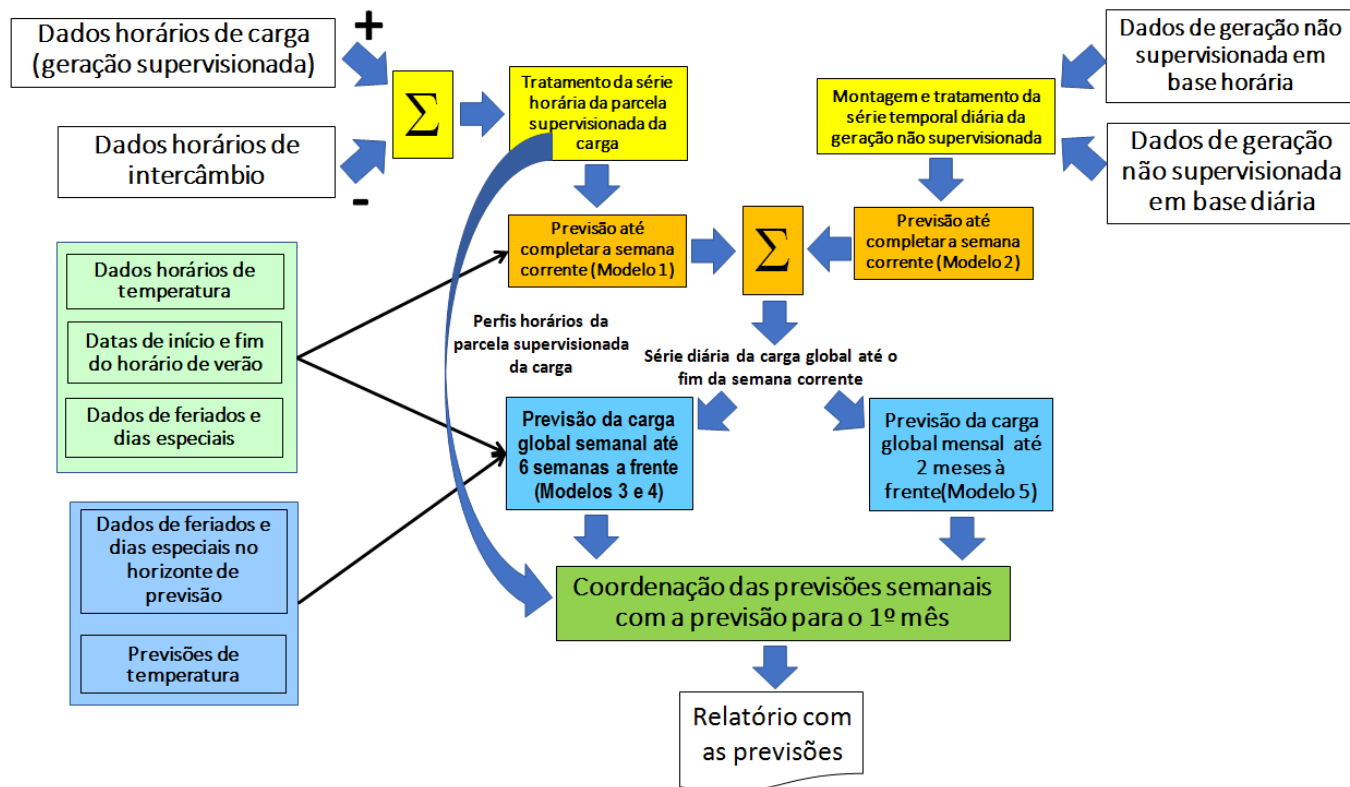


Figura 1 - Estrutura do modelo de previsão

Tabela 1 - Codificação de feriados e dias especiais

Tipo do dia	Código
Feriado Nacional perfil de sábado	1
Feriado Nacional perfil de domingo	2
Segunda-feira da semana do Carnaval	3
Terça-feira da semana do Carnaval	4
Quarta-feira de cinzas	5
Natal e 1º de Janeiro	6
Dia após Natal ou após 1º de Janeiro	7
Véspera de Natal ou véspera 1º de Janeiro	8
Véspera de feriado	9
Dia após feriado	10
Dia especial e recesso	11
Blecaute, Jogos da Copa, etc.	12

No Apêndice A, se encontra o Relatório de Desempenho que resume as avaliações e análises dos resultados obtidos com a última versão do modelo PrevCargaPMO (versão 1.34). A avaliação de desempenho do PrevCargaPMO demandou um grande esforço computacional por requerer a execução e análise de um expressivo número de casos.

2 Máquinas de Vetor de Suporte (Support Vector Machines – SVM)

2.1 Introdução

Inicialmente propostas para resolver problemas de classificação supervisionada, as Máquina de Vetor de Suporte (SVM) foram adaptadas e passaram a ser utilizadas também em problemas de regressão. A ampliação do escopo de aplicação tornou a SVM uma das principais técnicas do *machine learning*. O presente capítulo tem por objetivo descrever as Máquinas de Vetor de Suporte para regressão, mas seguindo o desenvolvimento histórico da SVM e visando facilitar o entendimento dos conceitos fundamentais inicia-se o capítulo com a descrição da abordagem SVM para problemas de classificação.

2.2 Máquinas de Vetor de Suporte para problemas de classificação

Considere um conjunto de observações classificadas em duas categorias, por exemplo, uma amostra de alunos classificados entre reprovados e aprovados, sendo que para cada aluno são conhecidas as notas em matemática (x_1) e português (x_2). A seguir, na

Figura 2 tem-se uma representação gráfica desta situação, onde os alunos reprovados e aprovados são representados por quadrados e círculos respectivamente.




Figura 2 – Dados linearmente separáveis

As observações representadas na

Figura 2 formam um conjunto de dados linearmente separável, pois neste caso é possível identificar uma reta que separe os quadrados e círculos em lados opostos. Todas as retas ilustradas na

Figura 2 separam perfeitamente os alunos da amostra, contudo não há garantias do mesmo desempenho excepcional na classificação de novas observações. Por exemplo, considere as retas C1 e C2 ilustradas na Figura , ambas oferecem uma separação perfeita das observações, i.e., sem erros de classificação.

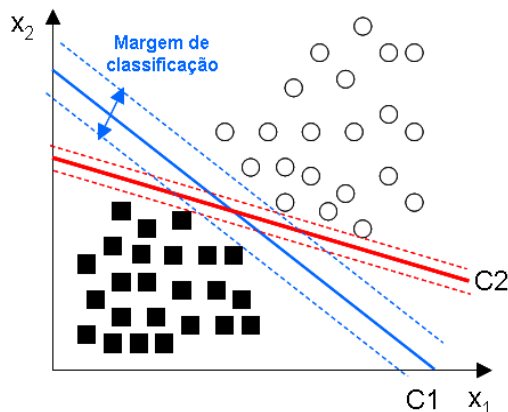


Figura 3 – Margem de classificação

Cada reta ilustrada na Figura é acompanhada de retas paralelas (linhas tracejadas) denominadas hiperplanos de Suporte. Partindo de uma das retas C1 ou C2 toma-se sua paralela até encontrar um quadrado e outra paralela até encontrar um círculo. A distância entre as duas paralelas (entre os dois hiperplanos de Suporte) é conhecida como margem de classificação. Intuitivamente, margens estreitas estão mais suscetíveis aos erros de classificação, pois qualquer perturbação na reta discriminante pode implicar em erros de classificação. Por outro lado, margens largas são menos sensíveis às perturbações. Portanto, o melhor classificador é aquele que tem a maior margem de classificação.

2.2.1 Caso linearmente separável

Considere o Vetor x como sendo o Vetor formado pelos atributos das observações (neste caso as notas em matemática e português) e o Vetor y como sendo o Vetor que representa o status do aluno assumindo valor +1 para os aprovados (círculos) e -1 para os reprovados (quadrados). A equação de uma reta (no caso multidimensional tem-se um hiperplano) que realiza a separação entre as classes é dada por $wx + b = 0$, em que w é um Vetor de pesos ajustáveis e ortogonal à reta discriminante (normal ao hiperplano) e b é um *bias*. Assim, pode-se escrever a seguinte regra de classificação (HAMEL, 2009):

$$y = \begin{cases} 1 & \text{se } wx + b > 0 \\ -1 & \text{se } wx + b < 0 \end{cases}$$

As retas (hiperplanos) paralelas a reta discriminante são descritas pelas seguintes equações:

$$wx_1 + b = 1 \tag{1}$$

$$wx_2 + b = -1 \tag{2}$$

Logo $w(x_1 - x_2) = 2$, onde $x_1 - x_2$ é a margem de classificação denotada por d :

$$d = 2 / \|w\| \tag{3}$$

Dada uma amostra contendo N observações, os parâmetros w e b devem ser ajustados de forma a maximizar a margem de classificação e atender as seguintes restrições:

$$wx + b \geq 1 \text{ se } y = 1 \tag{4}$$

$$wx + b \leq -1 \text{ se } y = -1 \tag{5}$$

As desigualdades em (4) e (5) podem ser resumidas em apenas uma inequação, conforme a seguir:

$$y_i(wx_i + b) \geq 1 \quad \forall i = 1, N \tag{6}$$

Assim, w e b devem ser determinados por meio do seguinte problema de otimização (HAMEL, 2009):

$$\begin{aligned} \text{Min}_{w,b} \quad & \frac{1}{2} \|w\|^2 \\ \text{s.a.} \quad & y_i(wx_i + b) \geq 1 \quad \forall i = 1, N \end{aligned} \tag{7}$$

A função objetivo é quadrática e as restrições são lineares, portanto trata-se de um problema de otimização convexo, cuja solução pode ser obtida por meio da otimização da função Lagrangeana L , cuja solução ótima coincide com a solução ótima do problema original (HAMEL, 2009):

$$L = \frac{1}{2} \|w\|^2 - \sum_{i=1}^N \lambda_i [y_i(wx_i + b) - 1] \tag{8}$$

em que $\lambda_i \geq 0 \quad \forall i = 1, N$ denota os multiplicadores de Lagrange.

Assim, o problema de programação matemática em (7) pode ser escrito da seguinte maneira:

$$\underset{\lambda}{Max} \quad \underset{w,b}{Min} \quad \frac{1}{2} \|w\|^2 - \sum_{i=1}^N \lambda_i [y_i (wx_i + b) - 1] \quad (9)$$

O multiplicador de Lagrange assume valor positivo nas observações que satisfazem a equação $y_i(wx_i + b) = 1$, ou seja, nas observações sobre os hiperplanos de Suporte, e nulo nas demais observações. A solução ótima da função Lagrangeana deve atender as seguintes condições de otimalidade (KKT) (HAMEL, 2009):

$$\frac{\partial L}{\partial w} = w - \sum_{i=1}^N \lambda_i y_i x_i = 0 \quad (10)$$

$$\frac{\partial L}{\partial b} = \sum_{i=1}^N \lambda_i y_i = 0 \quad (11)$$

$$\lambda_i [y_i (wx_i + b) - 1] = 0 \quad (12)$$

$$[y_i (wx_i + b) - 1] \geq 0 \quad (13)$$

$$\lambda_i \geq 0 \quad (14)$$

Da primeira condição em (10) tem-se que

$$w = \sum_{i=1}^N \lambda_i y_i x_i \quad (15)$$

Dado que $\sum_{i=1}^N \lambda_i y_i = 0$ e substituindo w na equação (9) obtém-se o dual da função Lagrangeana:

$$L = \sum_{i=1}^N \lambda_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \lambda_i \lambda_j y_i y_j x_i x_j \quad (16)$$

Assim, o dual do problema é dado por (HAMEL, 2009):

$$\underset{\lambda}{Max} \quad \sum_{i=1}^N \lambda_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \lambda_i \lambda_j y_i y_j x_i x_j$$

s.a.

$$\sum_{i=1}^N \lambda_i y_i = 0$$

$$\lambda_i \geq 0 \quad (17)$$

Dada a solução ótima é interessante observar os valores de λ_i , $i=1, N$, pois tais valores informam quais são os Vetores de Suporte (*support vectors*), i.e., as observações localizadas nos hiperplanos de Suporte ($\lambda_i > 0$) e que contribuem para a margem de classificação. Os valores nulos λ_i correspondem às observações que não contribuem para a margem de classificação.

A comparação entre os problemas primal (7) e dual (17) mostra que o primeiro determina os hiperplanos de Suporte (w e b) cujas margens são limitadas pelos Vetores de Suporte, enquanto o segundo identifica os Vetores de Suporte

que limitam o tamanho das margens dos hiperplanos de Suporte. A partir da solução ótima do problema dual (λ^*) pode-se determinar a solução ótima do modelo primal (w^* e b^*) por meio das seguintes relações (HAMEL, 2009):

$$w^* = \sum_{i=1}^N \lambda_i^* y_i x_i \tag{18}$$

$$b^* = w^* x_{sv} - 1 = \sum_{i=1}^N \lambda_i^* y_i x_i x_{sv} - 1 \tag{19}$$

A solução do problema de otimização dual pode ser obtida por diferentes implementações computacionais, por exemplo, pelo método do gradiente ascendente (*kernel-adatron algorithm*), métodos empregados na resolução de problemas de programação quadrática e o *sequential minimal optimization* (SMO), a técnica padrão adotada na resolução do problema dual associado ao SVM (HAMEL, 2009).

2.2.2 Caso não linearmente separável

A estrutura básica do SVM, apresentada até aqui para o caso de dados linearmente separáveis, pode ser estendida para o caso geral com dados não linearmente separáveis. A adaptação do SVM fundamenta-se na transformação do espaço das variáveis de entrada em outro espaço de maior dimensão e linearmente separável denominado espaço de atributos (*feature space*) de forma que hiperplanos podem ser utilizados na classificação do espaço transformado. A transformação é realizada por meio de uma função não linear $\Phi(x)$ ($\Phi: R^n \rightarrow R^m, m \geq n$) denominada função núcleo (*kernel function*) que mapeia o espaço original no *feature space*. Assim, o problema primal pode ser escrito como (HAMEL, 2009):

$$\begin{aligned} \text{Min}_{w,b} \quad & \frac{1}{2} \|w\|^2 \\ \text{s.a.} \quad & y_i (w\Phi(x_i) + b) \geq 1 \quad \forall i = 1, N \end{aligned} \tag{20}$$

A função Lagrangeana correspondente ao problema primal é:

$$L = \sum_{i=1}^N \lambda_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \lambda_i \lambda_j y_i y_j \Phi(x_i) \Phi(x_j) \tag{21}$$

O cálculo do produto $\Phi(x_i)\Phi(x_j)$ pode demandar esforço computacional e uma forma de reduzi-lo consiste em considerar uma função de núcleo $K(x_i, x_j) = \Phi(x_i)\Phi(x_j)$, conforme estabelecido pelo Teorema de Mercer. A substituição do produto $\Phi(x_i)\Phi(x_j)$ pela função de núcleo correspondente permite mapear o espaço de atributos sem a necessidade de conhecer a função $\Phi(x)$ e permite calcular o produto $\Phi(x_i)\Phi(x_j)$ no espaço original, tal procedimento é conhecido como o truque do núcleo (*trick kernel*). A seguir, na Tabela 2 são apresentados alguns exemplos de função de núcleo (HAMEL, 2009).

Tabela 2. *Kernel functions*

Nome	Função de núcleo	Parâmetros
Linear	$K(z, w) = z \bullet w$	Nenhum
Polinomial homogênea	$K(z, w) = (z \bullet w)^d$	$d \geq 2$
Polinomial não homogênea	$K(z, w) = (z \bullet w + c)^d$	$d \geq 2, c > 0$
Radial	$K(z, w) = \exp[- z + w ^2 / 2\sigma^2]$	$\sigma > 0$

Assim, a função Lagrangeana pode escrita como:

$$L = \sum_{i=1}^N \lambda_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \lambda_i \lambda_j y_i y_j K(x_i, x_j) \tag{22}$$

Assim, tem-se o seguinte problema dual (HAMEL, 2009):

$$\begin{aligned} \text{Max}_{\lambda} \quad & \sum_{i=1}^N \lambda_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \lambda_i \lambda_j y_i y_j K(x_i, x_j) \\ \text{s.a.} \quad & \sum_{i=1}^N \lambda_i y_i = 0 \\ & \lambda_i \geq 0 \end{aligned} \tag{23}$$

Denotando a solução ótima do dual por α^* , o hiperplano de Suporte é determinado pelas seguintes relações (HAMEL, 2009):

$$w^* = \sum_{i=1}^N \lambda_i^* y_i \Phi(x_i) \tag{24}$$

$$b^* = w^* \Phi(x_{sv}) - 1 = \sum_{i=1}^N \lambda_i^* y_i \Phi(x_i) \Phi(x_{sv}) - 1 = \sum_{i=1}^N \lambda_i^* y_i K(x_i, x_{sv}) - 1 \tag{25}$$

2.2.3 Classificadores de margem flexível

Conhecidos como *soft-margins classifiers*, tais classificadores devem-se ao fato de que em situações mais gerais as observações não são perfeitamente separáveis, em função de ruídos ou erros nos dados. Para ilustrar o efeito dos ruídos e dos erros nos dados sobre o limite de decisão, considere o exemplo ilustrado na Figura 4, onde os pontos P e Q são ruídos. Neste caso, o algoritmo SVM apresentado nas seções anteriores contrói um hiperplano discriminante que separa perfeitamente as observações, contudo este não é o melhor hiperplano de separação, dado que a margem de classificação é estreita e, portanto, o classificador tem pequena capacidade de generalização. Neste caso é preferível adotar um classificador alternativo, mesmo que classifique erroneamente as observações P e Q, pois possui maior margem de classificação e, portanto, maior capacidade de generalização.




Figura 4 – Margem de classificação e ruídos

Os algoritmos apresentados anteriormente (*hard-margins classifiers*) tentam construir hiperplanos que separem perfeitamente as observações, contudo isto nem sempre é possível e desejável, em função da menor capacidade de generalização, conforme as considerações acima. Para lidar com a presença de ruídos e erros nas observações

deve-se modificar o algoritmo SVM permitindo que este trabalhe com uma margem de erro tolerável. Em função dos ruídos e erros nas observações, as restrições $wx+b \geq 1$ (se $y = 1$) e $wx+b \leq -1$ (se $y = -1$) não são satisfeitas em todas as observações. Para restabelecer a viabilidade do problema de otimização, uma variável de folga $\xi \geq 0$ deve ser adicionada em cada restrição, conforme ilustrado a seguir:

$$wx + b \geq 1 - \xi, \text{ se } y = 1 \quad (26)$$

$$wx + b \leq -1 + \xi, \text{ se } y = -1 \quad (27)$$

As duas restrições acima podem ser sintetizadas em uma única restrição, conforme a seguir:

$$y_i(wx_i + b) + \xi_i \geq 1 \quad \forall i = 1, \quad (28)$$

As variáveis de folga estão associadas aos erros de classificação, assim, visando minimizá-los, o problema de otimização primal deve ser modificado conforme indicado a seguir (HAMEL, 2009):

$$\begin{aligned} \text{Min}_{w,b} \quad & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i \\ \text{s.a.} \quad & y_i(wx_i + b) + \xi_i \geq 1 \quad \forall i = 1, N \\ & \xi_i \geq 0 \end{aligned} \quad (29)$$

No problema de otimização acima, o coeficiente C é definido a priori (C é um hiperparâmetro) com a finalidade de atribuir um grau de penalidade aos erros de classificação e desta forma busca-se uma solução de equilíbrio entre a largura da margem e a soma dos erros de classificação. A ausência desta parcela favorece a construção de classificadores com margens muito largas, porém com muitos erros de classificação em função dos ruídos nos dados. O balanceamento entre a largura da margem de classificação e a soma dos erros é controlado por meio da constante $C > 0$, cujo valor pode ser escolhido com base no desempenho do classificador em um conjunto de validação, ou seja, em um conjunto de dados não utilizados no ajuste do modelo. A largura da margem e a constante C variam em sentidos opostos, pois, um valor grande para C implica na redução da margem de classificação, enquanto um valor pequeno implica em um margem larga. A função Lagrangeana correspondente ao modelo acima é apresenta a seguir:

$$L = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i - \sum_{i=1}^N \lambda_i [y_i(wx_i + b) + \xi_i - 1] - \sum_{i=1}^N \mu_i \xi_i \quad (30)$$

O multiplicador de Lagrange assume valor positivo nas observações que satisfazem a equação $y_i(wx_i+b)=1$, ou seja, nas observações sobre os hiperplanos de Suporte, e nulo nas demais observações. A solução ótima da função Lagrangeana deve atender as seguintes condições de otimalidade (KKT):

$$\frac{\partial L}{\partial w} = w - \sum_{i=1}^N \lambda_i y_i x_i = 0 \quad (31)$$

$$\frac{\partial L}{\partial b} = \sum_{i=1}^N \lambda_i y_i = 0 \quad (32)$$

$$\frac{\partial L}{\partial \xi} = C - \lambda_i - \mu_i = 0 \quad (33)$$

$$\lambda_i [y_i(wx_i + b) + \xi_i - 1] = 0 \quad (34)$$

$$y_i(wx_i + b) + \xi_i - 1 \geq 0 \quad (35)$$

$$\lambda_i \geq 0 \tag{36}$$

$$\mu_i \geq 0 \tag{37}$$

$$\xi_i \geq 0 \tag{38}$$

Da primeira condição KKT tem-se que o Vetor normal ao hiperplano é uma combinação linear das observações no conjunto de treinamento.

$$w = \sum_{i=1}^N \lambda_i y_i x_i \tag{39}$$

A primeira e segunda condições KKT são idênticas às encontradas nos *hard-margin classifiers* apresentados nas seções anteriores. Da terceira condição KKT tem-se que:

$$\lambda_i = C - \mu_i \tag{40}$$

Substituindo os resultados na função Lagrangeana tem-se a sua versão dual:

$$L = \sum_{i=1}^N \lambda_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \lambda_i \lambda_j y_i y_j x_i x_j \tag{41}$$

em que $0 \leq \lambda_i \leq C$ e $0 \leq \mu_i \leq C$.

Assim, o dual do problema é dado por (HAMEL, 2009):

$$\begin{aligned} \text{Max}_{\lambda} \quad L &= \sum_{i=1}^N \lambda_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \lambda_i \lambda_j y_i y_j x_i x_j \\ \text{s.a.} \quad &\sum_{j=1}^N \lambda_j y_j = 0 \\ &0 \leq \lambda_i \leq C \end{aligned} \tag{42}$$

Vale observar que a única diferença entre os algoritmos *soft-margin* e *hard-margin* reside na inclusão de limites superiores aos multiplicadores λ . Os Vetores de Suporte estão associados com as variáveis de folga nulas na solução ótima o que implica em multiplicadores:

$$0 < \lambda_i < C \tag{43}$$

Denotando a solução ótima do dual por α^* , o hiperplano de Suporte é determinado pelas seguintes relações, idênticas às do *hard-margin classifier* (HAMEL, 2009):

$$w^* = \sum_{i=1}^N \lambda_i^* y_i x_i \tag{44}$$

$$b^* = w^* x_{sv} - 1 = \sum_{i=1}^N \lambda_i^* y_i x_i x_{sv} - 1 \tag{45}$$

Portanto a consideração da variável de folga ξ com a finalidade de lidar com erros e ruídos nos dados tem como efeito apenas a limitação dos multiplicadores λ . O truque da função núcleo também pode ser aplicado ao classificador com margem flexível com a finalidade de adaptá-lo para as situações em que os dados não são linearmente separáveis. Vale ressaltar que dados não linearmente separáveis, passam a ser linearmente separáveis quando se considera o classificador de margem flexível, e os pontos que conferem não linearidades são tratados como ruídos.

2.3 Máquinas de Vetor de Suporte para regressão

As Máquinas de Vetor de Suporte também podem ser utilizadas em problemas de regressão (SMOLA & SCHOLKOPF, 2004). Esta técnica também é chamada de Regressão por Vetores de Suporte (*Support Vector Regression – SVR*) e assim como no SVM, o objetivo é mapear o espaço original no *feature space* de dimensão superior e então realizar a regressão neste espaço.

Considere uma série temporal com n observações de carga $y_i \forall i=1,n$ acompanhadas das respectivas variáveis explicativas representadas pelo Vetor $X_i \forall i=1,n$. A previsão de carga pode ser efetuada pelo ajuste do seguinte modelo de regressão:

$$f(X) = w^T X + b \tag{46}$$

Conforme ilustrado na Figura 5a, a equação de regressão em (1) pode ser tratada como um hiperplano no centro de um hipertubo (*hypertube*) de largura 2ε com $\varepsilon > 0$ que envolve todas as observações.



(a) Hipertubo e hiperplano de regressão

(b) Variáveis de folga

Figura 5 Hipertubo, hiperplano de regressão e variáveis de folga

A melhor forma de alinhar o tubo aos dados consiste em posicioná-lo de maneira que as observações fiquem próximas da parede do tubo. Apesar do alinhamento ótimo do tubo aos dados não ser efetuado pelo método dos mínimos quadrados ordinários, o posicionamento do tubo é determinado pela solução do seguinte problema de programação quadrática:

$$\begin{aligned} \underset{w, b}{Min} \quad & \frac{1}{2} w^T w \\ & y_i - (w^T X_i + b) \leq \varepsilon \\ & (w^T X_i + b) - y_i \leq \varepsilon \end{aligned} \tag{47}$$

Contudo, não se pode garantir que todos os dados estejam dispostos dentro de um tubo de largura 2ε . Para acomodar estas situações o modelo em (2) deve ser modificado com a adição de variáveis de folga ξ indicadas no modelo em (48). Geometricamente, as variáveis de folga representam as distâncias entre as paredes do tubo e as observações exteriores ao tubo, conforme indicado na Fig. 5b.

$$\begin{aligned} \underset{w, b, \xi^-, \xi^+}{Min} \quad & \frac{1}{2} w^T w + C \sum_{i=1}^n (\xi_i^+ + \xi_i^-) \\ & y_i - (w^T X_i + b) \leq \xi_i^+ + \varepsilon \\ & (w^T X_i + b) - y_i \leq \xi_i^- + \varepsilon \\ & \xi_i^-, \xi_i^+ \geq 0 \end{aligned} \tag{48}$$

No problema de otimização em (48) a constante C é positiva e permite controlar o *trade-off* entre a maximização da margem dentro tubo e a minimização das variáveis de folga, um mecanismo de prevenção ao sobreajuste (*overfitting*). Adicionalmente, a solução do problema de otimização em (48) na sua forma dual em (49) é mais simples de ser alcançada.

$$\begin{aligned}
 & \underset{\lambda_i^+, \lambda_i^-}{Max} \quad -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (\lambda_i^+ - \lambda_i^-)(\lambda_j^+ - \lambda_j^-) X_i^T X_j + \sum_{i=1}^n y_i (\lambda_i^+ - \lambda_i^-) - \varepsilon \sum_{i=1}^n (\lambda_i^+ - \lambda_i^-) \\
 & \text{s. a.} \quad \sum_{i=1}^n (\lambda_i^+ - \lambda_i^-) = 0 \\
 & \quad \quad \quad 0 \leq \lambda_i^+, \lambda_i^- \leq C
 \end{aligned} \tag{49}$$

em que λ denota os multiplicadores de Lagrange associados com as restrições do problema de otimização em (3).

As relações entre as soluções dos problemas primal em (48) e dual em (49) são estabelecidas pelas equações (51) e (51) a seguir:

$$w = \sum_{i=1}^n (\lambda_i^+ - \lambda_i^-) X_i \tag{51}$$

$$b = \frac{1}{n} \sum_{i=1}^n w^T X_i - y_i \tag{52}$$

Substituindo a equação (50) em (46) tem-se a equação do predictor em (53) para uma entrada X .

$$f(X) = \sum_{i=1}^n (\lambda_i^+ - \lambda_i^-) X_i^T X + b \tag{53}$$

Uma motivação das Máquinas de Vetores de regressão é a facilidade com que se pode estender o modelo linear no modelo não linear. A transformação das equações (53) e do problema de programação matemática em (49) para o caso não linear consiste em substituir o produto $X_i^T X_j$ por uma função núcleo (*kernel trick*) que mapeia o espaço de entrada em um espaço de maior dimensão:

$$\Phi(X_i, X_j) = \phi(X_i)\phi(X_j) \tag{54}$$

O modelo de regressão linear resultante é ilustrado em (55). Na sequência, em (56) tem-se a equação de regressão para o caso não linear:

$$\begin{aligned}
 & \underset{\lambda_i^+, \lambda_i^-}{Max} \quad -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (\lambda_i^+ - \lambda_i^-)(\lambda_j^+ - \lambda_j^-) \Phi(X_i^T X_j) + \sum_{i=1}^n y_i (\lambda_i^+ - \lambda_i^-) - \varepsilon \sum_{i=1}^n (\lambda_i^+ - \lambda_i^-) \\
 & \text{s. a.} \quad \sum_{i=1}^n (\lambda_i^+ - \lambda_i^-) = 0 \\
 & \quad \quad \quad 0 \leq \lambda_i^+, \lambda_i^- \leq C
 \end{aligned} \tag{55}$$

$$f(X) = \sum_{i=1}^n (\lambda_i^+ - \lambda_i^-) \Phi(X_i^T X) + b \tag{56}$$

Os resultados de uma Máquina de Vetores de Suporte para regressão são sensíveis à definição dos seus hiperparâmetros, um conjunto formado pela constante C , pela largura do tubo ε , pela função núcleo (*kernel*) e seus parâmetros.

2.4 Validação Cruzada

O objetivo de um algoritmo de aprendizagem é codificar um mapeamento de entrada-saída de modo que a regressão seja capaz de generalizar problemas futuros a partir de informações do passado. Portanto, um processo de treinamento consiste na escolha dos parâmetros de cada modelo para um determinado conjunto de dados. Assim, a tarefa de seleção de parâmetros pode ser entendida como a obtenção do melhor mapeamento possível, segundo um critério qualquer. Neste sentido, uma forma interessante de encontrar a melhor configuração para os

hiperparâmetros C , ϵ e da função Kernel para um determinado conjunto de dados consiste em aplicar a validação cruzada (*k-fold cross validation*) (MORENO-TORRES et al, 2012, YADAV & SHUKLA, 2016).

A *K-fold cross validation* consiste em dividir aleatoriamente o conjunto de dados original em um número K de subconjuntos de mesmo tamanho. Com isso, o treinamento é realizado K vezes, utilizando a cada rodada um dos subconjuntos para validação e todos os outros para o treinamento do modelo. Para cada subconjunto de treinamento são calculadas métricas de desempenho para avaliar o erro de generalização e, ao final, de todas as rodadas de treinamento, é calculado o valor médio dos erros. Uma vantagem da validação cruzada é que o treinamento é realizado em todo o conjunto de dados, esperando-se assim uma maior capacidade de generalização do modelo. A Figura 6 ilustra o processo de validação cruzada *K-fold* para um $k=10$.

A identificação dos hiperparâmetros do SVM para regressão inicia-se com a escolha de um conjunto de valores possíveis para C , ϵ e o parâmetro da função *Kernel*. Na sequência, as combinações dos valores selecionados para cada hiperparâmetro determinam um conjunto de soluções de interesse. Assim, por meio de uma busca exaustiva (*grid search*) aplica-se a validação cruzada para avaliar o erro associado à cada solução de interesse. Ao final, a melhor solução é que apresentar o menor erro.

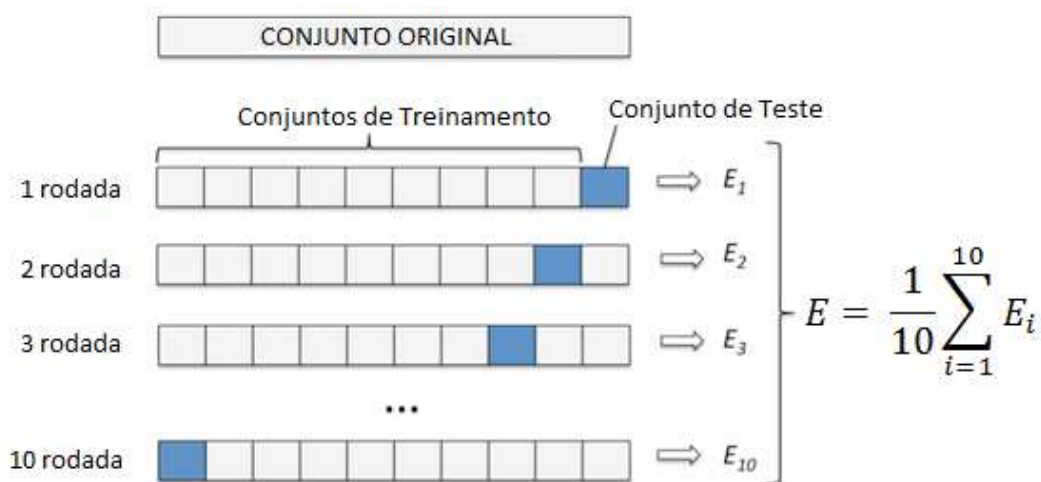


Figura 6 – Exemplo de validação cruzada para $k=10$ (BUHAGIAR, 2017)

3 Modelagem da previsão de carga no PrevCargaPMO

3.1 Introdução

O programa PrevCargaPMO conta com cinco modelos (Máquinas de Vetor de Suporte), conforme indicado na Figura 1, capazes de fornecer previsões de carga para diferentes horizontes:

- Modelo 1: Previsão da carga média diária (geração supervisionada).
- Modelo 2: Modelo de previsão da geração não supervisionada média diária.
- Modelo 3: Previsão semanal da carga média global da primeira semana à frente.
- Modelo 4: Previsão semanal da carga média global da segunda até a sexta semana à frente.
- Modelo 5: Modelo de previsão mensal da carga média global até 2 meses à frente.

Nos modelos 3, 4 e 5, a carga global por Subsistema é definida pela seguinte equação:

$$\text{Carga Global}_{\text{por Subsistema}} = \text{Geração supervisionada} - \text{Intercâmbio} + \text{Geração não supervisionada}$$

Sendo que a parcela supervisionada da Carga Global do Subsistema é igual a:

$$\text{Geração supervisionada} - \text{Intercâmbio}$$

Ressalta-se que o ajuste (treinamento) dos modelos é precedido pelo tratamento dos dados de carga e temperatura. A metodologia empregada no tratamento de dados é descrita na seção 3.2. Na sequência, na seção 3.3 apresentam-se os modelos de previsão descritos acima e as estratégias usadas na coordenação das previsões semanais e mensais.

3.2 Metodologia de tratamento de dados

3.2.1 Tratamento dos dados de temperatura

A temperatura é uma das principais variáveis explicativas da carga e neste sentido é fundamental que os dados de temperatura não apresentem valores discrepantes (*outliers*) e lacunas (*gaps*), pois a presença destes erros pode comprometer o ajuste do modelo de previsão.

Inicialmente verifica-se a presença de lacunas de dados. No caso de ausência de dados de temperatura ao longo de um dia inteiro (uma lacuna com duração de 24 horas), a lacuna é preenchida pelo perfil médio de temperatura resultante da média dos perfis diários imediatamente adjacentes ou pelo perfil imediatamente sem lacuna, no caso de um dos perfis adjacentes também ter lacuna. Em último caso, nos dias sem dados de temperatura, toma-se o perfil médio horário da temperatura ao longo do mesmo mês e ano do dia sem dados ou, no caso extremo, a média dos perfis horários do histórico com dados completos.

Na sequência, os eventuais *outliers* são identificados e corrigidos com o auxílio do estimador de Nadaraya-Watson, um método de regressão não paramétrica (MARTINEZ & MARTINEZ, 2002). Dada uma série de temperatura, a respectiva versão suavizada é obtida por meio do seguinte estimador:

$$Y(t) = \frac{\sum_{i=1}^N K\left(\frac{t-t_i}{h}\right) y_i}{\sum_{i=1}^N K\left(\frac{t-t_i}{h}\right)} \quad (57)$$

em que K é uma função núcleo (gaussiana), N é o número de observações, t_i é o instante da temperatura verificada y_i e h é um hiperparâmetro denominado largura de banda.

Como resultado, o estimador de Nadaraya-Watson produz uma versão suavizada $Y(t)$ da série de temperatura. A partir do desvio padrão (DP) dos desvios entre as séries real e suavizada obtém-se os limites dos intervalos de confiança para a temperatura em cada hora:

$$\text{Limite superior: } LS(t) = Y(t) + 3,5 DP \quad (58)$$

$$\text{Limite inferior: } LI(t) = Y(t) - 3,5 DP \quad (59)$$

Os valores discrepantes situam-se fora dos intervalos de confiança definidos acima e são substituídos pelos valores suavizados correspondentes.

3.2.2 Tratamento dos dados da parcela supervisionada da carga

Os dados de carga também são susceptíveis à lacunas e *outliers* e merecem passar por um tratamento prévio. Embora a previsão de carga com resolução horária não seja objeto do PrevCargaPMO o tratamento de dados de carga fornece uma versão tratada da série de carga com resolução horária.

3.2.2.1 Identificação dos perfis diários típicos

A metodologia de tratamento de dados de carga inicia-se com a identificação de lacunas de dados já durante a leitura de dados horários da geração supervisionada e de intercâmbio, as lacunas nestas duas séries são substituídas por zero. Os erros grosseiros (*outliers*) no resultado da geração supervisionada menos intercâmbio são identificados com o auxílio de um *boxplot* e os valores discrepantes são substituídos por zero. Os perfis sem lacunas ou *outliers* são padronizados pelas respectivas médias e posteriormente classificados pelo método de Ward (PESSANHA et al, 2015), um algoritmo de análise de agrupamentos, para a identificação automática de K perfis típicos de carga, em que cada perfil corresponde ao centroide de um *cluster* de perfis diários semelhantes. O algoritmo para agregação de N perfis diários de carga em K *clusters* (no PrevCargaPMO o valor de K foi fixado em 40) é descrito a seguir:

- 1) Inicie com N *clusters*, cada um contendo apenas um perfil diário de carga com resolução horária e construa a matriz de distâncias de ordem N entre os perfis.
- 2) Identifique o menor elemento da matriz de distâncias para encontrar o par de *clusters* mais similares.
- 3) Reúna os dois *clusters* identificados na etapa 2 em um único *cluster* e atualize a matriz de distâncias, retirando as linhas e colunas relativas aos dois *clusters* identificados em 2 e incluindo a linha e coluna com as distâncias entre os demais *clusters* e o novo *cluster* formado. Note que a ordem da matriz de distâncias diminui de uma unidade a cada vez que a etapa 3 é executada.
- 4) Repita os passos 2 e 3 até que restem apenas dois *clusters*. A cada iteração guarde a identificação dos *clusters* que foram fundidos e também a distância entre eles.

Nas etapas 1 e 3 do algoritmo de Ward as distâncias entre os *clusters* são calculadas com base na seguinte fórmula:

$$d_{ij} = \frac{p_i p_j}{p_i + p_j} d^2(c_i, c_j) \quad (60)$$

em que p_i e p_j denotam as quantidades de objetos nos *clusters* i e j respectivamente e $d^2(c_i, c_j)$ representa o quadrado da distância euclidiana entre os centroides dos agrupamentos i e j .

3.2.2.2 Identificação do perfil diário para dias sem dados de carga

Ao final do método de Ward, cada perfil participante da análise de agrupamentos é rotulado com número entre 1 e K correspondente ao *cluster* em que foi alocado. Adicionalmente, para cada um destes perfis são conhecidos o dia da

semana, o mês, o tipo de dia (normal, feriado ou dia especial) e o horário (normal ou verão). A partir destas informações podem ser calculadas as seguintes frequências (probabilidades condicionais):

$$P(\text{dia da semana } i \mid \text{cluster } j) = P(i \mid j) \quad \forall i=1,7 \text{ e } j=1,k \quad (61)$$

$$P(\text{mês } m \mid \text{cluster } j) = P(m \mid j) \quad \forall m=1,12 \text{ e } j=1,k \quad (62)$$

$$P(\text{tipo de dia } n \mid \text{cluster } j) = P(n \mid j) \quad \forall n=1,9 \text{ e } j=1,k \quad (63)$$

$$P(\text{horário } h \mid \text{cluster } j) = P(h \mid j) \quad \forall h=1,2 \text{ e } j=1,k \quad (64)$$

A probabilidade $P(\text{cluster } j) = P(j) \quad \forall j=1,k$ é a frequência relativa em cada *cluster*. As probabilidades acima podem ser combinadas pelo Teorema de Bayes com o intuito de identificar o perfil de carga típico (*cluster*) mais provável em um dia qualquer, conhecendo-se apenas a data (dia da semana e mês), o horário (normal ou verão) e o tipo do dia (normal, feriado ou dia especial). Admitindo que as características dos dias sejam condicionalmente independentes, o classificador *Naive Bayes* (GRUS, 2016) atribui o perfil típico j ao dia da semana i , no mês m , com tipo n e horário h se a hipótese de máxima a posterior for verificada para o *cluster* j , conforme descrito pela desigualdade a seguir:

$$P(i \mid j) * P(m \mid j) * P(n \mid j) * P(h \mid j) * P(j) > P(i \mid w) * P(m \mid w) * P(n \mid w) * P(h \mid w) * P(w) \quad \forall j \neq w=1,K \quad (65)$$

3.2.2.3 Estimativa da demanda média diária para os dias sem dados de carga verificados

O perfil típico atribuído pelo classificador *Naive Bayes* a um dia com perfil de carga incompleto está normalizado pela média, assim é preciso multiplicá-lo por uma estimativa da demanda média diária para obter o perfil horário em MW. A estimativa da demanda média diária para um dia D sem dados de carga é fornecida por uma Máquina de Vetor de Suporte em função das seguintes variáveis:

- valores passados da carga média diária nos dias $D-1$, $D-7$, $D-14$ e $D-21$
- temperatura máxima no dia D
- temperatura média no dia D
- temperatura mínima no dia D
- mês do dia D (11 variáveis indicadoras ou *dummy*, em dezembro todas as variáveis são nulas)
- dia da semana do dia D (6 variáveis indicadoras ou *dummy*, no sábado todas as variáveis são nulas)
- horário do dia D (0 para o horário normal e 1 para o horário de verão)
- tipo do dia (uma variável indicadora ou *dummy*) que assume valor 1 para os feriados e 0 nos demais dias.

O perfil estimado para um dia sem dados de carga (lacuna de 24 horas) é determinado pelo produto entre a previsão da demanda média diária fornecida pelo modelo SVM e o perfil (em p.u. da demanda média) atribuído pelo *Naive Bayes*.

3.2.2.4 Correção de valores discrepantes

Ao final, os eventuais *outliers*, identificados pelo *boxplot* da série de carga, são substituídos pelos valores medianos na mesma hora e mesmo dia semana em uma janela de 744 horas. Na sequência aplica-se o estimador de Nadaraya-Watson (MARTINEZ & MARTINEZ, 2002) a seguir para suavizar a série de carga:

$$Y(t) = \frac{\sum_{i=1}^N K\left(\frac{t-t_i}{h}\right) y_i}{\sum_{i=1}^N K\left(\frac{t-t_i}{h}\right)} \quad (66)$$

em que K é uma função núcleo (gaussiana), N é o número de observações, t_i é o instante da carga verificada y_i e h é um hiperparâmetro denominado largura de banda.

Como resultado, o estimador de Nadaraya-Watson produz uma versão suavizada $Y(t)$ da série de carga. A partir do desvio padrão (DP) dos desvios entre as séries de carga e sua versão suavizada obtêm-se os limites dos intervalos de confiança para a carga em cada hora:

$$\text{Limite superior: } LS(t) = Y(t) + 3,5 DP \quad (67)$$

$$\text{Limite inferior: } LI(t) = Y(t) - 3,5 DP \quad (68)$$

Os valores discrepantes situam-se fora dos intervalos de confiança definidos acima e são substituídos pelos valores suavizados correspondentes.

3.2.3 Tratamento dos dados da geração não supervisionada

Os dados de geração não supervisionada são fornecidos em base horária e base diária. As lacunas de dados são substituídas por zero durante a leitura de dados. Assim, o tratamento de dados inicia-se com a montagem de uma série temporal da média diária da geração não supervisionada. Os valores negativos são substituídos por zero e na sequência pela média geométrica dos valores imediatamente adjacentes. Ao final, aplica-se uma regressão não paramétrica LOESS (MARTINEZ & MARTINEZ, 2002) com o objetivo de obter uma versão suavizada da série com valores diários da geração não supervisionada. A partir do desvio padrão (DP) dos desvios entre as séries diária e sua versão suavizada obtêm-se os limites dos intervalos de confiança para a geração não supervisionada em cada dia:

$$\text{Limite superior: } LS(t) = Y(t) + 2,0 DP \quad (69)$$

$$\text{Limite inferior: } LI(t) = Y(t) - 2,0 DP \quad (70)$$

Os valores discrepantes situam-se fora dos intervalos de confiança definidos acima e são substituídos pelos valores suavizados correspondentes.

3.3 Modelos de Previsão

3.3.1 Modelo 1 - Modelo para previsão da carga média diária (parcela supervisionada)

A elaboração ou revisão do PMO ocorre antes do fim da semana operativa corrente. Logo, o valor da carga global de energia para a semana corrente não é conhecido, mas pode ser estimado a partir das informações disponíveis.

A carga global é composta pela geração supervisionada, intercâmbio e geração não supervisionada. Para alcançar este objetivo, o Modelo 1 foi especificado de forma a fornecer as previsões das médias diárias da parcela supervisionada da carga (com o intercâmbio) dos dias que restam para completar a semana operativa corrente (semana S). As previsões obtidas pelo Modelo 1 em conjunto com os valores verificados disponíveis permitem estimar a carga média da semana operativa corrente. Os dias identificados como blecautes, jogos da copa e demais dias atípicos (código 12 na codificação dos tipos de dias) são previamente eliminados do conjunto de treinamento do modelo SVM.

O Modelo 1 foi implementado em uma Máquina de Vetor de Suporte e fornece previsões da demanda média diária para o dia D em função das seguintes variáveis explicativas:

- valores passados da carga média diária nos dias $D-1$ e $D-7$
- temperatura máxima prevista para o dia D

- temperatura média prevista para o dia D
- temperatura mínima prevista para o dia D
- mês do dia D (12 variáveis indicadoras ou *dummy*)
- dia da semana do dia D (7 variáveis indicadoras)
- horário do dia D (0 para o horário normal e 1 para o horário de verão)
- tipo do dia (11 variáveis indicadoras ou *dummy*), para os dias normais todas as variáveis indicadoras são nulas). Cada variável indicadora está associada com um feriado ou dia especial, conforme as 11 primeiras categorias da tabela de codificação de feriados e dias especiais.

Adicionalmente, para um dia normal D e em um mês M, ajusta-se um outro modelo SVM envolvendo apenas os dias normais no mesmo dia da semana do dia D e em uma janela temporal com dados dos meses M-1, M e M+1. No ajuste do modelo SVM adicional consideram-se apenas os dados passados da carga dos dias D-1 e D-7 e a temperatura (média, mínima e máxima). Assim, para os dias normais têm-se duas previsões e adota-se a previsão mais próxima da média semanal dos valores observados. As demandas médias diárias previstas pelo modelo são multiplicadas pelos perfis típicos atribuídos pelo classificador Naive Bayes (seção 3.2.2.2), assim obtém-se os perfis horários para os dias que completam a semana operativa corrente.

3.3.2 Modelo 2 - Modelo para previsão da média diária da geração não supervisionada

Os dados de geração não supervisionada são fornecidos em dois arquivos, um contendo uma série temporal horária e outro com a série das médias diárias. Em geral, para o mês corrente ou para o mês anterior ao dia da previsão os dados de geração não supervisionada correspondem aos valores médios diários.

Assim, o *PrevcargaPMO* importa os dois arquivos e internamente produz uma série temporal da média diária da geração não supervisionada. A partir desta série ajusta-se um modelo SVM para produzir previsões das médias diárias da geração não supervisionada dos dias que completam a semana operativa corrente. Tal modelo SVM tem como variável dependente a média diária da geração não supervisionada no dia D e como variáveis explicativas os valores passados da própria geração não supervisionada nos dias D-1 e D-7, acompanhados de 11 variáveis *dummy* para capturar a sazonalidade mensal e 6 variáveis *dummy* para capturar a sazonalidade diária.

3.3.3 Modelos 3 e 4 – Modelo para previsão da carga média semanal (carga global)

Dado que a previsão de temperatura apresenta restrições em sua acurácia para períodos muito longos, para as previsões das médias semanais da carga global até seis semanas à frente foi necessária a elaboração de dois modelos de previsão: o Modelo 3 para a previsão da carga média na primeira semana operativa, no qual considera-se a temperatura prevista, e o Modelo 4 para a previsão nas demais semanas operativas.

Assim, para a previsão da primeira semana à frente (semana S+1, em que S denota a semana operativa corrente), o Modelo 3 foi especificado de forma a fornecer previsões do valor da média semanal da carga global na semana S+1 em função das seguintes variáveis explicativas:

- valores passados da média semanal da global carga nas semanas S, S-51 e S-52.
- temperatura máxima ou média prevista para a semana S+1
- mês mais frequente na semana S+1 (11 variáveis indicadoras ou *dummy*, em dezembro todas as variáveis são nulas)
- variável indicadora do horário de verão na semana S+1 (0 se a maioria dos dias pertence ao horário normal e 1 caso a maioria dos dias da semana pertença ao período do horário de verão)

- total de feriados com perfis de sábado/domingo, Natal e Ano Novo na semana S+1
- total de feriados com perfis de sábado/domingo, Natal e Ano Novo na semana corrente

Para a previsão da carga média semanal da segunda semana em diante, por não ser possível contar com previsões de temperatura, o programa gera duas previsões da carga global média semanal para as semanas S+h, $\forall h=2,6$, sendo uma baseada na previsão carga média global e a outra baseada na previsão da taxa de crescimento da carga, e na sequência escolhe uma das previsões.

O primeiro conjunto de previsões da carga média global para as semanas S+h, $\forall h=2,6$ é obtido em função das seguintes variáveis explicativas:

- valores passados da carga média global semanal na semana corrente S
- mês mais frequente na semana S+h (11 variáveis indicadoras ou *dummy*, em dezembro todas as variáveis são nulas)
- total de feriados em dias úteis com perfis de sábado/domingo, Natal e Ano novo na semana S+h
- total de feriados em dias úteis com perfis de sábado/domingo, Natal e Ano novo na semana corrente

Já o segundo conjunto de previsões da carga média global para as semanas S+h, $\forall h=2,6$ é obtido pela seguinte equação de previsão:

$$\text{Previsão da carga média na semana S+h} = (\text{carga média da semana operativa corrente S}) \times \exp(r_h) \quad (71)$$

em que r_h corresponde à taxa de crescimento prevista, para a semana S+h, o logaritmo da razão da carga média de duas semanas separadas por h semanas, i.e., $r_h = \ln[\text{carga}(\text{semana S+h})/\text{carga}(\text{semana S})]$.

A previsão da taxa de crescimento da média semanal da carga global h passos à frente (até seis semanas à frente) é obtida em função das seguintes variáveis explicativas:

- valor passado da taxa de crescimento da carga média semanal na semana corrente S
- mês mais frequente na semana S+h (11 variáveis indicadoras ou *dummy*, em dezembro todas as variáveis são nulas)
- indicador de horário de verão da semana S+h (0 se a maioria dos dias pertence ao horário normal e 1 caso a maioria dos dias da semana pertença ao período do horário de verão)
- total de feriados em dias úteis com perfis de sábado/domingo, Natal e Ano Novo na semana S+h
- carga da semana corrente S

Adicionalmente, o método da decomposição clássica da série temporal nas componentes de tendência, sazonalidade e erro (HYNDMAN & KHANDAKAR, 2008) é aplicado à série de carga global média semanal para obter previsões semanais de 2 até 6 semanas acompanhadas dos respectivos intervalos com 95% de confiança. Apesar da previsão obtida pelo método da decomposição da série temporal não depender das variáveis explicativas, a previsão captura a tendência e a componente sazonal presente na série e fornece uma referência contra a qual podem ser comparadas as previsões semanais geradas pelos dois modelos baseados em SVM. Para cada semana do horizonte de previsão tem-se duas previsões semanais (SVM), a previsão escolhida é a mais próxima da

previsão gerada pelo método da decomposição clássica. Portanto, as previsões semanais apresentadas pelo programa são as obtidas pela abordagem SVM e as previsões calculadas pelo método da decomposição clássica servem apenas como referência.

3.3.4 Modelo 5 – Modelo para previsão da carga média mensal (carga global)

Tal modelo tem por finalidade fornecer previsões da carga global média mensal para o mês de previsão M e o mês seguinte M+1. As previsões de carga para os meses M e M+1 são determinadas em função das seguintes variáveis:

- valores passados da carga mensal no meses M-1, M-2, M-3 e M-4.
- 11 variáveis indicadoras (*dummy*) para representar a sazonalidade.

O modelo de previsão foi implementado em uma Máquina de Suporte e a mesma Máquina é utilizada para prever os dois meses do horizonte de previsão, neste caso a previsão para o segundo mês depende da previsão do primeiro mês.

Adicionalmente, o método de Holt-Winters (HYNDMAN & KHANDAKAR, 2008) é aplicado na série de carga global média mensal com a finalidade de obter previsões da carga mensal acompanhadas dos respectivos intervalos de 95% de confiança. Fatores sazonais aditivos também são calculados com o auxílio de um modelo de regressão linear múltipla, no qual a variável explicada é a carga e as variáveis explicativas são uma tendência linear (contador de meses) e um conjunto de 11 variáveis *dummy*. Para cada mês há duas previsões mensais, uma fornecida pelo modelo SVM e outra pelo Holt-Winters. Se as direções de ambas as previsões mensais são compatíveis com a direção indicada pelo sinal (+ ou -) do fator sazonal correspondente ao mês de previsão, o programa escolhe a previsão que fornece o incremento de carga mensal mais próximo do valor estimado pelo fator sazonal. Caso contrário, se ambos os modelos SVM e Holt-Winters indicarem previsões com direções diferentes da apontada pelo fator sazonal, a previsão mensal é igual a um dos limites do intervalo de confiança para o mês da previsão: limite inferior se o fator sazonal é negativo ou o limite superior se o fator sazonal é positivo. Se as previsões resultantes seguirem em direções opostas, o programa escolhe a previsão com a mesma direção indicada pelo fator sazonal.

3.4 Compatibilização das previsões no caso da REV0

Após a execução dos modelos de previsão deve-se buscar a compatibilização das previsões para os diferentes horizontes, i.e., a previsão mensal para o primeiro mês deve ser compatível com as previsões/dados das semanas dentro do período de abrangência do primeiro mês.

A estratégia de compatibilização das previsões semanais e mensais depende do momento da revisão do PMO. Portanto, há dois tipos de estratégia de atualização: REV0 e revisões semanais. Ressalta-se que no caso da REV0, os dados de carga disponíveis terminam no mês imediatamente anterior ao primeiro mês do horizonte de previsão.

Na REV0, a previsão para a primeira semana é mantida, mas as previsões das demais semanas são ajustadas de forma que a média das previsões semanais seja compatível com a carga mensal prevista para o primeiro mês do horizonte de previsão. A opção de manter a previsão da primeira semana deve-se ao fato desta ter maior previsibilidade, pois inclusive considera previsões de temperatura. Já nas revisões semanais do PMO, as previsões semanais são atualizadas semanalmente em função de novos dados de carga. Neste caso, a previsão da carga mensal para o primeiro mês é atualizada em função dos novos dados e das novas previsões semanais.

3.4.1 Coordenação das previsões no caso da REV0

No caso da REV0, a coordenação das previsões consiste em ajustar as previsões semanais, com dias no primeiro mês do horizonte, de forma que a média ponderada das previsões semanais seja igual a previsão da demanda média mensal para o primeiro mês.

Quando a semana operativa corrente inicia e termina em meses distintos busca-se obter estimativas das demandas médias diárias dos dias da semana corrente que pertencem ao primeiro mês do horizonte de previsão. Assim, no caso da primeira semana do primeiro mês começar no mês anterior, tem-se a seguinte previsão da demanda média

diária da geração não supervisionada ($PDMD_{NS}$) nos dias da semana corrente pertencentes ao primeiro mês do horizonte:

$$PDMD_{NS} = PDMS1_G - \frac{1}{7} \sum_{dia=1}^7 (MD_{NS}(dia) + \sum_{hora=1}^{24} Carga(dia, hora)) \quad (72)$$

Na equação (72) $PDMS1_G$ é a previsão da carga média global semanal para a primeira semana com dias no primeiro mês do horizonte de previsão, $MD_{NS}(dia)$ denota a média diária verificada da geração não supervisionada, uma informação disponível apenas para o período histórico, e $Carga(dia, hora)$ denota os valores verificados/previdos da demanda média horária (apenas a parcela supervisionada da carga) em cada dia da semana operativa. A equação (72) depende de previsões diárias fornecidas pelo modelo descrito na seção 3.3.1.

A primeira semana do primeiro mês do horizonte de previsão pode conter dias do mês anterior e para estes dias há valores estimados/verificados da média diária da geração não supervisionada (MD_{NS}). Para os demais dias da semana não há informações da geração não supervisionada, logo para estes dias admite-se a mesma média diária $PDMD_{NS}$ calculada em (72). Assim, a previsão da carga global para cada dia na primeira semana do primeiro mês do horizonte é igual a:

$$PDMD_G(dia) = PDMD_{NS} + \frac{1}{24} \sum_{hora=1}^{24} Carga(dia, hora) \quad (73)$$

em que $Carga(dia, hora)$ denota previsões horárias da parcela supervisionada da carga, fornecidas pelo modelo descrito em 3.3.1.

Assim, a energia consumida nos dias da primeira semana do primeiro mês do horizonte previsão é igual a:

$$Energia\ 1^{a}\ semana\ do\ 1^{o}\ mês = \sum_{dia=1}^{n^{o}\ de\ dias\ na\ primeira\ semana\ \in\ 1^{o}\ mês} PDMD_G(dia) \quad (74)$$

Naturalmente, se a primeira semana do primeiro mês começa e termina dentro do mesmo mês, o n^{o} de dias na primeira semana \in 1^o mês é igual a 7 e a energia na primeira semana é igual a primeira previsão semanal fornecida pelo modelo 3 descrito na seção 3.3.3:

$$Energia\ 1^{a}\ semana\ do\ 1^{o}\ mês = 7 \times Previsão\ da\ demanda\ média\ para\ a\ 1^{a}\ semana \quad (75)$$

Logo, a previsão da energia consumida nos demais dias do primeiro mês é dada por:

$$\Delta = PDMM1_G * NDM1 - Energia\ 1^{a}\ semana\ do\ 1^{o}\ mês \quad (76)$$

em que $PDMM1_G$ é a previsão da carga média global para o primeiro mês, fornecida pelo modelo 3 descrito na seção 3.3.3, e $NDM1$ é o número de dias do primeiro mês.

Assim, a carga média no período entre o início da segunda semana e o fim do primeiro mês é igual a:

$$\delta = \frac{\Delta}{NDM1 - n^{o}\ de\ dias\ na\ primeira\ semana\ \in\ 1^{o}\ mês} \quad (77)$$

A partir das previsões horárias da parcela supervisionada da carga, fornecidas pelo modelo descrito na seção 3.3.1 para os dias da última semana operativa no primeiro mês, pode-se calcular o fator de ajuste α , definido pela razão da carga média nos dias da última semana operativa pertencentes ao primeiro mês e a carga média na última semana operativa do primeiro mês:

$$\alpha = \frac{\sum_{dia=1}^{NDUS1} \sum_{hora=1}^{24} Carga(dia, hora)}{\frac{NDUS1}{7} \sum_{dia=1}^7 \sum_{hora=1}^{24} Carga(dia, hora)} \quad (78)$$

em que $Carga(dia, hora)$ denota previsões horárias da carga (apenas a parcela supervisionada) e $NDUS1$ é o número de dias na última semana operativa, pertencentes ao primeiro mês.

Naturalmente, $\alpha=1$ no caso da última semana operativa pertencer completamente ao primeiro mês. Assim, a previsão da carga média global no período da última semana operativa no primeiro mês $PDMUSM1_G$ é definida como:

$$PDMUSM1_G = \alpha * PDMUS_G \quad (79)$$

em que $PDMUS_G$ é a previsão da demanda média global semanal para a última semana operativa no primeiro mês (previsão para toda a semana), fornecida pelo modelo 4 descrito na seção 3.3.3.

Na sequência, em função da ausência de previsões de temperatura a partir da segunda semana operativa do horizonte de previsão, efetua-se o ajuste das previsões semanais para a segunda semana em diante, mas dentro do período do primeiro mês. O ajuste visa tornar as previsões semanais, fornecidas pelo modelo 4 na seção 3.3.3, compatíveis com a previsão mensal para o primeiro mês, fornecida pelo modelo 3.3.4.

Seja $PDMSM1(i)$ a previsão da demanda média semanal da carga global da semana i , a partir da segunda semana do horizonte de previsão e completamente dentro do primeiro mês (previsões fornecidas pelo modelo 4 na seção 3.3.3). Uma previsão alternativa da carga média global para o período entre o início da segunda do horizonte e a última semana no primeiro mês, é dada por:

$$\beta = \frac{\sum_{i=2}^{\text{última semana completamente no mês 1}} PDMSM1(i)*7 + PDMUSM1*NDUS1}{NDM1 - n^{\circ} \text{ de dias na primeira semana em } 1^{\circ} \text{ mês}} \quad (80)$$

em que $NDM1 - n^{\circ} \text{ de dias na primeira semana em } 1^{\circ} \text{ mês}$ é o total de dias do primeiro mês descontado dos dias na primeira semana operativa do horizonte e $NDUS1$ é o total de dias do primeiro mês na última semana.

O resultado da equação (80) é uma alternativa ao resultado da equação (77), este último obtido a partir da previsão mensal e da previsão para a primeira semana, fornecida pelo modelo 3 descrito na seção 3.3.3.

Assim, as previsões semanais ajustadas para as semanas completamente dentro do primeiro mês são dadas por:

$$PDMSM1(i) = PDMSM1(i) \frac{\delta}{\beta} \quad (81)$$

Já para a última semana parcialmente no primeiro mês, a demanda média nos dias pertencentes ao primeiro mês é dada por:

$$PDMUSM1 = PDMUSM1 \frac{\delta}{\beta} \quad (82)$$

3.4.2 Compatibilização das previsões no caso das revisões semanais

No caso das revisões semanais, a atualização da previsão da carga global para o primeiro mês do horizonte é calculada com base na seguinte equação:

$$PDMM1 = \frac{\sum_{\text{período } i \in 1^{\circ} \text{ mês}} W(i) \times \text{Carga global}(i)}{\sum_{\text{período } i \in 1^{\circ} \text{ mês}} W(i)} \quad (83)$$

em que o período i pode ser um dia, uma semana ou parcela de uma semana, $\text{Carga global}(i)$ é a previsão ou valor verificado da carga global para o período i e $W(i)$ atribuído ao valor da carga global do i -ésimo período.

A revisão semanal desenvolve-se ao longo do primeiro mês do horizonte de previsão, logo com o avanço do mês começam a surgir dados verificados/estimados da carga global do primeiro mês. Estas observações parciais, em conjunto com as previsões de carga, permitem atualizar a previsão da carga média global mensal. Assim, para os dias do primeiro mês do horizonte com carga global conhecida (pelo menos com a parcela supervisionada conhecida, a geração não supervisionada pode ser estimada), tem-se que $W(i) = 1$ e $\text{Carga global}(i)$ igual ao respectivo valor da demanda média diária conhecida. Para o período de previsão, $W(i)$ e a $\text{Carga global}(i)$ são determinados com base na seguintes regras:

-
- Se o período i é uma semana completamente dentro do primeiro mês, então $W(i) = 7$ e $Carga\ global(i)$ é a respectiva previsão semanal da carga global fornecida pelos modelo descritos na seção 3.3.3.
 - Se o período i é um dia, por exemplo, um dia da semana operativa corrente, então $W(i)=1$ e $Carga\ global(i)$ é a respectiva previsão diária fornecida pelos modelos descritos na seção 3.3.1 e 3.3.2.
 - Se o período i corresponde à uma parcela da semana, então $W(i)$ é igual ao total de dias da semana no primeiro mês do horizonte de previsão e $Carga\ global(i)$ é a previsão de carga fornecida pela equação 79.

4 Programa PrevCargaPMO

4.1 Instalação

Para instalar o PrevCargaPMO copie o arquivo prevcargapmo2017_1.0.zip para algum diretório. Na sequência, acesse o R e use a opção do menu "Pacotes/Instalar pacote(s) a partir de arquivos zip locais..." (Figura 7) para instalar o pacote prevcargapmo disponibilizado no arquivo prevcargapmo_1.27.tar.zip.

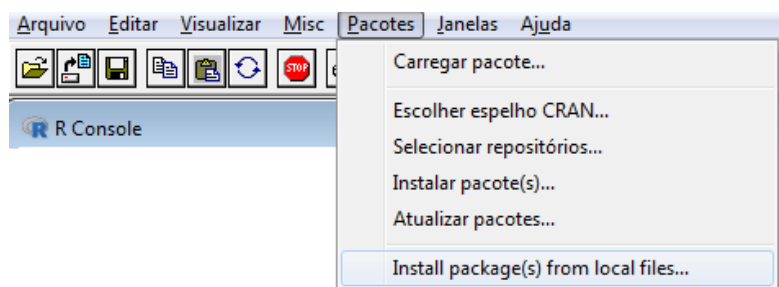


Figura 7 – Menu Pacotes e opção *Install packages(s) from local files...*

4.2 Entrada de Dados

Os dados de entrada para o modelo de previsão devem ser organizados em tabelas e/ou arquivos, conforme apresenta a Tabela 3.

Tabela 3 -- Tabelas e arquivos de entrada do previsor.

Conteúdo da Tabela	Nome da Tabela / Arquivo CSV / Data.frame
Parâmetros de execução e modelagem	PARAMETROS
Dados históricos de carga	CARGAHIST
Dados históricos de temperatura equivalente	TEMPHIST
Datas de feriados nacionais e estaduais	FERIADOS
Datas de início e fim do horário de verão	HORAVERAO
Informações sobre o horizonte de previsão	HORIZONTE
Previsões de temperatura equivalente	TEMPPREVISTA
Dados históricos de geração não supervisionada em base horária	NSUPHISTHORARIA
Dados históricos de geração não supervisionada em base diária	NSUPHISTDIARIA
Dados históricos de intercâmbio	INTERCAMBIO

A tabela PARAMETROS deve conter o nome do subsistema e os nomes das tabelas de dados de carga, temperatura histórica, feriados, horizonte de previsão, temperatura prevista e horário de verão, como visualizado na Figura 8. No campo "separador" deve-se informar 0 ou 1 para especificar o separador decimal usado nos arquivos de saída: 0 para ponto e 1 para vírgula.

	A	B	C	D	E	F	G	H	I	J	K
1	Subsistema	CARGAHIST	TEMPHIST	FERIADOS	HORIZONTE	TEMPPREVISTA	HORAVERAO	separador	NSIMHISTHORARIA	NSIMHISTDIARIA	INTERCAMBIO
2	Subsistema	CARGAHIST_Subsistema	TEMPHIST_Subsistema	FERIADOS_Subsistema	HORIZONTE_Subsistema	TEMPPREVISTA_Subsistema	HORAVERAO_Subsistema	1	NSUPHISTHORARIA_Subsistema	NSUPHISTDIARIA_Subsistema	INTERCAMBIO_Subsistema

Figura 8 – Exemplo da Tabela PARAMETROS

A tabela CARGAHIST com dados históricos de carga deve conter os valores médios da demanda (MW) em intervalos horários. Adicionalmente, cada valor médio deve ser acompanhado da respectiva data de ocorrência, especificada em termos de ano/mês/dia/hora/minuto. Cada linha da tabela deve conter uma média horária de carga e sua respectiva data. Na Figura 9 tem-se um exemplo com as primeiras linhas da tabela com dados históricos de carga. Uma tabela contendo dados históricos de carga deverá ser construída para cada subsistema, por exemplo, CARGAHIST_SE, CARGAHIST_S, CARGAHIST_NE e CARGAHIST_N.

	A	B	C	D	E	F
1	Ano	Mês	Dia	Hora	Min	Carga
2	2015	3	27	1	0	40000
3	2015	3	27	2	0	45000
4	2015	3	27	3	0	44000
5	2015	3	27	4	0	46000
6	2015	3	27	5	0	47000

Figura 9 – Exemplo da Tabela CARGAHIST

As informações desta tabela serão fornecidas pelo ONS a partir dos dados disponíveis nas bases de dados que dão Suporte ao processo de Previsão de Carga no ONS. Caso algum dado histórico de carga seja faltante ou nulo, o valor a ser fornecido será estimado pelo PrevcargaPMO por meio de técnicas de tratamento de dados.

A tabela TEMPHIST com dados históricos de temperatura deve conter os valores médios da temperatura equivalente (°C) em intervalos horários. Adicionalmente, cada valor médio deve ser acompanhado da respectiva data de ocorrência, especificada em termos de ano/mês/dia/hora/minuto. Cada linha da tabela deve conter uma média horária de temperatura equivalente e sua respectiva data. Na Figura tem-se um exemplo com as primeiras linhas da tabela com dados históricos de temperatura equivalente. Uma tabela contendo dados históricos de temperatura deverá ser construída para cada subsistema, por exemplo, TEMPHIST_SE, TEMPHIST_S, TEMPHIST_NE e TEMPHIST_N.

	A	B	C	D	E	F
1	Ano	Mês	Dia	Hora	Min	Temperatura
2	2015	3	27	1	0	22
3	2015	3	27	2	0	23
4	2015	3	27	3	0	22
5	2015	3	27	4	0	23
6	2015	3	27	5	0	25

Figura 10 – Exemplo da Tabela TEMPHIST

As médias horárias da temperatura equivalente devem ser informadas para o mesmo período do histórico de dados de carga. Portanto, as tabelas com dados históricos de carga e temperatura devem ter o mesmo número de linhas. As informações desta tabela serão fornecidas pelo ONS a partir dos dados disponíveis nas bases de dados que dão Suporte ao processo de Previsão de Carga no ONS. Caso algum dado histórico de temperatura equivalente seja faltante ou nulo, o valor a ser fornecido será estimado pelo PrevcargaPMO por meio de técnicas de tratamento de dados.

A tabela FERIADOS com informações de feriados e dias especiais deve informar a data de cada feriado (no formato ano/mês/dia) ao longo do período do histórico de carga e o tipo do feriado/dia especial, cuja codificação deve seguir a codificação indicada na

Tabela 4. Na Figura 11 tem-se um exemplo da tabela com dados de feriados e dias especiais. Uma tabela contendo dados de feriados e dias especiais deverá ser construída para cada subsistema, por exemplo,

FERIADOS_SE, FERIADOS_S, FERIADOS_NE e FERIADOS_N. Ressalta-se que a associação dos feriados e dias especiais às séries de carga é uma atribuição do ONS e que o modelo deverá considerar a possibilidade de atualização e incorporação de novos dias especiais na previsão de carga por ele elaborada.

Tabela 4 - Codificação de feriados e dias especiais

Tipo do dia	Código
Feriado Nacional perfil de sábado	1
Feriado Nacional perfil de domingo	2
Segunda-feira da semana do Carnaval	3
Terça-feira da semana do Carnaval	4
Quarta-feira de cinzas	5
Natal e 1º de Janeiro	6
Dia após Natal e após 1º de Janeiro	7
Véspera de Natal e véspera 1º de Janeiro	8
Véspera de feriado	9
Dia após feriado	10
Dia especial e recesso	11
Blecaute, Jogos da Copa, etc.	12

	A	B	C	D
1	Ano	Mês	Dia	Tipo
2	2014	1	1	5
3	2014	1	2	7
4	2014	3	3	3
5	2014	3	4	4
6	2014	3	5	6
7	2014	4	18	1
8	2014	4	21	1

Figura 11 - Exemplo da tabela FERIADOS

A tabela HORAVERAO deve contar com as datas de início de fim do horário de verão, sendo informadas no formato ano/mês/dia para cada edição do horário de verão ao longo do período do histórico de carga, conforme indicado na Figura 1.

	A	B
1	Data Inicial	Data final
2	2015 / 10 / 18	2016 / 2 / 21
3	2016 / 10 / 16	2017 / 2 / 19

Figura 12 – Exemplo da tabela HORAVERAO

A tabela HORIZONTE deve contar as datas dos instantes inicial e final da previsão no formato ano/mês/dia/hora/minuto, datas dos feriados no período de previsão no formato ano/mês/dia acompanhadas da indicação do tipo do feriado segundo a codificação da

Tabela 4. Adicionalmente, as datas de início e fim do horário de verão mais recente podem ser informadas opcionalmente, caso estejam envolvidas no horizonte de previsão. Na Figura 3 tem-se um exemplo da tabela com informações do horizonte de previsão. Uma tabela semelhante deverá ser construída para cada subsistema, por exemplo, HORIZONTE_SE, HORIZONTE_S, HORIZONTE_NE e HORIZONTE_N.

	A	B	C	D	E	F	G
1	Variável	Ano	Mês	Dia	Hora	Minuto	Feriado/Dia Especial
2	Instante inicial da previsão	2017	6	1	0	0	
3	Data final da previsão	2017	8	4	23	59	
4	feriado	2017	6	14	0	0	9
5	feriado	2017	6	15	0	0	1
6	feriado	2017	6	16	0	0	10

Figura 13 – Exemplo da tabela HORIZONTE

A tabela TEMPPREVISTA com dados previsões de temperatura deve conter os valores médios da temperatura equivalente (°C) em intervalos horários ao longo do período de previsão. Adicionalmente, cada valor médio deve ser acompanhado da respectiva data especificada em termos de ano/mês/dia/hora/minuto. Cada linha da tabela deve conter uma média horária de temperatura equivalente e sua respectiva data. Na Tabela 14, tem-se um exemplo da tabela com as primeiras linhas contendo as temperaturas previstas para o período de previsão. Uma tabela semelhante deverá ser construída para cada subsistema, por exemplo, TEMPPREVISTA_SE, TEMPPREVISTA_S, TEMPPREVISTA_NE e TEMPPREVISTA_N.

	A	B	C	D	E	F
1	Ano	Mês	Dia	Hora	Min	Temperatura
2	2017	4	1	1	0	22
3	2017	4	1	2	0	23
4	2017	4	1	3	0	22
5	2017	4	1	4	0	23
6	2017	4	1	5	0	25

Figura 14 - Exemplo da tabela TEMPPREVISTA

As informações desta tabela serão fornecidas pelo ONS a partir dos dados disponíveis nas bases de dados que dão Suporte ao processo de Previsão de Carga no ONS.

Os dados históricos, em base horária, da geração não supervisionada (MW) devem ser informados na tabela NSUPHISTHORARIA ilustrada na Figura 15. Adicionalmente, cada valor deve ser acompanhado da respectiva data especificada em termos de ano/mês/dia/hora/minuto. Cada linha da tabela deve conter uma média horária da geração não supervisionada e sua respectiva data. Uma tabela semelhante deverá ser construída para cada subsistema, por exemplo, NSUPHISTHORARIA_SE, NSUPHISTHORARIA_S, NSUPHISTHORARIA_NE e NSUPHISTHORARIA_N.

	A	B	C	D	E	F
1	Ano	Mes	Dia	Hora	Min	Geracao
2	2014	1	1	1	0	74
3	2014	1	1	2	0	74
4	2014	1	1	3	0	75
5	2014	1	1	4	0	75
6	2014	1	1	5	0	75
7	2014	1	1	6	0	74
8	2014	1	1	7	0	74
9	2014	1	1	8	0	73
10	2014	1	1	9	0	73
11	2014	1	1	10	0	74

Figura 15 - Exemplo da tabela NSUPHISTHORARIA

As informações desta tabela serão fornecidas pelo ONS a partir dos dados disponíveis nas bases de dados que dão Suporte ao processo de Previsão de Carga no ONS.

Já os dados históricos da geração não supervisionada (MW), em base diária, devem ser informados na tabela NSUPHISTDIARIA ilustrada na Figura 16. Adicionalmente, cada valor deve ser acompanhado da respectiva data especificada em termos de ano/mês/dia/hora/minuto. Cada linha da tabela deve conter uma média diária da geração não supervisionada e sua respectiva data. Uma tabela semelhante deverá ser construída para cada subsistema, por exemplo, NSUPHISTDIARIA_SE, NSUPHISTDIARIA_S, NSUPHISTDIARIA_NE e NSUPHISTDIARIA_N.

	A	B	C	D	E	F
1	Ano	Mes	Dia	Hora	Min	Geracao
2	2017	1	1	0	0	52
3	2017	1	2	0	0	53
4	2017	1	3	0	0	47
5	2017	1	4	0	0	52
6	2017	1	5	0	0	56
7	2017	1	6	0	0	59
8	2017	1	7	0	0	56
9	2017	1	8	0	0	57
10	2017	1	9	0	0	58

Figura 16 - Exemplo da tabela NSUPHISTDIARIA

Por fim, os dados históricos, em base horária, do intercâmbio (MW) devem ser informados na tabela INTERCAMBIO ilustrada na Figura 17. Adicionalmente, cada valor deve ser acompanhado da respectiva data especificada em termos de ano/mês/dia/hora/minuto. Cada linha da tabela deve conter uma média horária do intercâmbio e sua respectiva data. Uma tabela semelhante deverá ser construída para cada subsistema, por exemplo, INTERCAMBIO_SE, INTERCAMBIO_S, INTERCAMBIO_NE e INTERCAMBIO_N.

	A	B	C	D	E	F
1	Ano	Mes	Dia	Hora	Min	Intercambio
2	2014	1	1	1	0	2233
3	2014	1	1	2	0	2170
4	2014	1	1	3	0	2182
5	2014	1	1	4	0	2191
6	2014	1	1	5	0	2128
7	2014	1	1	6	0	1983
8	2014	1	1	7	0	1351
9	2014	1	1	8	0	828
10	2014	1	1	9	0	1121

Figura 17 - Exemplo da tabela INTERCAMBIO

4.3 Execução

Acesse o R, digite `library(prevcargapmo)` e pressione a tecla *Enter* para carregar o pacote. Na sequência digite `nome_objeto_saida=previsorpmo("local dos dados","local de saída",chave1,chave2,chave3,chave4,chave5,chave6 chave7)` e pressione *Enter*. Os resultados gerados pelo programa são armazenados no objeto de saída (um objeto R tipo lista), cujo nome pode ser especificado pelo usuário. A seguir, tem-se uma descrição dos parâmetros de entrada da função `previsorpmo`:

- Em "local dos dados" informe o diretório onde estão localizados os arquivos de dados, por exemplo, "c:/pmo/dados" (atenção para as barras).
- Em "local de saída" informe o diretório onde serão armazenados os arquivos gerados pelo previsor. O diretório de saída pode ser o mesmo diretório informado para os arquivos de dados. Os parâmetros dos modelos de previsão são salvos em arquivos .rda no diretório informado em "local de saída".
- Para usar modelos SVM previamente treinados e armazenados em arquivos disponíveis em "local de saída" faça `chave1=0`. Para treinar os modelos de previsão faça `chave1=1`.
- Faça `chave2=0` para ler dados disponíveis em arquivos ".csv" e `chave2=1` para ler dados disponíveis em formato `data.frame`. No caso dos dados estarem disponíveis em `data.frames`, o campo "local de dados" deve estar preenchido com a lista (tipo de objeto em ambiente R) contendo os seguinte `data.frames`: CARGAHIST, TEMPHIST, TEMPPREV, FERIADOS, HORAVERAO, FERIADO, SEPARADOR, INTERCAMBIO, NSUPHIST, NSUPDIA, cada um correspondendo a um arquivo csv indicado na Tabela 3.
- O programa permite diferentes opções de inclusão da temperatura nos modelos de previsão, se `chave3=0` o modelo de previsão considera a máxima temperatura diária, se `chave3=1` o modelo considera a temperatura média diária e se `chave3=2` o modelo considerar as temperaturas máxima e média diárias. Faça `chave3=3` para não considerar a temperatura como variável explicativa. Adicionalmente, faça `chave3=4` para considerar as previsões da temperatura média diária ao longo do horizonte de previsão.
- Para considerar os dados de geração não supervisionada faça `chave4=1`, caso contrário faça `chave4=1`.
- Para considerar os dados de intercâmbio faça `chave5=1`, caso contrário faça `chave5=0`.
- Faça `chave6=1` se o objetivo é obter uma previsão de carga para a REVO do PMO e faça `chave6=0` para uma revisão semanal do PMO.
- Faça `chave7=1` para ativar a comparação da previsão mensal gerada pelo SVM com os intervalos de previsão com 95% de confiança gerados pelo previsor de Holt Winters.

Por exemplo, digite os seguinte comando no console do R:

```
library(prevcargapmo)
caminho="C:/entrada"
caminhosaida="C:/saída"
```

```

treinamodelo=1
tipoinput=0
tipotemp=1
naosimulada=1
intercambio=1
tipoestudo=1
resultado=previsorpmo(caminho,caminhosaida,treinamodelo,tipoinput,tipotemp,naosimulada,intercambio,tipoestudo)
    
```

Ao final da execução as previsões resultantes são apresentadas no console do R (Figura 18) e gravadas em arquivos .CSV no diretório informado em "caminhosaida", conforme descrito no comando acima. Todos os arquivos de resultados começam com os nomes PREVCARGAPMO_previsão e mostram previsões semanais, mensais, diárias e horárias para os dias que completam a semana operativa corrente, conforme indicado na Tabela 3 e ilustrado nas Figuras 19, 20, 21, 22 e 23.

```

CEPEL - Centro de Pesquisas de Energia Eletrica
PPPP RRRR EEEEE V V CCCC AAA RRRR GGGG AAA PPPP M M OOO
P P R R E E V V C A A R R G A A P P MM MM O O
PPPP RRRR EEEEE V V C A A RRRR G GG A A PPPP M M M O O
P R R E V V C AAAAA R R G G AAAAA P M M O O
P R R EEEEE V CCCC A A R R GGGG A A P M M OOO

[1] "Opcoes de execucao"
[1] "Treina modelos SVM"
[1] "Dados em arquivos CSV"
[1] "Temperatura media no modelo SVM de previsao semanal"
[1] "Com geracao nao supervisionada"
[1] "Com intercambio"
[1] "PMO REVO"
[1] "Nome da serie: SE"
[1] "CONCLUIDA LEITURA DO ARQUIVO PARAMETROS.CSV"
[1] "CONCLUIDA LEITURA DO ARQUIVO DE DADOS DE INTERCAMBIO"
[1] "Mensagem: Horizonte de previsao informado 2017-02-28"
[1] "Mensagem: Horizonte de previsao alterado para 2017-03-03"
[1] "CONCLUIDA LEITURA DO ARQUIVO C:/prevcargapmol.27/TESTEAGOSTO2018/DecksPrevCargaPMO
Temperatura/SE_TP_20161229/SE_TP_20161229_HORIZONTE.csv" - Novo Feriado e
[1] "CONCLUIDA LEITURA DO ARQUIVO C:/prevcargapmol.27/TESTEAGOSTO2018/DecksPrevCargaPMO
Temperatura/SE_TP_20161229/SE_TP_20161229_CARGAHIST.csv" - Novo Feriado e
[1] "CONCLUIDA LEITURA DO ARQUIVO C:/prevcargapmol.27/TESTEAGOSTO2018/DecksPrevCargaPMO
Temperatura/SE_TP_20161229/SE_TP_20161229_FERIADOS.csv" - Novo Feriado e
[1] "CONCLUIDA LEITURA DO ARQUIVO C:/prevcargapmol.27/TESTEAGOSTO2018/DecksPrevCargaPMO
Temperatura/SE_TP_20161229/SE_TP_20161229_HORAVERA0.csv" - Novo Feriado e
[1] "CONCLUIDA LEITURA DO ARQUIVO C:/prevcargapmol.27/TESTEAGOSTO2018/DecksPrevCargaPMO
Temperatura/SE_TP_20161229/SE_TP_20161229_TEMP HIST.csv" - Novo Feriado e
[1] "CONCLUIDA LEITURA DO ARQUIVO C:/prevcargapmol.27/TESTEAGOSTO2018/DecksPrevCargaPMO
Temperatura/SE_TP_20161229/SE_TP_20161229_TEMPPREVISTA.csv" - Novo Feriado e
[1] "CONCLUIDA LEITURA DOS ARQUIVOS DE DADOS DA GERACAO NAO SUPERVISIONADA"
[1] "TRATAMENTO DE DADOS DA GERACAO NAO SIMULADO"
[1] "AJUSTA MODELO DE PREVISAO DA GERACAO NAO SUPERVISIONADA"
[1] "PREVISAO DA GERACAO NAO SUPERVISIONADA"
[1] "=====
[1] "PREVISOES DA GERACAO NAO SUPERVISIONADA EM BASE DIARIA"
[1] "=====
Geracao nao supervisionada diaria MW medio
2016-12-23 3034.455
2016-12-24 3000.127
2016-12-25 2937.898
2016-12-26 2875.310
2016-12-27 2843.103
2016-12-28 2838.770
2016-12-29 2804.550
    
```

```

2016-12-30                2745.169
[1] "=====
[1] "PREVISOES DA GERACAO NAO SUPERVISIONADA EM BASE SEMANAL"
[1] "=====
      Geracao nao supervisionada semanal MW
2016-11-18                4007.387
2016-11-25                4118.175
2016-12-02                3922.051
2016-12-09                3583.178
2016-12-16                3528.322
2016-12-23                3439.773
2016-12-30                2863.561
[1] "TRATAMENTO DE DADOS"
[1] "PREVISAO PARA COMPLETAR A SEMANA CORRENTE"
[1] "MONTAGEM DA SERIE DE CARGA GLOBAL"
[1] "PREVISAO SEMANAL DA CARGA GLOBAL"
[1] "PREVISAO MENSAL DA CARGA GLOBAL"
[1] "mensagem: PMO"
[1] "GRAVANDO ARQUIVOS DE SAIDA"
[1] "==== Previsoes Mensais da Carga Global MW ====
dezembro/2016  janeiro/2017  fevereiro/2017
      37507.37      38014.80      37843.12
    
```

Figura 18 - Previsões resultantes apresentadas no console do R

```

[1] "==== Previsoes da Carga Global MW - abertas para o primeiro mes ====
      MW Dias
2017-01-01 30840.60  1
2017-01-02 36058.91  1
2017-01-03 37825.40  1
2017-01-04 39026.78  1
2017-01-05 40655.60  1
2017-01-06 41034.18  1
2017-01-13 38632.42  7
2017-01-20 38773.29  7
2017-01-27 38164.59  7
2017-01-31 36006.29  4
janeiro 38014.80 31
[1] "==== Previsoes Semanais da Carga Global MW ====
2016-12-30 2017-01-06 2017-01-13 2017-01-20 2017-01-27 2017-02-03 2017-02-10
37940.06 37629.21 38632.42 38773.29 38164.59 36006.29 41588.01
[1] "==== Previsoes Diarias MW - completam semana operativa corrente ====
      Geracao Nao Supervisionada MW Geracao Supervisionada MW Carga Global MW
2016-12-29      2804.550      37369.69      40174.24
2016-12-30      2745.169      37659.90      40405.06
[1] "==== Previsoes Horarias da Geracao Supervisionada MW - completam semana operativa corrente ====
      2016-12-29 2016-12-30
Hora.1 33109.09 34034.82
Hora.2 30887.36 31798.83
Hora.3 29618.53 30548.40
Hora.4 29010.81 29946.89
Hora.5 29066.26 29964.50
Hora.6 30240.25 31135.75
Hora.7 31842.98 32831.66
Hora.8 34230.42 35069.02
Hora.9 37489.00 38257.74
Hora.10 39671.85 40341.81
Hora.11 41165.65 41760.09
Hora.12 41421.72 41941.43
Hora.13 41004.36 41305.85
Hora.14 42131.92 42294.80
Hora.15 42931.60 42986.46
Hora.16 43053.33 42950.51
Hora.17 42583.94 42296.87
Hora.18 40522.52 40291.30
Hora.19 38147.82 38016.94
Hora.20 38778.67 39041.88
Hora.21 41093.96 40411.98
Hora.22 41023.31 40180.02
Hora.23 40223.51 39408.65
    
```

Hora.24 37623.59 37021.28
 [1] "Execucao realizada com sucesso"

Figura 18 - Previsões resultantes apresentadas no console do R (continuação)

4.4 Resultados gerados pelo Modelo

Os resultados gerados pelo previsor são organizados em cinco arquivos no formato texto ".csv" e em formato *data.frame*. Os nomes e conteúdos dos arquivos ".csv" são apresentados na Tabela 5.

Tabela 5 – Conteúdo das tabelas de saída do modelo

Conteúdo da arquivo	Nome do arquivo csv
Previsões diárias de carga média supervisionada para os dias que complementam a semana operativa corrente	PREVCARGAPMO_previsao_diaria_geracao_despachada.csv
Previsões das médias diárias da geração não supervisionada, e da carga global	PREVCARGAPMO_previsao_diaria_MW.csv
Previsões semanais de carga média global para as 6 semanas subseqüentes à semana operativa corrente	PREVCARGAPMO_previsao_semanal_carga_global.csv
Previsões mensais de carga média global para 2 meses à frente	PREVCARGAPMO_previsao_mensal_carga_global.csv
Previsão mensal da carga média global para o primeiro mês aberta por dias e semana	PREVCARGAPMO_previsao_carga_global_mes_1_aberta.csv
Previsão mensal da carga média global obtida pelo método de Holt WInters	PREVCARGAPMO_HW_MENSAL.csv
Previsão semanal da carga média global obtida pelo método da decomposição	PREVCARGAPMO_HW_SEMANAL.csv

O arquivo PREVCARGAPMO_previsao_diaria_geracao_despachada.csv (Figura 20) contém as previsões horárias da carga média nos dias complementares à semana operativa.

Já o arquivo PREVCARGAPMO_previsao_diaria_MW.csv contém as previsões das médias diárias da geração não supervisionada, geração supervisionada e da carga global (Figura 21). As previsões semanais da carga global disponibilizadas no arquivo PREVCARGAPMO_previsao_semanal_carga_global.csv são apresentadas na Figura 22.

O arquivo PREVCARGAPMO_previsao_mensal_carga_global.csv (Figura 23) apresenta previsões mensais da carga média global até dois meses à frente, enquanto o arquivo PREVCARGAPMO_previsao_carga_global_mes_1_aberta.csv (Figura 24) mostra a desagregação semanal da previsão da carga global para o primeiro mês do horizonte de previsão.

Já as previsões semanais e mensais obtidas pelos métodos de séries temporais e acompanhadas pelos intervalos de confiança podem ser visualizadas nos arquivos PREVCARGAPMO_HW_SEMANAL.csv (Figura 25) e PREVCARGAPMO_HW_MENSAL.csv (Figura 26) respectivamente. Ressalta-se que as previsões semanais apresentadas pelo programa são as obtidas pela abordagem SVM, as previsões calculadas pelo método da decomposição clássica servem apenas como referência.

Caso o horizonte de previsão faça parte do período de dados históricos (situação de avaliação do desempenho do modelo), a planilha também carrega os resultados "OUTSAMPLE", que são apresentados nas planilhas "SAIDA_DIARA_OUTSAMPLE", "SAIDA_SEMANAL_OUTSAMPLE" e "SAIDA_MENSAL_OUTSAMPLE" com os desvios relativos (%) e absolutos (MW) entre os valores verificados e previstos.

Para ilustrar o acesso aos resultados no formato *data.frame* considere os seguintes comandos para execução do PrevCargaPMO no ambiente R:

```
library(prevcargapmo)
caminho="C:/entrada"
caminhosaida="C:/saida"
treinamodelo=1
```

```
tipoinput=0
tipotemp=1
naosimulada=1
intercambio=1
tipoestudo=1
resultado=previsorpmo(caminho,caminhosaida,treinamodelo,tipoinput,tipotemp,naosimulada,intercambio,tipoestudo)
```

O objeto *resultado* guarda todos os resultados gerados pelo programa no formato data.frame, conforme ilustrada na Figura 19.

```
> names(resultado)
[1] "MENSALGLOBAL" "PRIMEIROMESGLOBAL" "SEMANALGLOBAL" "DIARIA" "HORARIADESPACHADA" "NDESPSEMANAL" "NDESPDIARIA"
```

Figura 19 - *Data.frames* gerados após a execução do programa

Para acessar cada um dos resultados no formato *data.frame* deve-se digitar os seguintes comandos:

```
resultado$MENSALGLOBAL
resultado$PRIMEIROMESGLOBAL
resultado$SEMANALGLOBAL
resultado$DIARIA
resultado$HORARIADESPACHADA
resultado$NDESPSEMANAL
resultado$NDESPDIARIA
resultado$HWSEMANAL
resultado$HWMENSAL
```

```
> t(resultado$HORARIADESPACHADA)
      2016-12-29 2016-12-30
Hora.1 33454.63 31767.47
Hora.2 31211.57 29681.19
Hora.3 29929.56 28513.89
Hora.4 29315.71 27953.07
Hora.5 29371.22 27969.44
Hora.6 30557.07 29062.43
Hora.7 32175.91 30645.00
Hora.8 34587.28 32732.38
Hora.9 37878.04 35708.06
Hora.10 40082.51 37652.73
Hora.11 41591.13 38976.30
Hora.12 41849.89 39145.21
Hora.13 41428.31 38552.16
Hora.14 42567.06 39475.06
Hora.15 43374.63 40120.59
Hora.16 43497.42 40087.21
Hora.17 43024.11 39477.28
Hora.18 40941.85 37606.00
Hora.19 38543.72 35483.48
Hora.20 39180.40 36440.04
Hora.21 41518.56 37718.77
Hora.22 41447.50 37502.34
Hora.23 40640.13 36782.74
Hora.24 38014.82 34554.82
```

	A	B	C
1	Hora	29/12/2016	30/12/2016
2	1	33,455	31,767
3	2	31,212	29,681
4	3	29,930	28,514
5	4	29,316	27,953
6	5	29,371	27,969
7	6	30,557	29,062
8	7	32,176	30,645
9	8	34,587	32,732
10	9	37,878	35,708
11	10	40,083	37,653
12	11	41,591	38,976
13	12	41,850	39,145
14	13	41,428	38,552
15	14	42,567	39,475
16	15	43,375	40,121
17	16	43,497	40,087
18	17	43,024	39,477
19	18	40,942	37,606
20	19	38,544	35,483
21	20	39,180	36,440
22	21	41,519	37,719
23	22	41,448	37,502
24	23	40,640	36,783
25	24	38,015	34,555

Figura 20 – Previsão horária da geração supervisionada para os dias que completam a semana corrente, arquivo PREVCARGAPMO_previsao_diaria_geracao_despachada.csv

	A	B	C	D
1		Geracao Nao Supervisionada MW	Geracao Supervisionada MW	Carga Global MW
2	29/12/2016	2795	37758	40552
3	30/12/2016	2665	35150	37816

> resultado\$DIARIA

	Geracao Nao Supervisionada MW	Geracao Supervisionada MW	Carga Global MW
2016-12-29	2794.809	37757.63	40552.44
2016-12-30	2665.221	35150.32	37815.54

Figura 21 – Previsão da média diária da geração não supervisionada, supervisionada e da carga global semana corrente, arquivo PREVCARGAPMO_previsao_diaria_MW.csv

	A	B	C
1	inicio	fim	Demanda Media MW
2	24/12/2016	30/12/2016	37657
3	31/12/2016	06/01/2017	38482
4	07/01/2017	13/01/2017	38823
5	14/01/2017	20/01/2017	38776
6	21/01/2017	27/01/2017	38208
7	28/01/2017	03/02/2017	38861
8	04/02/2017	10/02/2017	40766

> resultado\$SEMANALGLOBAL

2016-12-30	2017-01-06	2017-01-13	2017-01-20	2017-01-27	2017-02-03	2017-02-10
37657.20	38482.15	38822.86	38775.74	38208.09	38861.45	40766.27

Figura 22 – Previsões semanais da carga global, arquivo PREVCARGAPMO_previsao_semanal_carga_global.csv

> resultado\$MENSALGLOBAL

dezembro/2016	janeiro/2017	fevereiro/2017
37539.22	38634.13	39931.16

	A	B
1		previsao.demanda.media.mensal.MW
2	dez/16	37539
3	jan/17	38634
4	fev/17	39931

Figura 23 – Previsões mensais da carga global, arquivo PREVCARGAPMO_previsao_mensal_carga_global.csv

> resultado\$PRIMEIROMESGLOBAL				A	B	C
	MW	Dias			Previsoes parciais MW	Pesos
2017-01-01	33696.69	1	1			
2017-01-02	39784.13	1	2	01/01/2017	33697	1
2017-01-03	40501.37	1	3	02/01/2017	39784	1
2017-01-04	38340.37	1	4	03/01/2017	40501	1
2017-01-05	40381.74	1	5	04/01/2017	38340	1
2017-01-06	41030.13	1	6	05/01/2017	40382	1
2017-01-13	38822.86	7	7	06/01/2017	41030	1
2017-01-20	38775.74	7	8	13/01/2017	38823	7
2017-01-27	38208.09	7	9	20/01/2017	38776	7
2017-01-31	38319.19	4	10	27/01/2017	38208	7
janeiro	38634.13	31	11	31/01/2017	38319	4
			12	janeiro	38634	31

Figura 24 – Previsão da carga global para o primeiro mês aberta em semanas, arquivo PREVCARGAPMO_previsao_carga_global_mes_1_aberta.csv

> resultado\$HWMENSAL								A	B	C	D	E
	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95			Point.Forecast	Lo.80	Hi.80	Lo.95	Hi.95
Jan 2017	38432.32	37809.93	39022.50	37516.64	39336.63	1		38432	37810	39023	37517	39337
Feb 2017	39283.75	38601.56	39947.64	38207.99	40326.28	2		39284	38602	39948	38208	40326
						3						

Figura 25 – Previsões mensais da carga global e intervalos de confiança gerados pelo método de Holt-Winters, arquivo PREVCARGAPMO_HW_MENSAL.csv

	A	B	C	D	E	
1	Previsao Semanal HoltWinters	Lower 80%	Lower 95%	Upper 80%	Upper 95%	
2		38852	37586	36916	40118	40788
3		40724	39374	38659	42074	42789
4		39781	38351	37595	41210	41966
5		40368	38864	38067	41872	42669
6		41160	39585	38750	42736	43570
7		40544	38900	38030	42189	43059

> resultado\$HWSEMANAL						
	Previsao Semanal HoltWinters	Lower 80%	Lower 95%	Upper 80%	Upper 95%	
1		38852.10	37586.06	36915.86	40118.14	40788.34
2		40724.06	39373.92	38659.20	42074.20	42788.93
3		39780.51	38351.20	37594.57	41209.82	41966.46
4		40367.93	38863.60	38067.26	41872.25	42668.59
5		41160.36	39584.58	38750.41	42736.14	43570.31
6		40544.41	38900.27	38029.91	42188.55	43058.90

Figura 26 – Previsões semanais da carga global geradas pelo método da decomposição clássica de séries temporais, arquivo PREVCARGAPMO_HW_SEMANAL.csv

Caso o horizonte de previsão faça parte do período contido nos arquivos de dados históricos; i.e., quando existirem dados verificados de carga para o horizonte de previsão, o modelo de previsão também gera outras três tabelas com resultados do treinamento do modelo. Para a execução nesta modalidade deve-se disponibilizar dados verificados de carga e temperatura até a sexta-feira da última semana operativa do período avaliado que deve ser de pelo menos dois meses. Estas tabelas fornecem informações sobre o desempenho das previsões segundo as métricas de desempenho MAD (*Mean Absolute Deviation*) e MAPE (*Mean Absolute Percentage Error*), que são descritas pelas equações (84) e (85). O conteúdo das tabelas de saída adicionais pode ser verificado na Tabela 6.

$$MAD = \frac{\sum_{i=1}^N |x_i - x_i^p|}{N} \tag{84}$$

$$MAPE = \frac{\sum_{i=1}^N \left| \frac{(x_i - x_i^p)}{x} \right|}{N} * 100 \tag{85}$$

em que x_i é o valor verificado, x_i^p é o valor previsto e N é o número de observações.

Tabela 6 - Conteúdo das tabelas de saída adicionais do modelo

Conteúdo da Tabela	Nome da Tabela / Arquivo
Previsões diárias de carga média complementares à semana operativa corrente acompanhadas dos erros MAD e MAPE do período.	PREVISAO_DIARIA_OUTSAMPLE
Previsões semanais de carga média para as 5 semanas subsequentes à semana operativa corrente acompanhadas dos erros MAD e MAPE do período.	PREVISAO_SEMANAL_OUTSAMPLE
Previsões mensais de carga média para 2 meses à frente acompanhadas dos erros MAD e MAPE do período.	PREVISAO_MENSAL_OUTSAMPLE

As Figuras 27, 28 e 29 ilustram, respectivamente, um exemplo de saída das tabelas listadas na Tabela 6 PREVISAO_DIARIA_OUTSAMPLE, PREVISAO_MENSAL_OUTSAMPLE e PREVISAO_MENSAL_OUTSAMPLE.

	A	B	C	D	E
1	HORAS	X2017.07.07	verificado	Erro.relATIVO.percentage	Erro.MW
2	Hora.1	9722	9240	5.212	- 481.59
3	Hora.2	9364	8936	4.791	- 428.13
4	Hora.3	9153	8764	4.433	- 388.53
5	Hora.4	9040	8668	4.294	- 372.21
6	Hora.5	9005	8585	4.896	- 420.33
7	Hora.6	8868	8543	3.806	- 325.16
8	Hora.7	8710	8287	5.109	- 423.41
9	Hora.8	9543	8932	6.840	- 610.92
10	Hora.9	10417	9622	8.265	- 795.26
11	Hora.10	10861	9912	9.577	- 949.23
12	Hora.11	11107	10048	10.538	- 1,058.85
13	Hora.12	11036	9993	10.440	- 1,043.23
14	Hora.13	10775	9745	10.569	- 1,029.90
15	Hora.14	11024	10012	10.109	- 1,012.09
16	Hora.15	11238	10301	9.101	- 937.47
17	Hora.16	11180	10297	8.574	- 882.89
18	Hora.17	10907	10218	6.744	- 689.07
19	Hora.18	10753	10318	4.213	- 434.65
20	Hora.19	11065	10543	4.953	- 522.20
21	Hora.20	10745	10194	5.404	- 550.92
22	Hora.21	10548	9885	6.711	- 663.38
23	Hora.22	10998	10379	5.965	- 619.09
24	Hora.23	10770	10177	5.828	- 593.11
25	Hora.24	10280	9785	5.059	- 495.07

Figura 27 – Exemplo de saída da tabela PREVISAO_DIARIA_OUTSAMPLE

	A	B	C	D	E
1	SEMANAS.1.6.	previsto	verificado	Erro.relATIVO.percentage	Erro.MW
2	2017-07-08 2017-07-14	9412	9382	0.318	- 29.9
3	2017-07-15 2017-07-21	9473	9426	0.506	- 47.7
4	2017-07-22 2017-07-28	9476	9299	1.904	- 177.0
5	2017-07-29 2017-08-04	9600	9298	3.253	- 302.5
6	2017-08-05 2017-08-11	9542	9637	0.992	95.6
7	2017-08-12 2017-08-18	9555	9649	0.979	94.5

Figura 28 – Exemplo da tabela de saída PREVISAO_SEMANAL_OUTSAMPLE

	A	B	C	D	E
1	MESES	previsto	verificado	Erro.relATIVO.percentage	Erro.MW
2	julho	9454	9311	0.015	-143.08
3	agosto	9576	9665	0.930	89.86

Figura 29 – Exemplo da tabela de saída PREVISAO_MENSAL_OUTSAMPLE

Referências bibliográficas

Baghel. M.; Ghosh, A.; Singh, N.K.; Singh, A.K. Short –Term Electric Load Forecasting Using SVR Implementing LibSVM Package and Python Code, Electrical, Computer and Electronics Engineering (UPCON), 2016 IEEE Uttar Pradesh Section International Conference on, 9-11 December, 2016

Bakirtzis, A.G.; Petridis, V.; Klartzis, S.J.; Alexladis, M.C.; Maissis. A. A neural network short term load forecasting model for the Greek power system, IEEE Transactions on Power Systems, v. 11, n. 2, May, 1996.

Bozic, M; Stojonavic, M. Application of SVM Methods for Mid-Term Load Forecasting, Serbian Journal Of Electrical Engineering, Vol. 8, No. 1, pages 73-83, February 2011.

Buhagiar, J. Automatic Segmentation of Indoor and Outdoor scenes from Visual Lifelogging, Faculty of ICT, University of Malta, 2017.

Chen, S.T.; Yu,D.C.; Moghaddamjo, A.R. Weather sensitive short-term load forecasting using nonfully connected artificial neural network, Transactions on Power Systems, v.7, n.3, pp. 1098-1105, August, 1992.

Chen, B.J.; Chang, M.W.; Lin, C.J. Load forecasting using support vector machines: a study on EUNITE Competition 2001, IEEE Transactions on power systems, v. 19, n. 4, November 2004.

Ceperic, E; Ceperic, V; Baric, A. A Strategy for Short-Term Load Forecasting by Support Vector Regression Machines, IEEE Transactions on Power Systems, Volume: 28, Issue: 4, pages 4356 – 4364, November 2013.

Domingos, P. The Master Algorithm: how the quest for the ultimate learning machine will remake our world, Basic Books, 2015

Fortunato, L.A.M.; Neto, T.A.A.; Albuquerque, J.C.R.; Pereira, M.V.F. Introdução ao Planejamento da Expansão e Operação de Sistemas de Produção de Energia Elétrica, Niterói, Universidade Federal Fluminense, EDUFF,1990.

Gross, G; Galiana, F.D. Short-Term Load Forecasting, Proceedings of IEEE, vol. 75, no. 12, pp. 1558 – 1573, Dec. 1987.

Grus, J. Data science do zero: primeiras regras com o Python, Rio de Janeiro: Alta Books, 2016.

Hahn, H.; Meyer-Nieberg, S.; Pickl, S. Electric load forecasting methods: Tools for decision making, European Journal of Operational Research, 199, pp. 902–907, 2009.

Hamel, L. Knowledge discovery with support vector machines, Wiley, 2009.

Hippert, H.S., Pedreira, C.E., Souza, R.C. Neural Networks for Short-Term Load Forecasting: A review and evaluation, IEEE Transactions on Power Systems, v. 16, n. 1, February, 2001.

Hong,W.C. Electric load forecasting by support vector model, Applied Mathematical Modelling Volume 33, Issue 5, Pages 2444-2454, May 2009.

Hyndman, R., Khandakar, Y. Automatic time series forecasting: The forecast package for r. Journal of Statistical Software 27 (1), 1–22, 2008.

Kodogiannis, V.S.; Anagnostakis, E.M. A study of advanced learning algorithms for short-term load forecasting, Engineering Applications of Artificial Intelligence 12, pp. 159 - 173, 1999

Liao, G.C.; Tsao, T.P. Application of fuzzy neural networks and artificial intelligence for load forecasting, Electric Power Systems Research 70, pp. 237–244, 2004.

Lotufo, A.D.P.; Minussi, C.R. Electric power systems load forecasting: a survey, Powertech, Budapest, 1999.

Martinez, W.L.; Martinez, A.R. Computational statistics handbook with matlab, Chapman & Hall/CRC, 2002.

Mastorocostas, P.A.; Theocharis, J.B.; Bakirtzis, A.G. Fuzzy modeling for short-term load forecasting using the orthogonal least squares method, IEEE, Transactions on Power Systems, vol. 14, n.1, february, 1999.

Moreno-Torres, J.G.; Saez, J.A.; Herrera, F. Study on the Impact of Partition-Induced Dataset Shift on k-Fold Cross-Validation, IEEE Transactions on Neural Networks and Learning Systems Volume: 23, Issue: 8, August 2012.

Niu, D.X.; Wang, Y.L. Support Vector Machines Based on Data Mining Technology in Power Load Forecasting, International Conference on Wireless Communications, Networking and Mobile Computing, Shanghai, China, September, 2007.

Park, H.Y.; Lee, B.H.; Son, J.H.; Ahn, H.S.; A comparison of neural network-based methods for load forecasting with selected input candidates, PowerTech, 2017 IEEE Manchester, 18-22 Jun , 2017.

Pessanha, J.F.M.; Justino, T.C. Uma Metodologia para Previsão de Carga no Curto-Prazo. XIII Simpósio de Especialistas em Planejamento da Operação e Expansão Elétrica, Foz do Iguaçu, 2014.

Pessanha, J.F.; Xavier, V.L.; Amaral, M.R.S.; Laurencel, L.C. Construindo tipologias de curvas de carga com o programa R, Pesquisa Operacional para o Desenvolvimento, v. 7, n. 1, 2015.

R Core Team, R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>, 2017

Smola, A.J; Scholkopf, B. A Tutorial on Support Vector Regression, Journal Statistics and Computing, Volume 14 Issue 3, Pages 199-222, August 2004.

Turkay, B.E.; Demren,D. Electrical load forecasting using support vector machines, Electrical and Electronics Engineering (ELECO), 2011 7th International Conference on, December 2011.

Vapnik, V.N.; Boser, E.B.; Guyon, I.M.; Training Algorithm for Optimal Margin Classifiers, Proceedings of the fifth annual workshop on Computational learning theory, Pages 144-152, Pennsylvania, July 1992.

Wang, J.H.; Wu, L.; Lu, H.Y. Special periods peak load analysis and superior forecasting method based on LS-SVM, International Conference on Wavelet Analysis and Pattern Recognition, Beijing, China, 2-4 November. 2007.

Xu, H.; Wang, J.H.; Zheng, S.Q. Online daily load forecasting based on support vector machines, Proceedings of the Fourth International Conference on Machine Learning and Cybernetics, Guangzhou, 18-21 August 2005

Yadav, S.; Shukla, S. Analysis of k-Fold Cross-Validation over Hold-Out Validation on Colossal Datasets for Quality Classification, Advanced Computing (IACC), 2016 IEEE 6th International Conference on, February 2016.

Yu, P.S.; Chen, S.T.; Chang, I.F. Support vector regression for real-time flood stage forecasting, Journal of Hydrology, 328 (3-4), pp. 704-716, September, 2006.

Zhang, G.; Patuwo, B.E.; Hu, M.Y. Forecasting with artificial neural networks: The state of the art, International Journal of Forecasting, 14, pp. 35-62, 1998.

Apêndice A – Relatório de Desempenho

Ao longo do desenvolvimento do PrevCargaPMO foram realizadas diversas avaliações de desempenho com o objetivo de identificar problemas e as respectivas soluções capazes de obter previsões mais precisas. A avaliação de desempenho do PrevCargaPMO requer um grande esforço computacional, pois envolve a execução e análise de um expressivo número de casos. Neste relatório apresenta-se o resultado da avaliação de desempenho da última versão do PrevCargaPMO (versão 1.34).

A avaliação de desempenho contou com dados disponibilizados pelo ONS para os subsistema Norte, Nordeste, Sul e Sudeste ao longo do período entre janeiro e dezembro de 2017, um total de 196 casos, 49 para cada subsistema, sendo 11 casos de REVO e 38 de revisões semanais. Vale ressaltar que os conjuntos de dados cobrem um período de pouco mais de três anos.

O desempenho foi avaliado por meio das métricas MAPE (média do erro relativo %), MAD (média do erro absoluto MW) e uma variação do U-Theil (um métrica de desempenho relativo), na qual o resultado do PrevCargaPMO é comparado com uma previsão de referência obtida pelo método da decomposição clássica (STL) para as previsões semanais e de Holt Winters para as previsões mensais. Um valor menor que a unidade para o UTheil significa que o PrevCargaPMO apresenta um resultado superior ao método utilizado na previsão de referência. As métricas de desempenho são descritas a seguir:

$$MAPE \% = \sum_{t=1}^{\text{Horizonte}} \text{abs} \left(\frac{\text{Previsão}_t - \text{Verificado}_t}{\text{Verificado}_t} \right) \square 100\% \quad (\text{A.1})$$

$$MAD = \sum_{t=1}^{\text{Horizonte}} \text{abs}(\text{Previsão}_t - \text{Verificado}_t) \quad (\text{A.2})$$

$$U - Theil = \frac{\sum_{t=1}^{\text{Horizonte}} (\text{Previsão}_t - \text{Verificado}_t)^2}{\sum_{t=1}^{\text{Horizonte}} (\text{Previsão_referência}_t - \text{Verificado}_t)^2} \quad (\text{A.3})$$

A análise de desempenho foi conduzida por meio de um programa em ambiente R, desenvolvido especificamente para esta finalidade. Adicionalmente, adotou-se como padrão de qualidade as previsões com erros menores que 3%.

Em todas as execuções do PrevCargaPMO foram considerados os dados de intercâmbio, geração não supervisionada, previsão de temperatura horária para a primeira semana do horizonte de previsão e comparação das previsões geradas pelo SVM com as previsões geradas pelos métodos da decomposição clássica (previsão semanal) e Holt Winters (previsão mensal).

De forma resumida, o PrevCargaPMO monta a série diária da carga global e a partir dela produz previsões de carga para diferentes horizontes: previsões diárias para completar a semana corrente, previsões semanais até 6 semanas à frente e previsões mensais até 2 meses à frente. Ao final, o PrevCargaPMO faz uma compatibilização da previsões para o primeiro mês com as previsões semanais no período do primeiro mês. O presente relatório tem por finalidade avaliar a qualidade das previsões semanais e mensais geradas pelo PrevCargaPMO.

Vale destacar que nas previsões semanais o PrevCargaPMO gera três previsões para cada semana do horizonte, duas previsões obtidas a partir de dois modelos SVM com especificações distintas e uma previsão calculada pelo método da decomposição clássica, um método estatístico simples e útil na geração de intervalos de previsão. Os modelos SVM levam em conta variáveis explicativas, por exemplo, as previsões de temperatura (apenas para a primeira semana do horizonte) e a presença de feriados na semana. Por esta razão as previsões geradas pelo SVM têm prioridade e fazem parte dos resultados apresentados pelo PrevCargaPMO. Contudo, o PrevCargaPMO também gera arquivos de saída com as previsões semanais e intervalos de previsão calculados pelo método da decomposição clássica.

As previsões obtidas pelo modelo de decomposição clássica servem de referência na escolha da melhor previsão SVM entre as duas previsões disponíveis. As previsões geradas pelo método de decomposição clássica também

são úteis no cálculo da estatística U-Theil, uma estatística que permite comparar o desempenho da previsão apresentada pelo PrevCargaPMO e a previsão obtida pelo método da decomposição clássica.

No caso das previsões mensais, a abordagem de Holt-Winters fornece as previsões de referência e intervalos de previsão a serem comparados com as previsões geradas por um único modelo SVM. Caso a previsão gerada pelo modelo SVM situe-se fora dos limites do intervalo de confiança, o PrevCargaPMO assume que a previsão é igual ao limite do intervalo de confiança mais próximo da previsão SVM. Caso a previsão mensal esteja situada dentro do intervalo de previsão o PrevCargaPMO escolhe a previsão que resulte em um crescimento mais próximo de um fator sazonal calculado com base em um modelo de regressão linear. As previsões mensais e intervalos de previsão gerados pelo método de Holt-Winters também são gravadas em arquivos após a execução do PrevCargaPMO.

Ressalta-se que as previsões semanais com dias no primeiro mês do horizonte de previsão são ajustadas com o objetivo de compatibilizar as previsões semanais e a previsão mensal para o primeiro mês.

A seguir, para cada subsistema apresentam-se as métricas de desempenho segregadas por tipo de revisão: REV0 e demais revisões.

A1. Resultados para o subsistema Norte

A1.1 Resultados para REV0

Na Tabela A1 apresentam-se os valores de MAPE e U-Theil para as previsões mensais referentes aos 12 casos do conjunto REV0 do subsistema Norte. Observa-se que em apenas dois meses o U-Theil assume valor maior que 1, i.e., em geral, no período avaliado as previsões mensais produzidas pelo PrevCargaPMO foram melhores que as previsões obtidas pelo método de Holt-Winters. Os maiores erros de previsão nos meses 1 e 2 do horizonte de previsão foram da ordem de 3,4% e 4,4% respectivamente. Porém, na média, os erros relativos (MAPE) foram de 1,5% e 2,0% para os meses 1 e 2 respectivamente. Conforme ilustrado nos resultados, um U-Theil menor que 1 não necessariamente implica em menores erros. Na Tabela A1 as células em amarelo correspondem aos erros relativos entre 3% e 4% e as células em vermelho aos erros acima de 4%.

Tabela A1 - Erros relativos e MAPE (%) para os casos REV0 no subsistema Norte

Data da REV 0	Mês Corrente	Previsão 1 mês à frente	Previsão 2 meses à frente	U-Theil
25/01/2017	1.1755	0.3358	4.4221	0.2222
22/02/2017	0.8706	3.3615	0.2117	0.6769
29/03/2017	0.4221	2.9079	3.0154	0.4626
26/04/2017	0.0372	1.1813	1.2105	0.2012
24/05/2017	0.2486	0.0340	2.2611	0.7993
28/06/2017	0.0875	2.4264	2.7355	1.0002
26/07/2017	0.2326	0.2256	2.1651	0.5690
23/08/2017	0.0122	2.0999	1.1219	0.9114
27/09/2017	0.2749	0.2743	0.0526	0.0309
25/10/2017	0.2287	1.5598	0.9411	0.9243
22/11/2017	1.7096	2.1159	3.6704	0.9346
27/12/2017	1.8053	2.4638	4.3411	1.0883
Média (MAPE)	0.5921	1.5822	2.1790	0.6517
Mediana	0.2617	1.8298	2.2131	0.7381
Máximo	1.8053	3.3615	4.4221	1.0883
Mínimo	0.0122	0.0340	0.0526	0.0309

Já na Tabela A2 apresentam-se os valores de MAD (MW) para as previsões mensais referentes aos 12 casos do conjunto REV0 do subsistema Norte.

Tabela A2 - Erros absolutos e MAD (MW) para os casos REV0 no subsistema Norte

Data da REV 0	Mês Corrente	Previsão 1 mês à frente	Previsão 2 meses à frente
25/01/2017	60.3068	17.6206	242.5813
22/02/2017	45.6898	184.3984	11.3860
29/03/2017	23.1537	156.3640	171.4352
26/04/2017	1.9978	67.1596	67.1261
24/05/2017	14.1323	1.8829	121.5254
28/06/2017	4.8544	130.4102	154.5428
26/07/2017	12.5012	12.7475	123.4549
23/08/2017	0.6910	119.7333	63.7479
27/09/2017	15.6726	15.5852	2.9540
25/10/2017	12.9959	87.6181	51.1015
22/11/2017	96.0284	114.8923	196.3537
27/12/2017	98.0271	131.8047	237.8497
Média (MAD)	32.1709	86.6847	120.3382
Mediana	14.9025	101.2552	122.4902
Máximo	98.0271	184.3984	242.5813
Mínimo	0.6910	1.8829	2.9540

A seguir, na Figura A1, apresentam-se as previsões semanais para as 12 REV0 do subsistema Norte. A primeira semana é a semana corrente, as demais correspondem ao horizonte de previsão. As previsões de temperatura são disponibilizadas apenas para a segunda semana.

Figura A1 Previsões semanais e respectivas métricas para as REV0 do subsistema Norte

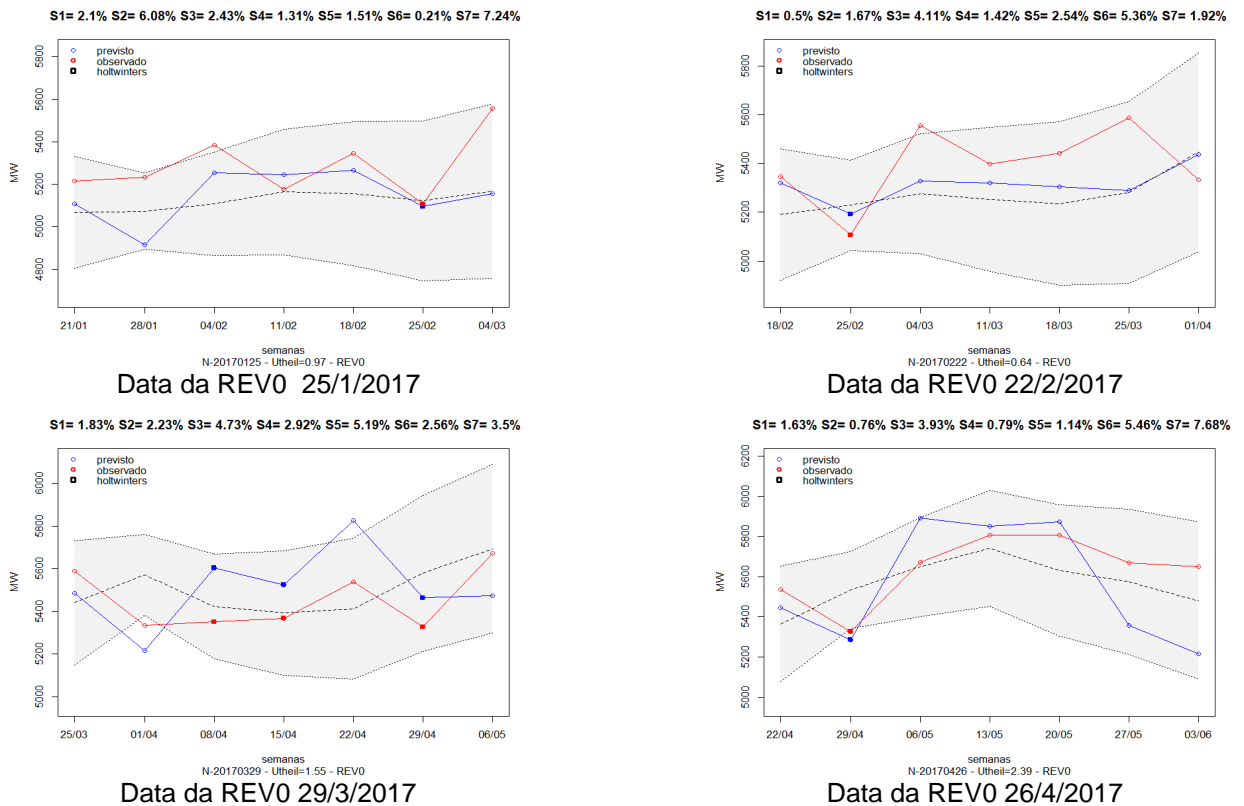










Figura A1 Previsões semanais e respectivas métricas para as REV0 do subsistema Norte (continuação)



Na Figura A1, as datas indicadas nos eixos das abscissas correspondem às datas de início das semanas operativas. A previsão gerada com base no método da decomposição clássica (STL) é representada pela linha tracejada no meio da região definida pelos limites dos intervalos de confiança, tal previsão é utilizada como referência no cálculo da estatística U-Theil. Adicionalmente, na Figura A1 os pontos marcados com quadrados indicam semanas com feriados. Conforme indicado na Figura A1 e na Tabela A3, em 3 dos 12 casos analisados o U-Theil foi menor que a unidade, i.e., em termos globais o método da decomposição clássica gerou previsões semanais melhores que as obtidas pelo PrevCargaPMO, apesar das informações de temperatura (para a primeira semana) e tipos de dias (feriados e dias especiais) em cada semana. Vale ressaltar que entre as duas previsões semanais apresentadas na Figura A1 (linhas em azul e tracejada), apenas as previsões semanais apresentadas pelo PrevCargaPMO (em azul) são compatibilizadas com a previsão mensal para o primeiro mês. Ainda conforme ilustrado na Figura A1, na maior parte das vezes, os intervalos de previsão com 95% gerados pelo método da decomposição clássica cobrem os valores verificados e as previsões geradas pelo PrevCargaPMO. Os valores apresentados na Tabela A3 indicam um MAPE de 2,36% na semana 1 (primeira semana do horizonte de previsão). Conforme ilustrado na Figura A1 e na Tabela A3, o PrevCargaPMO apresenta um bom resultado para a primeira semana, com exceção dos meses de Janeiro, Setembro e Novembro, nestes a decomposição clássica apresentou resultados superiores. Na sequência, na Tabela A4, apresentam-se os erros absolutos e MAD (MW) das previsões semanais.

Tabela A3 - Erros relativos e MAPE (%) das previsões semanais geradas nas REV0 para o subsistema Norte

Data da REV 0	Semanas (horizonte de previsão inicia na semana 1 e termina na semana 6)							U-Theil
	Corrente	1	2	3	4	5	6	
25/01/2017	2.0953	6.0755	2.4287	1.3074	1.5087	0.2119	7.2373	0.9735
22/02/2017	0.4976	1.6736	4.1093	1.4201	2.5383	5.3586	1.9220	0.6405
29/03/2017	1.8349	2.2285	4.7265	2.9234	5.1929	2.5626	3.5041	1.5535
26/04/2017	1.6295	0.7553	3.9276	0.7863	1.1413	5.4622	7.6777	2.3942
24/05/2017	0.1554	0.6066	1.3949	0.4377	2.5844	2.4886	5.8413	4.6775
28/06/2017	0.1470	2.4182	3.0524	4.5028	2.6224	1.7371	1.9013	3.8385
26/07/2017	0.6518	0.5203	1.2223	0.7010	0.5082	0.7019	1.5199	1.1166
23/08/2017	0.4031	0.9125	3.7303	2.5082	2.0240	0.2714	0.3128	3.7285
27/09/2017	1.3539	3.5301	2.9269	0.8362	0.3443	0.1746	0.7211	1.0595
25/10/2017	0.7336	1.7257	3.0385	2.8819	2.6672	0.2051	1.7865	1.6260
22/11/2017	1.5755	4.0060	5.7259	1.8206	0.1962	0.4679	3.4189	0.7530
27/12/2017	2.3981	3.9559	2.2995	1.9770	3.5136	8.6798	8.0549	1.3811
Média (MAPE)	1.1230	2.3674	3.2152	1.8419	2.0701	2.3601	3.6582	1.9785
Mediana	1.0438	1.9771	3.0455	1.6203	2.2811	1.2195	2.6704	1.4673
Máximo	2.3981	6.0755	5.7259	4.5028	5.1929	8.6798	8.0549	4.6775
Mínimo	0.1470	0.5203	1.2223	0.4377	0.1962	0.1746	0.3128	0.6405

Tabela A4 - Erros absolutos e MAD (MW) das previsões semanais geradas nas REV0 para o subsistema Norte

Data da REV 0	Semanas (horizonte de previsão inicia na semana 1 e termina na semana 6)						
	Corrente	1	2	3	4	5	6
25/01/2017	109.3047	317.8547	130.7759	67.6908	80.6575	10.8231	402.1517
22/02/2017	26.6042	85.4676	228.3401	76.6528	138.1640	299.4477	102.5268
29/03/2017	102.5377	118.8813	252.8717	156.8928	287.5401	136.5003	198.6920
26/04/2017	90.2281	40.2313	222.7046	45.6466	66.2749	309.5883	433.7821
24/05/2017	9.0244	34.3803	78.8104	24.1017	142.6681	135.5312	307.6593
28/06/2017	8.0069	127.3684	164.0839	242.8840	143.2039	96.1181	105.3882
26/07/2017	35.5937	28.7921	67.7495	39.9300	28.8894	39.9721	84.2801
23/08/2017	22.9178	51.9660	206.8498	144.9530	116.6634	15.5888	17.8986
27/09/2017	77.7716	201.9891	161.9590	47.7705	19.8177	9.7802	40.7991
25/10/2017	42.2270	96.6806	171.9233	159.3142	150.4083	11.6713	102.0168
22/11/2017	88.8479	227.9906	326.9692	99.7287	10.6120	23.9186	182.8908
27/12/2017	122.5757	211.6164	121.2201	103.4520	191.1719	478.4389	440.9514
Média (MAD)	61.3033	128.6015	177.8548	100.7514	114.6726	130.6149	201.5864
Mediana	59.9993	107.7809	168.0036	88.1908	127.4137	68.0451	144.1395
Máximo	122.5757	317.8547	326.9692	242.8840	287.5401	478.4389	440.9514
Mínimo	8.0069	28.7921	67.7495	24.1017	10.6120	9.7802	17.8986

A1.2 Resultados para demais revisões semanais

Os erros relativos (%) das previsões semanais geradas ao longo de 38 revisões semanais (não inclui as REVO) são apresentados na Tabela A5 a seguir. Na sequência, na Tabela A6, são apresentados os respectivos erros absolutos (MW). O MAPE na primeira semana das revisões semanais foi da ordem de 3,7%, acima do MAPE das REVO apresentado na Tabela A3. Os gráficos com as previsões, valores verificados e intervalos de confiança das revisões semanais encontram-se no anexo deste relatório.

Tabela A5 -Erros relativos e MAPE (%) das previsões semanais geradas nas REVO para o subsistema Norte

Data das revisões / Revisão		Semanas (horizonte de previsão inicia na semana 1 e termina na semana 6)							U-Theil
		Corrente	1	2	3	4	5	6	
12/01/2017	2	0.6713	3.1903	2.9407	3.7943	5.3068	1.3157	3.7128	1.1241
19/01/2017	3	0.9747	7.7778	4.4814	5.6300	2.2423	5.0604	2.2032	1.2354
02/02/2017	1	1.7863	8.6361	0.0867	2.3037	1.3552	5.3056	2.9839	1.7276
09/02/2017	2	0.1174	4.7363	1.3382	1.4058	2.7848	0.9666	1.2928	0.6534
15/02/2017	3	0.0778	1.2753	0.3290	6.7051	3.4992	1.8726	5.1626	0.5735
02/03/2017	1	3.7686	9.4574	8.3019	7.2572	9.5841	2.3577	6.2927	1.1715
09/03/2017	2	0.7175	4.3982	0.0101	3.6291	4.7929	1.3319	1.3202	0.6020
16/03/2017	3	0.1748	3.6937	4.0589	2.5532	1.2335	0.0462	0.8029	0.8148
23/03/2017	4	2.0833	6.7558	1.4024	0.2714	0.1714	1.4054	0.3357	1.0296
06/04/2017	1	1.0777	9.4313	3.0084	4.6236	1.3316	4.2211	6.6117	2.1029
13/04/2017	2	0.2469	2.2911	2.8472	1.1141	4.9523	8.6595	8.0538	3.2707
20/04/2017	3	4.1175	9.5913	4.5726	8.5108	9.5300	9.4282	7.4986	4.0380
04/05/2017	1	1.0824	7.3595	9.1253	8.5698	5.7117	7.7931	4.6408	2.7214
11/05/2017	2	0.3692	5.8798	4.7719	0.4540	2.1502	2.4501	4.1589	1.1961
18/05/2017	3	0.0329	3.7934	2.9003	4.2782	0.0858	3.7953	2.3327	1.6063
01/06/2017	1	1.2425	6.2470	0.5656	0.0837	0.4554	3.4098	1.7121	2.7999
08/06/2017	2	0.1384	0.2214	0.0334	1.1541	3.0466	1.6569	2.0738	0.9495
14/06/2017	3	3.2799	3.9891	3.3323	0.5791	0.2721	0.7459	2.3127	1.5401
22/06/2017	4	0.2818	2.3414	3.3415	0.2502	0.1141	0.7452	2.2781	2.8949
06/07/2017	1	0.1100	4.8716	1.6263	2.6616	0.6297	0.2385	1.7662	2.1289
13/07/2017	2	0.6574	1.2436	1.5590	0.2711	0.4799	0.2013	0.9650	0.9723
20/07/2017	3	0.0570	2.2723	0.0475	0.0248	0.6117	1.2527	0.0782	1.2522
03/08/2017	1	0.9079	0.2417	1.3410	0.4914	0.6298	1.2562	1.4633	1.2856
10/08/2017	2	0.1741	1.6117	1.2772	0.4449	1.4017	1.5348	2.5753	2.3399
17/08/2017	3	1.0133	0.5003	0.9183	0.4034	1.2292	2.3949	2.5561	0.8266
31/08/2017	1	0.0216	0.0301	0.3967	0.3522	0.9505	1.4292	0.1380	0.2677
06/09/2017	2	2.0858	3.1678	2.9908	3.1559	2.6499	0.5031	0.3131	1.1282
14/09/2017	3	0.8694	2.9359	0.8388	1.2380	0.8535	0.7167	3.0595	0.5477
21/09/2017	4	0.6809	0.5385	0.7705	2.9585	1.7689	0.6770	0.1210	0.6839
05/10/2017	1	0.7339	0.8796	0.7048	0.6157	0.0595	1.4673	3.3666	0.6135
11/10/2017	2	1.0105	0.7346	6.3396	4.5253	1.0033	0.4769	0.7586	1.2044
19/10/2017	3	0.6012	3.7055	1.3885	0.3582	1.1107	0.6266	0.7081	0.3826
01/11/2017	1	3.9581	2.1001	1.0499	0.1834	1.7678	3.2503	2.2569	2.0259
09/11/2017	2	0.3038	2.6585	0.1303	0.4372	2.9672	1.1668	2.0455	0.8949
16/11/2017	3	0.4646	4.2407	0.5375	3.4961	0.4548	2.3736	4.2518	1.0976
30/11/2017	1	1.7140	2.5852	2.8316	1.5344	0.7577	2.4723	1.1464	0.2942
14/12/2017	3	0.6830	5.6517	0.6087	2.3801	1.3559	1.2051	3.5737	1.1201
21/12/2017	4	2.2291	0.7342	1.4357	0.6260	0.5755	6.4777	6.7739	2.6673
Média (MAPE)		1.0662	3.7308	2.2169	2.3507	2.1020	2.4286	2.7289	1.4457
Mediana		0.7003	3.1791	1.3955	1.3219	1.2826	1.4483	2.2675	1.1715
Máximo		4.1175	9.5913	9.1253	8.5698	9.5841	9.4282	8.0538	4.0380
Mínimo		0.0216	0.0301	0.0101	0.0248	0.0595	0.0462	0.0782	0.2677

Tabela A6 - Erros absolutos e MAD (MW) das previsões semanais geradas nas REVO para o subsistema Norte

Data das revisões / Revisão		Semanas (horizonte de previsão inicia na semana 1 e termina na semana 6)						
		Corrente	1	2	3	4	5	6
12/01/2017	2	34.36	161.59	153.41	198.51	285.75	68.12	198.50
19/01/2017	3	49.37	405.74	234.46	303.15	116.09	270.54	112.52
02/02/2017	1	93.45	465.02	4.49	123.16	69.21	294.81	161.06
09/02/2017	2	6.32	245.22	71.54	71.79	154.74	52.17	70.37
15/02/2017	3	4.03	68.18	16.80	372.58	188.88	101.93	288.50
02/03/2017	1	192.46	525.51	448.11	395.03	535.58	125.77	336.67
09/03/2017	2	39.87	237.40	0.55	202.80	255.68	71.26	70.85
16/03/2017	3	9.43	201.06	226.82	136.20	65.99	2.48	44.46
23/03/2017	4	113.40	377.52	74.81	14.52	9.20	77.82	17.88
06/04/2017	1	57.49	504.59	161.45	256.01	70.93	239.35	383.84
13/04/2017	2	13.21	122.96	157.65	59.34	280.81	502.73	467.67
20/04/2017	3	220.98	531.09	243.56	482.59	553.27	547.48	425.01
04/05/2017	1	57.66	417.30	529.77	497.64	323.73	440.30	255.55
11/05/2017	2	20.94	341.36	277.10	25.73	121.48	134.92	229.58
18/05/2017	3	1.91	220.28	164.38	241.71	4.73	209.51	127.04
01/06/2017	1	70.42	352.95	31.15	4.62	24.80	179.59	92.04
08/06/2017	2	7.82	12.19	1.84	62.86	160.46	89.07	111.86
14/06/2017	3	180.61	220.21	181.49	30.50	14.63	40.24	126.29
22/06/2017	4	15.55	127.52	175.99	13.45	6.15	40.69	126.05
06/07/2017	1	5.79	261.88	87.72	145.35	34.84	13.22	100.61
13/07/2017	2	35.34	67.08	85.14	15.00	26.60	11.47	54.86
20/07/2017	3	3.07	124.09	2.63	1.37	34.85	71.21	4.45
03/08/2017	1	50.24	13.40	76.39	27.94	35.87	69.66	84.57
10/08/2017	2	9.65	91.81	72.61	25.33	77.72	88.70	148.44
17/08/2017	3	57.72	28.44	52.29	22.37	71.04	138.04	146.83
31/08/2017	1	1.23	1.67	22.93	20.30	54.60	81.78	7.63
06/09/2017	2	115.66	183.08	172.39	181.28	151.62	27.84	17.89
14/09/2017	3	50.25	169.23	48.18	70.84	47.23	40.94	176.10
21/09/2017	4	39.25	30.93	44.09	163.70	101.05	38.97	6.78
05/10/2017	1	41.99	48.67	40.26	35.44	3.33	83.02	186.11
11/10/2017	2	55.91	41.96	364.90	253.52	56.77	26.36	42.78
19/10/2017	3	34.34	213.28	77.79	20.27	61.40	35.34	40.30
01/11/2017	1	221.75	118.83	58.04	10.34	100.61	185.60	123.63
09/11/2017	2	17.19	146.96	7.35	24.88	169.44	63.91	110.64
16/11/2017	3	25.68	239.15	30.59	199.64	24.91	128.39	217.33
30/11/2017	1	97.55	147.63	155.11	82.99	38.73	132.25	60.44
14/12/2017	3	37.41	305.70	31.11	127.32	71.48	63.06	194.45
21/12/2017	4	120.57	37.53	76.80	33.00	30.11	352.45	373.38
Média (MAD)		58.15	205.50	122.68	130.34	116.69	135.29	151.13
Mediana		39.56	176.16	76.60	71.32	70.07	82.40	124.84
Máximo		221.75	531.09	529.77	497.64	553.27	547.48	467.67
Mínimo		1.23	1.67	0.55	1.37	3.33	2.48	4.45

A2. Resultados para o submercado Nordeste

A2.1 Resultados para REVO

Na Tabela A7 apresenta-se os valores de MAPE e U-Theil para as previsões mensais referentes aos 12 casos do conjunto REVO do subsistema Nordeste. Observa-se que em apenas 4 dos 12 meses avaliados o U-Theil superou a unidade, i.e., na maior parte do período avaliado as previsões mensais geradas pelo PrevargaPMO foram melhores que as previsões obtidas pelo método de Holt-Winters. Os maiores erros de previsão nos meses 1 e 2 do horizonte de previsão foram da ordem de 3,8% e 4,0% respectivamente. Na média, os erros relativos (MAPE) foram de 1,5% e 1,3% para os meses 1 e 2 respectivamente.

Tabela A7 - Erros relativos e MAPE (%) para os casos REVO no subsistema Nordeste

Data da REV 0	Mês Corrente	Previsão 1 mês à frente	Previsão 2 meses à frente	U-Theil
25/01/2017	0.2301	2.3369	2.5498	0.7009
22/02/2017	0.3823	1.6134	0.2802	0.7818
29/03/2017	0.2487	0.6347	0.1262	0.1951
26/04/2017	0.3105	0.0856	0.5833	0.5881
24/05/2017	0.4568	0.6064	3.9950	1.0149
28/06/2017	0.1317	3.8470	0.2866	0.9499
26/07/2017	0.3732	1.7369	0.2019	0.1754
23/08/2017	0.1829	2.3826	0.9312	0.9990
27/09/2017	0.5065	1.1647	2.1709	1.0627
25/10/2017	0.7024	1.8358	2.8081	4.5929
22/11/2017	0.8661	1.1835	0.2015	1.4681
27/12/2017	0.5828	0.0376	1.9243	0.7052
Média (MAPE)	0.4145	1.4554	1.3383	1.1028
Mediana	0.3778	1.3984	0.7573	0.8659
Máximo	0.8661	3.8470	3.9950	4.5929
Mínimo	0.1317	0.0376	0.1262	0.1754

Já na Tabela A8 apresenta-se os valores de MAD (MW) para as previsões mensais referentes aos 12 casos do conjunto REVO do subsistema Nordeste. Na sequência, a Figura A2, apresentam-se as previsões semanais para as 12 REVO do subsistema Nordeste. A primeira semana é a semana corrente, as demais correspondem ao horizonte de previsão. As previsões de temperatura são disponibilizadas apenas para a segunda semana.

Tabela A8 - Erros absolutos e MAD (MW) para os casos REVO no subsistema Norte

Data da REV 0	Mês Corrente	Previsão 1 mês à frente	Previsão 2 meses à frente
25/01/2017	25.2332	253.4452	279.9568
22/02/2017	41.4671	177.1383	29.7882
29/03/2017	27.3070	67.4845	13.3048
26/04/2017	33.0100	9.0283	59.3543
24/05/2017	48.1579	61.7008	388.3003
28/06/2017	13.4027	373.9068	29.1697
26/07/2017	36.2759	176.7631	20.7386
23/08/2017	18.6130	244.7239	100.3296
27/09/2017	52.0226	125.4819	237.2804
25/10/2017	75.6770	200.6498	310.7199
22/11/2017	94.6699	130.9536	22.2714
27/12/2017	64.4917	4.1541	206.5387
Média (MAD)	44.1940	152.1192	141.4794
Mediana	38.8715	153.8584	79.8420
Máximo	94.6699	373.9068	388.3003
Mínimo	13.4027	4.1541	13.3048

Figura A2 - Previsões semanais e respectivas métricas para as REVO do subsistema Nordeste









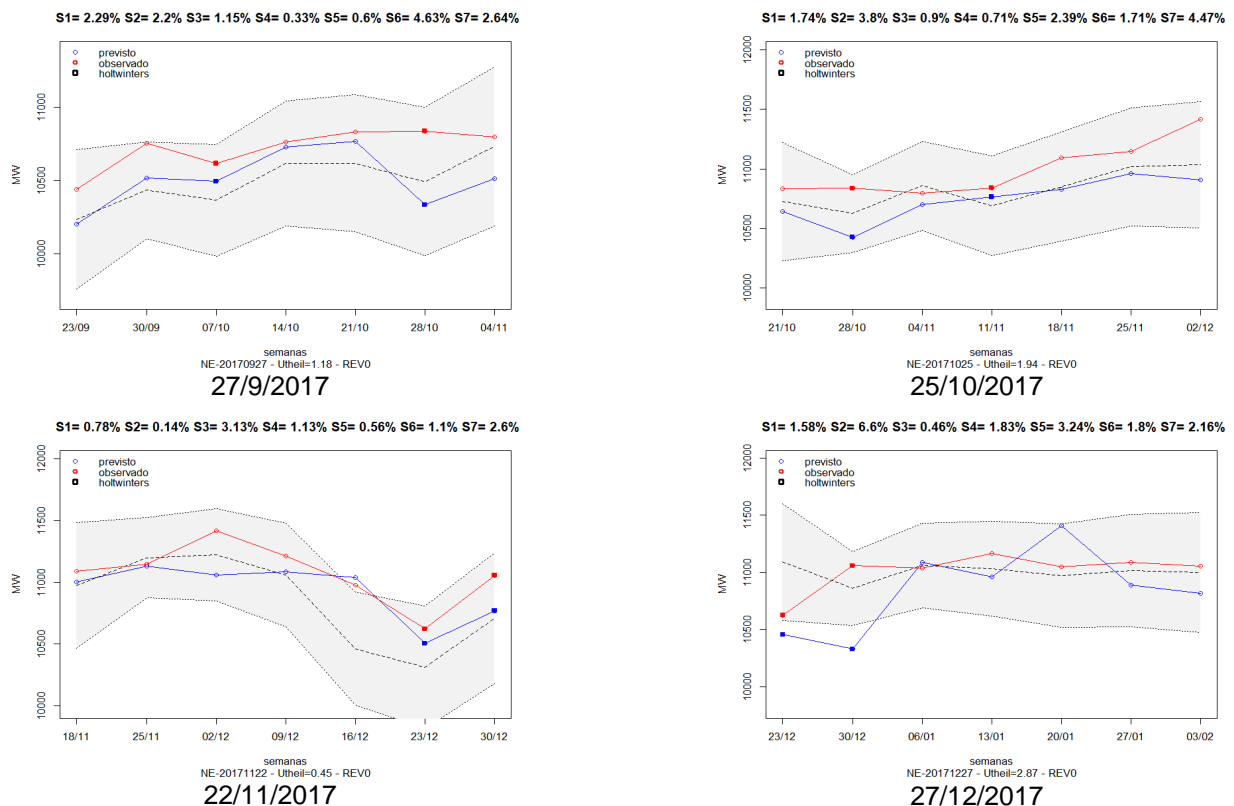


Figura A2 Previsões semanais e respectivas métricas para as REVO do subsistema Nordeste (continuação)



Na Figura A2, as datas indicadas nos eixos das abscissas correspondem às datas de início das semanas operativas. A previsão gerada com base no método da decomposição clássica é representada pela linha tracejada no meio da região definida pelos limites dos intervalos de confiança, tal previsão é utilizada como referência no cálculo da estatística U-Theil. Adicionalmente, na Figura A2 os pontos mais destacados com quadrados indicam semanas com feriados.

Conforme indicado na Figura A2 e na Tabela A9, em 4 dos 12 casos analisados o U-Theil foi menor que a unidade, i.e., em termos globais o método da decomposição clássica gerou previsões melhores que as obtidas pelo PrevCargaPMO, apesar das informações de temperatura (para a primeira semana) e tipos de dias (feriados e dias especiais) em cada semana. Ainda conforme ilustrado na Figura A2, na maior parte das vezes, os intervalos de previsão com 95% gerados pelo método da decomposição clássica cobrem os valores verificados e as previsões geradas pelo PrevCargaPMO. Vale ressaltar que entre as duas previsões semanais apresentadas na Figura A2 (linhas em azul e tracejada), apenas as previsões semanais apresentadas pelo PrevCargaPMO (em azul) são compatibilizadas com a previsão mensal para o primeiro mês.

Os valores de MAPE apresentados na Tabela A9 indicam um MAPE de 2,0% na semana 1 (primeira semana do horizonte de previsão). Conforme ilustrado na Figura A2 e na Tabela A9, o PrevCargaPMO apresenta um bom resultado para a primeira semana, com exceção do mês de Outubro, neste a decomposição clássica apresentou resultado superior. Na sequência, na Tabela A10, apresentam-se os erros absolutos e MAD (MW) das previsões semanais.

Tabela A9 - Erros relativos e MAPE (%) das previsões semanais geradas nas REV0 para o subsistema Nordeste

Data da REV 0	Semanas (horizonte de previsão inicia na semana 1 e termina na semana 6)							U-Theil
	Corrente	1	2	3	4	5	6	
25/01/2017	1.7056	0.8292	4.5774	0.6811	2.8117	1.6772	5.1480	1.2868
22/02/2017	0.1095	2.6365	0.5589	0.7735	2.3241	4.4224	0.5906	0.8492
29/03/2017	1.2304	1.6923	1.5629	2.1213	0.4236	7.5278	1.8478	1.1123
26/04/2017	1.9355	1.5289	0.0839	3.0369	0.7780	2.6576	1.5601	0.6594
24/05/2017	0.2186	1.1996	0.0879	0.2689	0.2707	2.6767	5.5462	0.7553
28/06/2017	0.4199	1.9465	5.0387	4.8475	4.5174	1.2285	2.6383	1.3724
26/07/2017	0.3619	0.5079	1.1525	0.9434	1.6496	3.9543	1.8096	2.5889
23/08/2017	0.4669	1.4778	1.0811	3.1091	3.9236	2.9375	1.0729	1.6569
27/09/2017	2.2938	2.1969	1.1476	0.3344	0.5967	4.6345	2.6444	1.1800
25/10/2017	1.7357	3.8039	0.9039	0.7058	2.3887	1.7054	4.4733	1.9401
22/11/2017	0.7836	0.1357	3.1313	1.1346	0.5573	1.1017	2.6028	0.4516
27/12/2017	1.5810	6.6043	0.4574	1.8321	3.2371	1.8016	2.1569	2.8694
Média (MAPE)	1.0702	2.0466	1.6486	1.6490	1.9565	3.0271	2.6742	1.3935
Mediana	1.0070	1.6106	1.1143	1.0390	1.9869	2.6671	2.3799	1.2334
Máximo	2.2938	6.6043	5.0387	4.8475	4.5174	7.5278	5.5462	2.8694
Mínimo	0.1095	0.1357	0.0839	0.2689	0.2707	1.1017	0.5906	0.4516

Tabela A10 - Erros absolutos e MAD (MW) das previsões semanais geradas nas REV0 para o subsistema Nordeste

Data da REV 0	Semanas (horizonte de previsão inicia na semana 1 e termina na semana 6)						
	Corrente	1	2	3	4	5	6
25/01/2017	189.06	92.25	512.01	73.16	304.69	173.01	569.86
22/02/2017	11.87	271.95	61.87	84.43	255.35	487.69	62.82
29/03/2017	135.69	179.97	166.32	224.53	46.01	770.16	196.97
26/04/2017	210.25	156.42	8.95	331.73	82.35	270.26	162.08
24/05/2017	23.14	121.99	9.13	27.53	27.46	262.33	535.65
28/06/2017	41.15	187.99	492.49	475.57	442.06	120.50	267.48
26/07/2017	35.41	49.82	116.84	95.55	169.13	406.83	182.73
23/08/2017	47.88	152.04	109.17	318.01	401.90	306.68	115.35
27/09/2017	239.47	236.20	121.83	35.98	64.63	502.23	285.51
25/10/2017	187.99	412.22	97.59	76.51	264.96	190.12	510.67
22/11/2017	86.91	15.12	357.48	127.25	61.17	117.04	287.80
27/12/2017	167.96	730.24	50.47	204.49	357.65	199.75	238.38
Média (MAD)	114.73	217.19	175.35	172.90	206.45	317.22	284.61
Mediana	111.30	168.20	113.01	111.40	212.24	266.29	252.93
Máximo	239.47	730.24	512.01	475.57	442.06	770.16	569.86
Mínimo	11.87	15.12	8.95	27.53	27.46	117.04	62.82

A2.2 Resultados para demais revisões semanais

Os erros relativos (%) das previsões semanais geradas ao longo de 38 revisões semanais (não inclui as REV0) são apresentados na Tabela A11 a seguir. Na sequência, na Tabela A12, são apresentados os respectivos erros absolutos (MW). O MAPE na primeira semana das revisões semanais foi da ordem de 2,5%, acima do MAPE das REV0 apresentado na Tabela A9. Os gráficos com as previsões, valores verificados e intervalos de confiança das revisões semanais encontram-se no anexo deste relatório.

Tabela A11 Erros relativos e MAPE (%) das previsões semanais geradas nas REVO para o subsistema Nordeste

Data das revisões / Revisão		Semanas (horizonte de previsão inicia na semana 1 e termina na semana 6)							U-Theil
		Corrente	1	2	3	4	5	6	
12/01/2017	2	0.3272	0.9636	3.5379	2.4408	3.1549	0.7007	3.5799	0.5472
19/01/2017	3	0.1849	0.3375	3.8131	3.2160	0.4934	1.3790	4.5234	0.8117
02/02/2017	1	1.4767	3.9292	0.6941	0.7921	2.3037	3.9163	5.4795	1.2832
09/02/2017	2	1.0888	0.7240	0.9513	4.0008	3.8986	2.0140	5.7740	0.9523
15/02/2017	3	0.8280	6.2900	0.7340	3.7444	2.8845	3.7168	5.0625	1.9642
02/03/2017	1	2.4268	9.4659	5.3000	5.5469	4.2591	1.6553	4.8930	1.9290
09/03/2017	2	1.0701	3.2251	2.9130	2.0979	0.8084	0.2579	0.5038	0.4615
16/03/2017	3	0.6645	1.4863	3.2173	0.8196	0.6752	0.7150	1.0759	0.8973
23/03/2017	4	0.7107	0.2464	1.7243	0.2377	1.0249	1.3401	7.0870	1.5055
06/04/2017	1	1.7991	5.5285	3.8730	4.3661	1.4740	1.8056	3.7812	2.0997
13/04/2017	2	0.8135	2.6493	3.1433	3.6094	2.1200	3.9348	0.8468	1.8441
20/04/2017	3	1.7547	3.6441	0.3199	2.8105	5.1361	2.2067	2.0296	1.7407
04/05/2017	1	0.6053	2.6737	6.3854	2.5743	1.4685	2.0589	2.5529	1.3526
11/05/2017	2	1.1769	2.9680	2.1989	1.8428	2.1219	1.0197	0.7646	0.7869
18/05/2017	3	0.0202	2.2928	4.2700	1.7606	2.5462	0.5651	6.8934	2.1955
01/06/2017	1	0.4219	2.9115	3.7823	2.8381	1.1298	3.5895	0.7826	1.0093
08/06/2017	2	0.3680	1.1063	1.4736	1.8301	2.6397	1.2388	1.2015	0.5673
14/06/2017	3	1.8543	1.3783	1.2997	1.7170	1.6011	0.8373	0.4094	0.4972
22/06/2017	4	0.6185	2.9676	4.5979	2.9394	0.9423	0.7996	3.2746	0.6855
06/07/2017	1	0.6390	3.3275	1.7719	1.7578	0.0855	3.6516	3.6792	2.5232
13/07/2017	2	0.1618	0.2943	0.7319	0.0910	2.8306	2.6077	3.7967	3.1935
20/07/2017	3	0.2753	0.7544	0.4564	2.7054	2.1331	3.4581	3.8959	3.2862
03/08/2017	1	1.3865	5.0634	3.3623	4.2872	4.3548	1.7349	0.7177	6.4616
10/08/2017	2	0.9908	0.8971	2.7095	2.6885	1.1550	1.1605	2.3157	0.9457
17/08/2017	3	1.6464	2.8895	2.1547	2.0148	1.2526	2.1392	0.2411	1.7206
31/08/2017	1	1.5813	2.8901	2.4664	2.6308	1.2906	1.1577	1.1916	1.3775
06/09/2017	2	0.0630	0.1677	1.3117	0.0651	1.6944	2.7609	0.1203	0.4526
14/09/2017	3	1.4050	1.6257	1.1281	3.4132	3.5315	1.4278	1.0781	2.4039
21/09/2017	4	1.1749	2.1044	3.4783	4.0052	2.6821	1.5762	4.9244	2.9827
05/10/2017	1	0.9601	1.9266	0.2883	0.4328	3.4416	0.2232	1.1277	1.0033
11/10/2017	2	1.3626	0.5257	0.4210	2.9082	0.0155	2.0879	2.5847	2.8435
19/10/2017	3	1.5373	2.4839	2.7608	0.2991	2.2896	2.0321	2.3990	2.2146
01/11/2017	1	1.9766	0.2317	2.5963	2.2831	2.3272	4.3740	3.2025	2.4337
09/11/2017	2	1.3255	2.8448	2.9256	2.8571	4.6164	2.4504	0.9155	0.8451
16/11/2017	3	1.5030	3.0075	2.2920	4.9899	2.1729	1.0680	2.2658	0.7493
30/11/2017	1	0.2065	3.1413	0.2163	1.3416	1.9417	3.2446	2.3314	0.6280
14/12/2017	3	0.1715	3.6793	3.6451	2.3511	1.0825	0.5561	1.3522	1.0039
21/12/2017	4	1.1102	3.8446	0.8051	1.3185	1.9265	0.4813	0.1925	1.4076
Média (MAPE)		0.9918	2.5391	2.3619	2.4112	2.1449	1.8932	2.6013	1.6212
Mediana		1.0305	2.6615	2.3792	2.5076	2.1210	1.6951	2.3236	1.3651
Máximo		2.4268	9.4659	6.3854	5.5469	5.1361	4.3740	7.0870	6.4616
Mínimo		0.0202	0.1677	0.2163	0.0651	0.0155	0.2232	0.1203	0.4526

Tabela A12 - Erros absolutos e MAD (MW) das previsões semanais geradas nas REVO para o subsistema Nordeste

Data das revisões / Revisão		Semanas (horizonte de previsão inicia na semana 1 e termina na semana 6)						
		Corrente	1	2	3	4	5	6
12/01/2017	2	36.02	106.13	392.15	271.52	352.89	75.27	387.94
19/01/2017	3	20.37	37.41	424.18	359.73	53.00	149.44	466.59
02/02/2017	1	164.27	439.50	74.56	85.84	237.62	433.53	598.10
09/02/2017	2	121.79	77.77	103.09	412.69	431.57	219.83	634.38
15/02/2017	3	88.94	681.62	75.71	414.49	314.84	408.36	558.28
02/03/2017	1	250.33	1,047.84	578.50	609.43	469.68	176.05	520.68
09/03/2017	2	118.45	352.02	320.05	231.35	85.97	27.44	53.32
16/03/2017	3	72.54	163.30	354.80	87.16	71.85	75.67	116.87
23/03/2017	4	78.09	27.18	183.38	25.30	108.48	145.57	725.06
06/04/2017	1	191.34	588.32	409.93	474.29	150.81	192.47	413.03
13/04/2017	2	86.57	280.41	341.45	369.27	225.98	429.81	89.64
20/04/2017	3	185.73	395.86	32.73	299.59	561.03	233.60	206.40
04/05/2017	1	61.93	285.01	697.49	272.51	149.33	213.90	261.32
11/05/2017	2	125.45	324.20	232.77	187.40	220.45	104.38	77.57
18/05/2017	3	2.21	242.71	434.22	182.91	260.64	57.34	675.59
01/06/2017	1	42.90	302.47	387.17	287.94	110.73	346.67	76.50
08/06/2017	2	38.24	113.24	149.50	179.36	254.94	121.08	117.87
14/06/2017	3	189.81	139.84	127.38	165.83	156.49	82.15	40.07
22/06/2017	4	62.75	290.84	444.06	287.31	92.45	78.25	321.21
06/07/2017	1	61.71	325.24	173.84	172.01	8.38	370.22	372.64
13/07/2017	2	15.81	28.87	71.62	8.93	286.98	264.11	389.28
20/07/2017	3	27.01	73.82	44.77	274.28	216.04	354.56	400.82
03/08/2017	1	136.00	513.35	340.55	439.57	448.04	175.19	73.40
10/08/2017	2	100.45	90.86	277.80	276.60	116.63	118.70	237.21
17/08/2017	3	166.75	296.26	221.68	203.46	128.12	219.12	25.17
31/08/2017	1	162.69	291.85	252.28	269.47	134.74	124.48	126.50
06/09/2017	2	6.36	17.15	134.36	6.80	182.18	293.08	12.95
14/09/2017	3	143.71	166.52	117.77	366.98	374.89	153.66	116.77
21/09/2017	4	120.34	219.71	373.99	425.17	288.64	170.71	533.65
05/10/2017	1	103.23	204.52	31.03	46.88	372.96	24.10	122.24
11/10/2017	2	144.65	56.58	45.60	315.16	1.67	226.33	286.70
19/10/2017	3	165.45	269.04	299.18	32.29	248.19	225.41	267.44
01/11/2017	1	214.20	25.02	281.43	253.24	259.43	499.34	359.16
09/11/2017	2	143.11	308.38	324.51	318.51	527.01	274.82	100.49
16/11/2017	3	162.92	333.60	255.51	569.65	243.70	117.23	240.71
30/11/2017	1	23.02	358.61	24.26	147.27	206.27	358.76	257.26
14/12/2017	3	19.24	403.88	387.23	259.96	119.45	62.07	149.39
21/12/2017	4	121.87	408.42	89.02	145.48	215.03	53.18	21.34
Média (MAD)		104.64	270.72	250.25	256.20	228.61	201.47	274.57
Mediana		110.84	282.71	253.90	270.50	218.25	175.62	248.99
Máximo		250.33	1047.84	697.49	609.43	561.03	499.34	725.06
Mínimo		2.21	17.15	24.26	6.80	1.67	24.10	12.95

A3. Resultados para o submercado Sul

A3.1 Resultados para REV0

Na Tabela A13 apresenta-se os valores de MAPE e U-Theil para as previsões mensais referentes aos 12 casos do conjunto REV0 do subsistema Sul. Observa-se que em apenas 1 dos 12 meses avaliados o U-Theil superou a unidade, i.e., na maior parte do período avaliado as previsões mensais geradas pelo PrecvargaPMO foram melhores que as previsões obtidas pelo método de Holt-Winters. Os maiores erros de previsão nos meses 1 e 2 do horizonte de previsão foram da ordem de 5,5% e 3,9% respectivamente e na média, os erros relativos (MAPE) foram de 2,7% e 1,9% para os meses 1 e 2 respectivamente.

Tabela A13 - MAPE (%) para os casos REV0 no subsistema Sul

Data da REV 0	Mês Corrente	Previsão 1 mês à frente	Previsão 2 meses à frente	U-Theil
25/01/2017	0.4098	3.8073	3.9084	0.7024
22/02/2017	0.6110	2.3613	2.1351	0.1791
29/03/2017	0.1872	4.6732	0.6860	0.5920
26/04/2017	0.4605	3.5993	0.6551	0.4884
24/05/2017	1.2025	1.9572	1.2956	0.6063
28/06/2017	0.0495	0.7803	2.8515	0.9878
26/07/2017	0.1007	2.8436	3.8019	0.5610
23/08/2017	1.7799	4.0139	0.1279	0.7856
27/09/2017	0.1393	1.8254	1.1031	0.2397
25/10/2017	0.1712	0.2972	3.0322	0.7414
22/11/2017	2.6575	5.4631	0.8525	1.2071
27/12/2017	2.1085	1.0624	1.7666	0.3259
Média (MAPE)	0.8231	2.7237	1.8513	0.6180
Mediana	0.4352	2.6025	1.5311	0.5991
Máximo	2.6575	5.4631	3.9084	1.2071
Mínimo	0.0495	0.2972	0.1279	0.1791

Já na Tabela A14 apresenta-se os valores de MAD (MW) para as previsões mensais referentes aos 11 casos do conjunto REV0 do subsistema Sul.

Tabela A14 - MAD (MW) para os casos REV0 no subsistema Sul

Data da REV 0	Mês Corrente	Previsão 1 mês à frente	Previsão 2 meses à frente
25/01/2017	49.4531	486.1476	469.2260
22/02/2017	78.0168	283.4879	229.9573
29/03/2017	22.4745	503.3255	73.7275
26/04/2017	49.6016	386.8031	70.1980
24/05/2017	129.2342	209.7300	138.5869
28/06/2017	5.3061	83.4659	309.5971
26/07/2017	10.7714	308.7402	419.3846
23/08/2017	193.2489	442.7739	13.9233
27/09/2017	15.3652	198.6668	123.3746
25/10/2017	18.6350	33.2403	357.2756
22/11/2017	297.2108	643.7008	103.1628
27/12/2017	248.4442	128.5673	218.0324
Média (MAD)	93.1468	309.0541	210.5372
Mediana	49.5273	296.1141	178.3097
Máximo	297.2108	643.7008	469.2260
Mínimo	5.3061	33.2403	13.9233

A seguir, na Figura A3, apresentam-se as previsões semanais para as 12 REV0 do subsistema Sul. A primeira semana é a semana corrente, as demais correspondem ao horizonte de previsão. As previsões de temperatura são disponibilizadas apenas para a segunda semana.

Figura A3 - Previsões semanais e respectivas métricas para as REVO do subsistema Sul







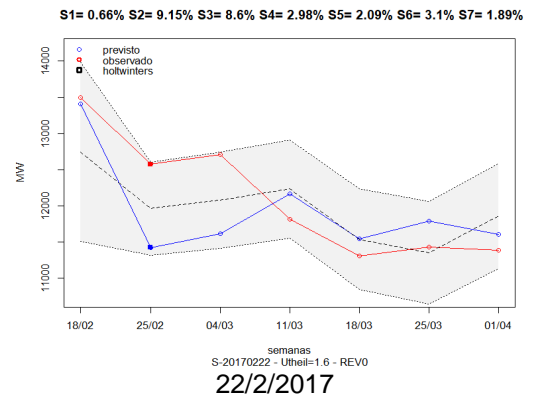

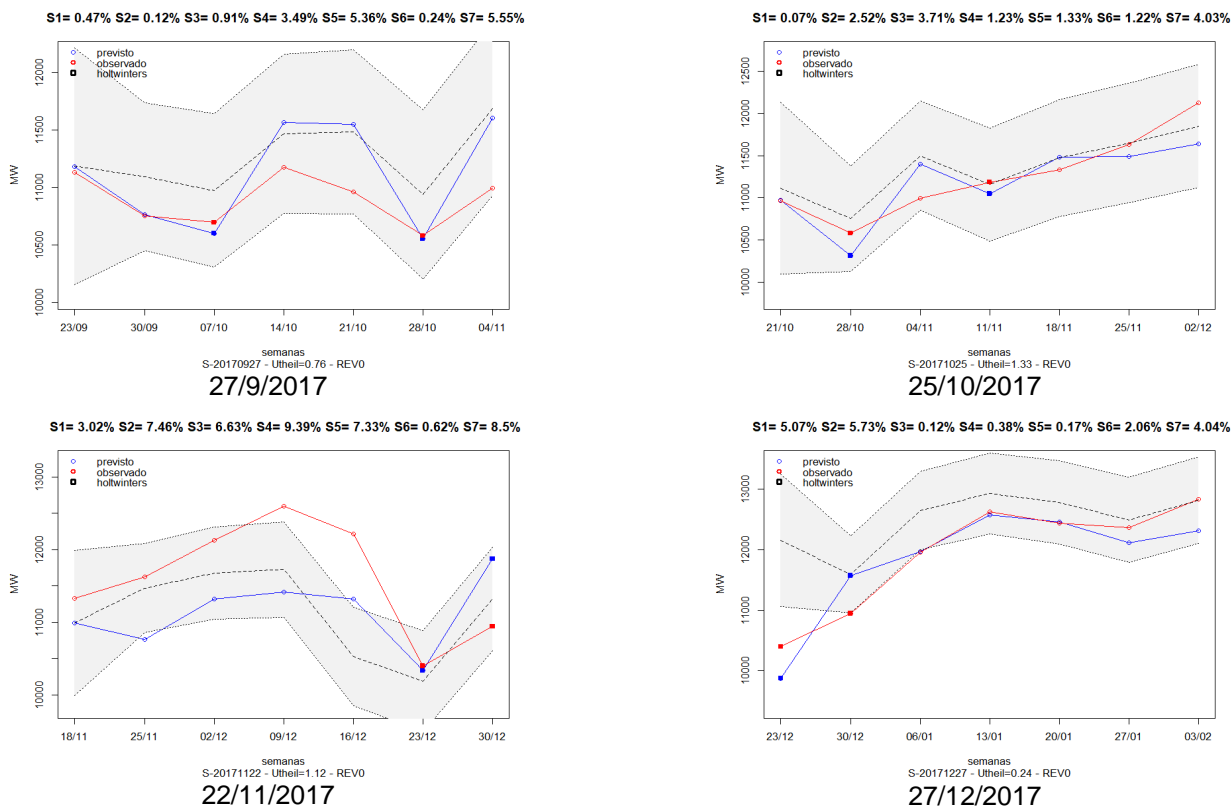


Figura A3 Previsões semanais e respectivas métricas para as REVO do subsistema Sul (continuação)



Ainda na Figura A3, as datas indicadas nos eixos das abscissas correspondem às datas de início das semanas operativas. A previsão gerada com base no método da decomposição clássica é representada pela linha tracejada no meio da região definida pelos limites dos intervalos de confiança, tal previsão é utilizada como referência no cálculo da estatística U-Theil. Adicionalmente, na Figura A3 os pontos mais destacados com quadrados indicam semanas com feriados.

Conforme indicado na Figura A3 e na Tabela A15, em apenas 2 dos 12 casos analisados o U-Theil foi menor que a unidade, i.e., em termos globais o método da decomposição clássica gerou previsões melhores que as obtidas pelo PrevCargaPMO, apesar das informações de temperatura (para a primeira semana) e tipos de dias (feriados e dias especiais) em cada semana. Ainda conforme ilustrado na Figura A3, na maior parte das vezes, os intervalos de previsão com 95% gerados pelo método da decomposição clássica cobrem os valores verificados e as previsões geradas pelo PrevCargaPMO. Vale ressaltar que entre as duas previsões semanais apresentadas na Figura A3 (linhas em azul e tracejada), apenas as previsões semanais apresentadas pelo PrevCargaPMO (em azul) são compatibilizadas com a previsão mensal para o primeiro mês.

Os valores de MAPE apresentados na Tabela A15 indicam um MAPE de 4,0% na semana 1 (primeira semana do horizonte de previsão). Conforme ilustrado na Figura A3 e na Tabela A15, o PrevCargaPMO apresenta um bom resultado para a primeira semana apenas nos meses de Janeiro, Abril, Junho, Setembro e Outubro e nestes a decomposição clássica apresentou um resultados superior com exceção de Setembro. Na sequência, na Tabela A16, apresentam-se os erros absolutos e MAD (MW) das previsões semanais.

Tabela A15 - Erros relativos e MAPE (%) das previsões semanais geradas nas REV0 para o subsistema Sul

Data da REV 0	Semanas (horizonte de previsão inicia na semana 1 e termina na semana 6)							U-Theil
	corrente	1	2	3	4	5	6	
25/01/2017	0.9581	1.2067	0.3196	3.6016	9.1588	7.7604	8.1066	1.0080
22/02/2017	0.6615	9.1499	8.5964	2.9847	2.0908	3.1001	1.8854	1.6000
29/03/2017	0.8709	4.6169	0.3889	4.2530	14.6040	3.8930	2.4370	2.9290
26/04/2017	1.3045	1.2751	3.9187	2.9892	4.2910	3.6835	0.1036	1.2720
24/05/2017	3.1103	4.0148	2.0828	2.6976	2.8102	0.3539	1.4601	1.5150
28/06/2017	0.2120	2.8963	0.8506	1.8294	0.4445	1.0997	1.4420	1.1650
26/07/2017	0.1232	3.6741	1.2205	1.3283	2.4240	3.6033	6.9829	2.3790
23/08/2017	3.1805	5.0605	5.5568	4.6081	4.7582	3.4828	0.7577	1.2750
27/09/2017	0.4696	0.1241	0.9058	3.4927	5.3555	0.2364	5.5545	0.7560
25/10/2017	0.0703	2.5156	3.7125	1.2277	1.3257	1.2158	4.0325	1.3260
22/11/2017	3.0210	7.4595	6.6309	9.3879	7.3276	0.6193	8.4995	1.1160
27/12/2017	5.0749	5.7254	0.1180	0.3791	0.1689	2.0570	4.0386	0.2390
Média (MAPE)	1.5881	3.9766	2.8585	3.2316	4.5633	2.5921	3.7750	1.3818
Mediana	0.9145	3.8445	1.6516	2.9870	3.5506	2.5785	3.2347	1.2737
Máximo	5.0749	9.1499	8.5964	9.3879	14.6040	7.7604	8.4995	2.9292
Mínimo	0.0703	0.1241	0.1180	0.3791	0.1689	0.2364	0.1036	0.2388

Tabela A16 - Erros absolutos e MAD (MW) das previsões semanais geradas nas REV0 para o subsistema Sul

Data da REV 0	Semanas (horizonte de previsão inicia na semana 1 e termina na semana 6)						
	corrente	1	2	3	4	5	6
25/01/2017	117.7619	146.7565	40.1933	461.1926	1236.1245	975.7399	1030.2109
22/02/2017	89.2798	1150.4446	1092.4564	352.4727	236.2968	354.2954	214.6892
29/03/2017	99.5301	525.7208	42.8656	452.8968	1544.8786	397.0924	263.5291
26/04/2017	137.9911	130.0619	423.7544	320.0583	462.7728	399.7556	11.2394
24/05/2017	335.4397	435.7122	226.0647	279.7522	301.4589	37.9709	156.9183
28/06/2017	22.7406	311.2704	91.6607	199.8534	47.5113	118.1061	155.5187
26/07/2017	13.1736	394.5747	131.6268	141.8623	260.7537	396.1278	744.2395
23/08/2017	342.1367	556.3289	592.2447	517.7716	532.5480	387.7073	81.4588
27/09/2017	52.2815	13.3462	96.8928	390.2990	587.1974	25.0091	610.5841
25/10/2017	7.7124	266.1648	408.1004	137.3106	150.2263	141.3842	488.9713
22/11/2017	342.3285	867.4455	804.0590	1182.4239	894.9345	64.4024	930.2233
27/12/2017	527.7763	626.6130	14.1039	47.8530	21.0060	254.3968	518.2256
Média (MAD)	174.0127	452.0366	330.3352	373.6455	522.9757	295.9990	433.8173
Mediana	108.6460	415.1435	178.8458	336.2655	382.1158	304.3461	376.2502
Máximo	527.7763	1150.4446	1092.4564	1182.4239	1544.8786	975.7399	1030.2109
Mínimo	7.7124	13.3462	14.1039	47.8530	21.0060	25.0091	11.2394

A3.2 Resultados para demais revisões semanais

Os erros relativos (%) das previsões semanais geradas ao longo de 36 revisões semanais (não inclui as REV0) são apresentados na Tabela 17 a seguir. Na sequência, na Tabela A18, são apresentados os respectivos erros absolutos (MW). O MAPE na primeira semana das revisões semanais foi da ordem de 3,3%, abaixo do MAPE das REV0 apresentado na Tabela A15. Os gráficos com as previsões, valores verificados e intervalos de confiança das revisões semanais encontram-se no anexo deste relatório.

Tabela A17 - Erros relativos e MAPE (%) das previsões semanais geradas nas REV0 para o subsistema Sul

Data das revisões / Revisão		Semanas (horizonte de previsão inicia na semana 1 e termina na semana 6)						U-Theil	
		Corrente	1	2	3	4	5		6
12/01/2017	2	1.2760	2.2225	2.3597	2.1399	0.4163	1.2590	10.4244	0.6558
19/01/2017	3	0.2394	4.3611	4.3504	1.0973	4.0848	9.1037	9.4529	1.0852
02/02/2017	1	0.6404	9.5177	4.2477	8.5765	7.6501	9.2233	2.2045	1.4427
09/02/2017	2	1.7004	5.7504	8.9767	7.5304	8.6718	1.1736	1.0277	1.0835
15/02/2017	3	4.5808	7.4800	6.8567	8.0731	1.3994	2.2595	1.2862	1.0357
02/03/2017	1	7.9231	12.3467	2.0370	0.9162	0.8450	2.0792	0.6440	2.4318
09/03/2017	2	0.5974	1.0676	4.0035	2.7532	0.0115	1.3135	6.7488	0.4902
16/03/2017	3	0.3184	0.8420	0.1689	0.5583	0.6338	0.1812	9.1873	0.5512
23/03/2017	4	0.9522	2.1232	1.1381	4.2700	1.3731	8.8584	2.8535	0.9071
06/04/2017	1	1.2239	0.8230	0.8268	8.3941	3.5295	2.6107	1.2478	1.5210
13/04/2017	2	1.1363	3.9313	7.7368	0.3261	2.8246	0.5408	2.6611	1.9623
20/04/2017	3	1.4813	0.4916	0.1510	2.8075	1.2823	2.1958	4.8295	0.5186
04/05/2017	1	0.2103	3.4676	1.4528	2.1899	2.3815	0.6109	3.0979	0.4748
11/05/2017	2	0.8813	2.4427	1.6409	3.0538	0.7933	0.1957	0.0487	0.2920
18/05/2017	3	0.5486	2.4527	3.1509	0.1158	0.0179	0.6572	0.2126	0.4609
01/06/2017	1	1.7680	2.5877	0.1904	0.9850	0.2890	0.8448	0.8230	0.4802
08/06/2017	2	0.7165	1.9929	0.4721	0.5096	0.7618	0.9745	2.5229	0.4881
14/06/2017	3	0.3512	0.2794	0.5924	0.3331	1.6359	2.2999	0.2776	0.2295
22/06/2017	4	1.0781	1.4923	1.6625	2.0503	3.4280	1.7695	1.8778	0.9479
06/07/2017	1	0.1856	1.8788	2.5315	0.9889	0.8029	1.0283	1.1027	1.3402
13/07/2017	2	0.3443	2.2241	0.0789	0.2270	0.7441	0.3613	1.6272	1.0800
20/07/2017	3	0.1551	1.1490	0.6993	0.1564	0.5110	0.7723	3.5107	0.8326
03/08/2017	1	1.6980	1.0630	0.1082	0.7038	2.5132	5.5972	4.8920	1.4247
10/08/2017	2	0.3325	0.0953	1.0234	2.8372	5.6374	5.3410	4.3244	1.2874
17/08/2017	3	1.2824	2.2929	4.0430	5.9525	5.7865	4.1720	4.7728	1.4356
31/08/2017	1	1.5272	7.1291	2.2427	2.1103	1.6143	3.5929	2.8037	1.7930
06/09/2017	2	1.4178	7.7946	4.5446	3.5932	0.2492	3.9339	1.9063	2.9771
14/09/2017	3	0.2102	5.7135	2.4109	3.5462	2.7557	1.2207	4.3791	1.3246
21/09/2017	4	1.7265	5.3269	3.1049	2.1337	2.9910	3.7982	1.0811	1.7911
05/10/2017	1	1.6884	5.5842	1.3690	0.8022	3.1446	2.9701	6.2000	1.4325
11/10/2017	2	3.0324	1.5615	0.6486	3.0200	2.3704	6.7769	2.4810	1.7702
19/10/2017	3	0.4077	1.1642	0.8776	2.5271	2.8870	0.1533	0.4411	0.2655
01/11/2017	1	1.1061	2.0913	6.3356	1.4787	2.7000	5.2013	8.5438	2.2045
09/11/2017	2	2.0820	5.7572	2.2308	4.0845	6.2232	9.7870	7.2108	0.9357
16/11/2017	3	2.8334	0.4576	3.7492	5.1883	8.1314	5.4456	1.3489	0.6220
30/11/2017	1	1.3483	3.1639	9.5069	6.9389	4.1458	10.7380	2.3413	0.9871
14/12/2017	3	1.5598	2.3290	0.9114	7.0283	0.0595	1.6381	2.0757	0.2363
21/12/2017	4	1.3689	2.9832	11.1363	1.1925	0.6699	2.2158	3.6766	0.7847
Média (MAPE)		1.3666	3.3008	2.8834	2.9260	2.5254	3.2341	3.3197	1.0943
Mediana		1.1801	2.3110	2.1339	2.1649	2.0032	2.2058	2.5020	1.0114
Máximo		7.9231	12.3467	11.1363	8.5765	8.6718	10.7380	10.4244	2.9771
Mínimo		0.1551	0.0953	0.0789	0.1158	0.0115	0.1533	0.0487	0.2295

Tabela 18 Erros absolutos e MAD (MW) das previsões semanais geradas nas REVO para o subsistema Sul

Data das revisões / Revisão		Semanas (horizonte de previsão inicia na semana 1 e termina na semana 6)						
		Corrente	1	2	3	4	5	6
12/01/2017	2	154.84	281.01	290.05	260.26	52.36	161.21	1406.94
19/01/2017	3	30.27	536.05	529.09	138.01	523.06	1228.70	1188.54
02/02/2017	1	77.89	1197.04	543.92	1157.53	961.88	1172.12	260.35
09/02/2017	2	213.86	736.35	1211.55	946.82	1102.04	138.60	116.14
15/02/2017	3	586.58	1009.55	862.11	1025.95	165.26	255.36	146.99
02/03/2017	1	996.20	1569.05	240.57	103.55	96.57	236.76	70.99
09/03/2017	2	75.92	126.08	452.46	314.66	1.31	144.78	718.68
16/03/2017	3	37.61	95.16	19.31	63.57	69.86	19.29	971.87
23/03/2017	4	107.62	242.65	129.59	470.67	146.22	937.08	291.06
06/04/2017	1	139.36	90.72	88.05	887.97	360.02	282.32	133.60
13/04/2017	2	125.25	418.64	818.43	33.26	305.44	57.91	286.99
20/04/2017	3	157.75	52.01	15.40	303.59	137.30	236.81	524.13
04/05/2017	1	21.45	374.98	155.56	236.18	258.46	66.31	321.27
11/05/2017	2	95.30	261.54	176.97	331.41	86.10	20.29	5.22
18/05/2017	3	58.74	264.52	341.96	12.57	1.85	70.50	22.81
01/06/2017	1	191.87	280.86	19.75	105.67	31.00	90.79	88.69
08/06/2017	2	77.77	206.67	50.65	54.68	81.88	105.01	275.62
14/06/2017	3	36.42	29.98	63.56	35.80	176.28	251.25	29.67
22/06/2017	4	115.66	160.10	178.68	220.93	374.49	189.15	201.66
06/07/2017	1	19.95	202.45	276.55	105.71	86.23	110.90	117.77
13/07/2017	2	37.11	242.97	8.44	24.38	80.25	38.59	175.04
20/07/2017	3	16.95	122.83	75.11	16.87	54.57	83.08	385.95
03/08/2017	1	182.36	114.64	11.55	75.71	276.29	596.54	549.67
10/08/2017	2	35.87	10.18	110.09	311.91	600.83	600.12	484.00
17/08/2017	3	136.96	246.66	444.47	634.42	650.18	466.93	531.31
31/08/2017	1	167.89	759.82	251.99	236.18	179.70	386.27	299.93
06/09/2017	2	151.11	875.82	508.640	399.99	26.79	420.83	213.03
14/09/2017	3	23.62	639.46	268.39	381.25	294.79	136.42	480.14
21/09/2017	4	193.23	592.99	333.81	228.25	334.23	416.45	114.39
05/10/2017	1	181.52	597.36	152.98	87.95	332.72	326.49	693.44
11/10/2017	2	324.39	174.50	71.12	319.54	260.57	757.97	281.13
19/10/2017	3	45.56	127.65	92.86	277.80	322.90	17.37	51.29
01/11/2017	1	117.03	229.90	708.61	167.55	313.97	630.71	1076.11
09/11/2017	2	228.87	643.92	252.79	474.98	754.62	1232.69	880.68
16/11/2017	3	316.90	51.85	435.99	629.13	1024.17	665.09	140.29
30/11/2017	1	156.79	383.65	1197.41	847.47	431.15	1175.21	279.89
14/12/2017	3	196.46	284.45	94.79	769.21	7.12	206.78	258.14
21/12/2017	4	167.19	310.25	1218.80	142.55	84.56	275.57	454.69
Média (MAD)		157.90	382.74	334.26	337.73	290.71	373.90	382.32
Mediana		131.10	263.03	246.28	248.22	219.08	244.03	280.51
Máximo		996.20	1569.05	1218.80	1157.53	1102.04	1232.69	1406.94
Mínimo		16.95	10.18	8.44	12.57	1.31	17.37	5.22

A4. Resultados para o submercado Sudeste

A4.1 Resultados para REV0

Na Tabela A19 apresenta-se os valores de MAPE e U-Theil para as previsões mensais referentes aos 12 casos do conjunto REV0 do subsistema Sudeste. Observa-se que em apenas 2 dos 11 meses avaliados o U-Theil superou a unidade, i.e., na maior parte do período avaliado as previsões mensais geradas pelo PrecvargaPMO foram melhores que as previsões obtidas pelo método de Holt-Winters. Os maiores erros de previsão nos meses 1 e 2 do horizonte de previsão foram da ordem de 3,5% e 4,8% respectivamente e na média, os erros relativos foram de 1,5% e 1,7% para os meses 1 e 2 respectivamente.

Tabela 19 - Erros relativos e MAPE (%) para os casos REV0 no subsistema Sudeste

Data da REV 0	Mês Corrente	Previsão 1 mês à frente	Previsão 2 meses à frente	U-Theil
25/01/2017	0.2259	2.2240	4.7542	0.7810
22/02/2017	0.2356	2.1453	3.1328	0.5013
29/03/2017	0.0227	3.5150	0.4867	0.6330
26/04/2017	0.8923	1.3282	2.1329	0.9936
24/05/2017	0.8169	0.7546	2.6394	0.7700
28/06/2017	0.1395	2.7212	0.9999	1.2032
26/07/2017	0.7352	0.3754	1.0102	0.6527
23/08/2017	0.1442	0.8897	0.8174	0.9886
27/09/2017	0.0248	0.8607	0.1651	0.5376
25/10/2017	0.3678	0.5258	0.9149	0.4559
22/11/2017	1.0732	1.8209	0.4248	1.7386
27/12/2017	0.8104	0.5414	2.3584	0.7721
Média (MAPE)	0.4574	1.4752	1.6531	0.8356
Mediana	0.3017	1.1090	1.0051	0.7711
Máximo	1.0732	3.5150	4.7542	1.7386
Mínimo	0.0227	0.3754	0.1651	0.4559

Já na Tabela A20 apresenta-se os valores de MAD (MW) para as previsões mensais referentes aos 11 casos do conjunto REV0 do subsistema Sul.

Tabela A20 - Erros absolutos e MAD (MW) para os casos REV0 no subsistema Sudeste

Data da REV 0	Mês Corrente	Previsão 1 mês à frente	Previsão 2 meses à frente
25/01/2017	90.2065	911.8756	1927.0203
22/02/2017	96.5986	869.5586	1183.7405
29/03/2017	9.2177	1328.1802	179.6359
26/04/2017	337.1632	490.2655	779.6962
24/05/2017	301.5217	275.8509	934.4894
28/06/2017	50.9930	963.4576	365.6458
26/07/2017	260.3204	137.2846	386.5056
23/08/2017	52.7389	340.4100	319.0275
27/09/2017	9.4757	335.9334	63.1233
25/10/2017	143.5443	201.0609	353.2755
22/11/2017	410.3634	703.0760	170.2574
27/12/2017	312.8894	216.9815	940.9210
Média (MAD)	172.9194	564.4946	633.6115
Mediana	120.0715	415.3377	376.0757
Máximo	410.3634	1328.1802	1927.0203
Mínimo	9.2177	137.2846	63.1233

A seguir, na Figura A4, apresentam-se as previsões semanais para as 12 REV0 do subsistema Sudeste. A primeira semana é a semana corrente, as demais correspondem ao horizonte de previsão. As previsões de temperatura são disponibilizadas apenas para a segunda semana.

Figura A4 Previsões semanais e respectivas métricas para as REVO do subsistema Sudeste

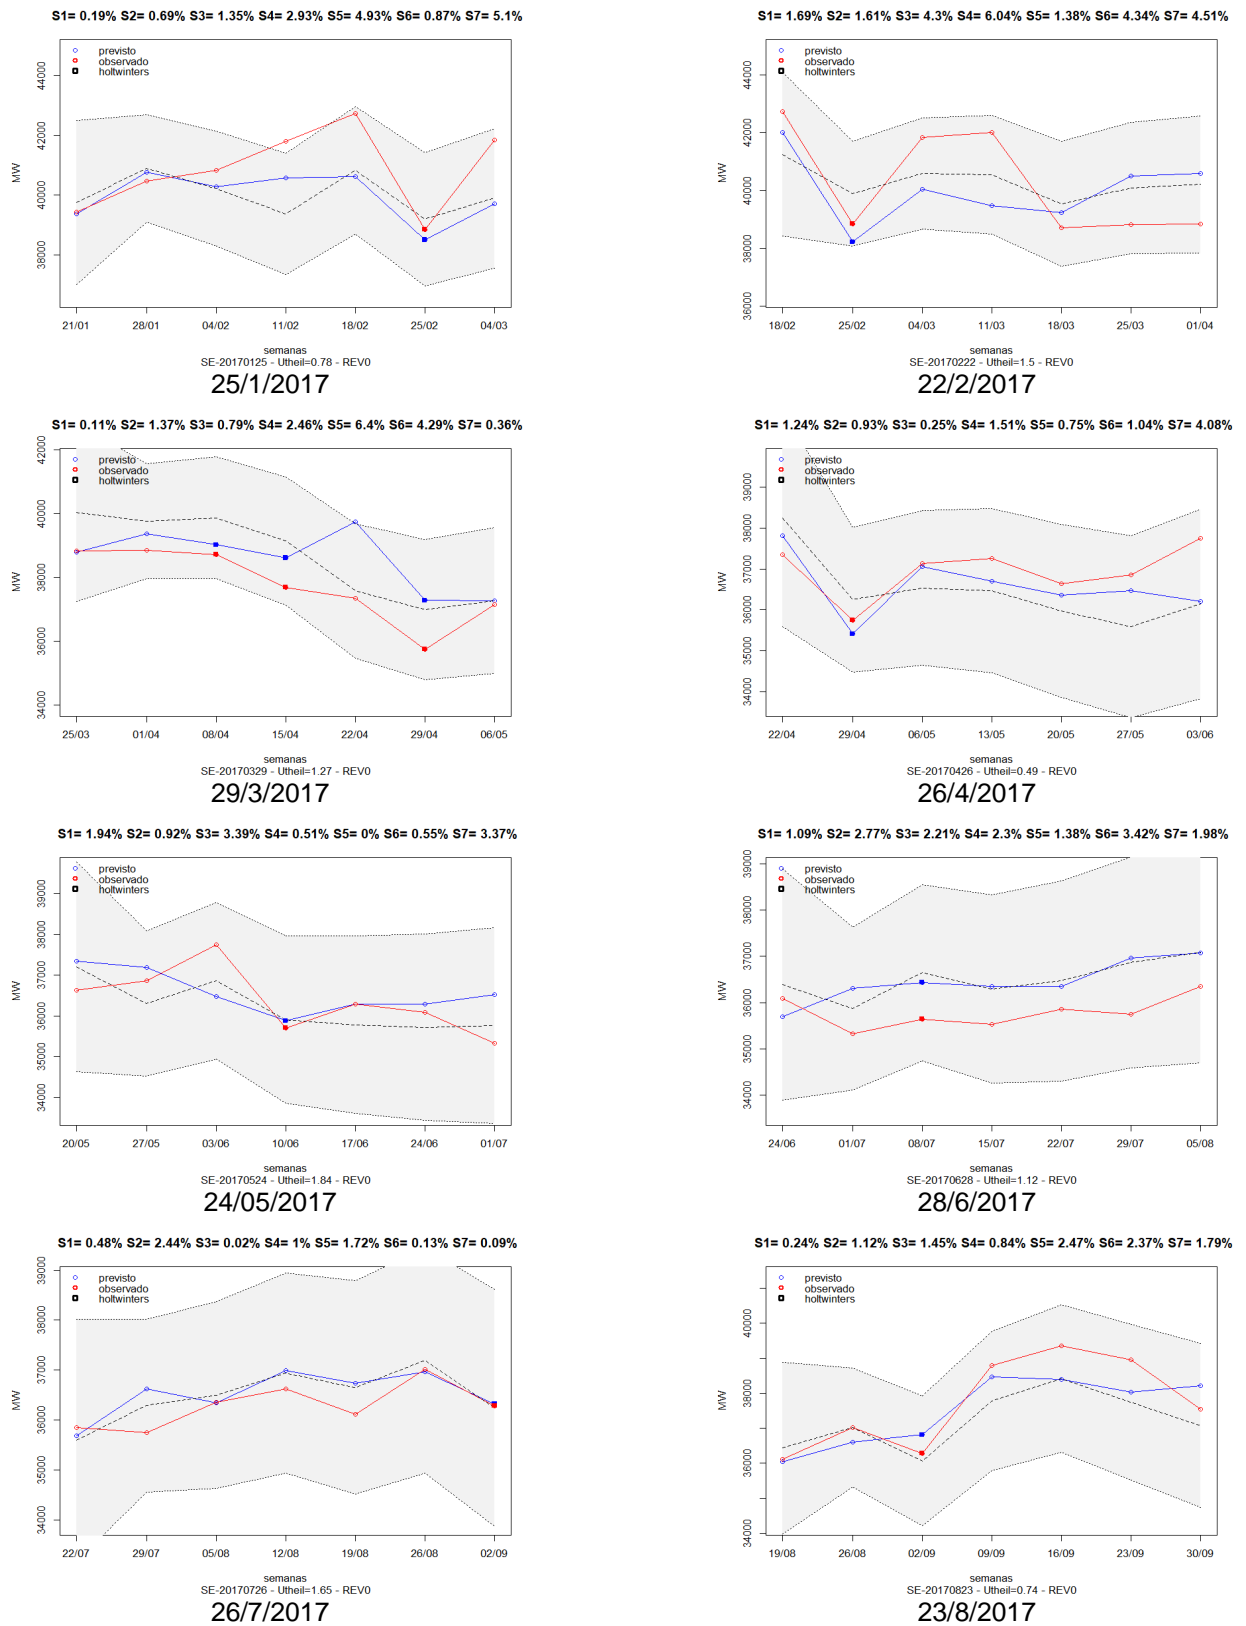
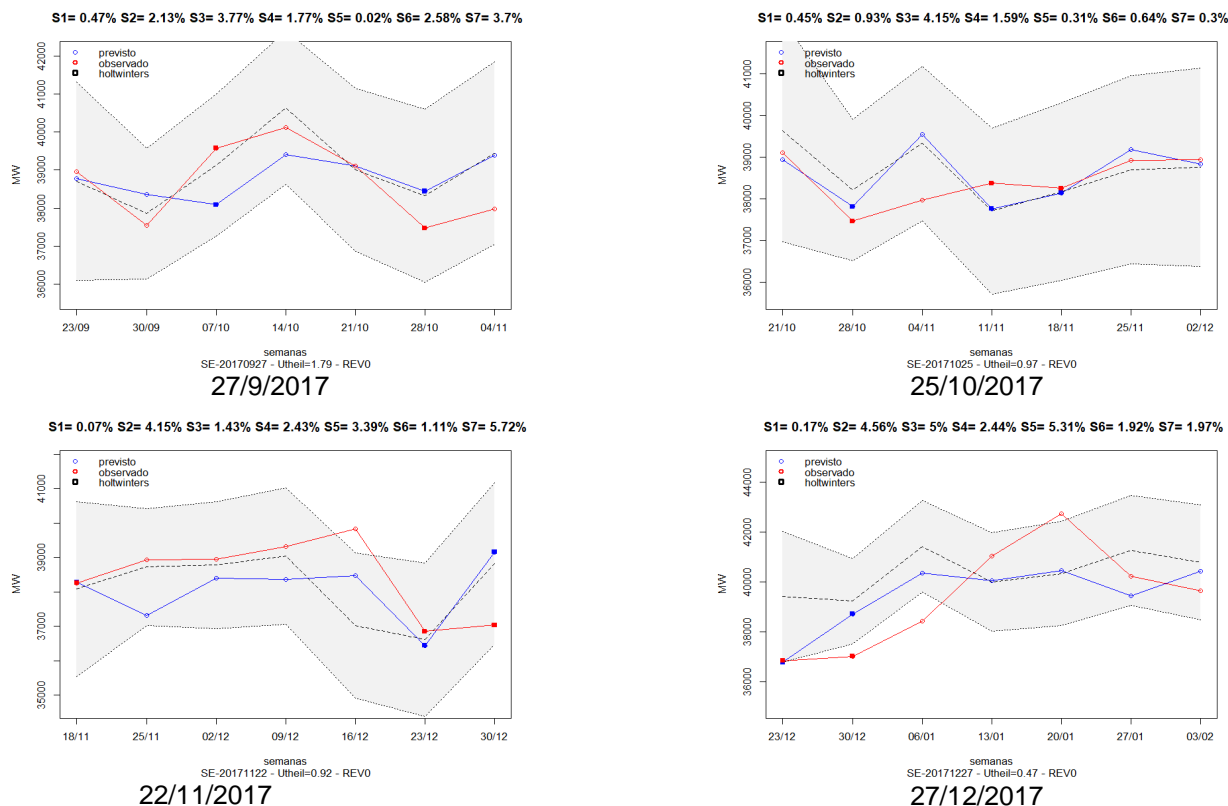


Figura A4 Previsões semanais e respectivas métricas para as REVO do subsistema Sudeste (continuação)



Ainda na Figura A4, as datas indicadas nos eixos das abscissas correspondem às datas de início das semanas operativas. A previsão gerada com base no método da decomposição clássica é representada pela linha tracejada no meio da região definida pelos limites dos intervalos de confiança, tal previsão é utilizada como referência no cálculo da estatística U-Theil. Adicionalmente, na Figura A4 os pontos mais destacados com quadrados indicam semanas com feriados.

Conforme indicado na Figura A4 e na Tabela A21, em 6 dos 12 casos analisados o U-Theil foi menor que a unidade, i.e., em termos globais o método da decomposição clássica gerou previsões equivalentes às obtidas pelo PrevCargaPMO, apesar das informações de temperatura (para a primeira semana) e tipos de dias (feriados e dias especiais) em cada semana. Ainda conforme ilustrado na Figura A4, na maior parte das vezes, os intervalos de previsão com 95% gerados pelo método da decomposição clássica cobrem os valores verificados e as previsões geradas pelo PrevCargaPMO. Vale ressaltar que entre as duas previsões semanais apresentadas na Figura A4 (linhas em azul e tracejada), apenas as previsões semanais apresentadas pelo PrevCargaPMO (em azul) são compatibilizadas com a previsão mensal para o primeiro mês.

Os valores de MAPE apresentados na Tabela A21 indicam um MAPE de 1,7% na semana 1 (primeira semana do horizonte de previsão). Conforme ilustrado na Figura A4 e na Tabela A21, na maioria dos meses o PrevCargaPMO apresenta um bom resultado para a primeira semana com exceção do mês de Novembro, neste mês a decomposição clássica apresentou um resultados superior. Na sequência, na Tabela A22, apresentam-se os erros absolutos e MAD (MW) das previsões semanais.

Tabela A21 - Erros relativos e MAPE(%) das previsões semanais geradas nas REV0 para o subsistema Sudeste

Data da REV 0	Semanas (horizonte de previsão inicia na semana 1 e termina na semana 6)							U-Theil
	corrente	1	2	3	4	5	6	
25/01/2017	0.1932	0.6935	1.3475	2.9298	4.9320	0.8734	5.0957	0.7772
22/02/2017	1.6885	1.6090	4.2996	6.0370	1.3772	4.3400	4.5121	1.5025
29/03/2017	0.1051	1.3730	0.7936	2.4604	6.3956	4.2880	0.3571	1.2695
26/04/2017	1.2379	0.9310	0.2481	1.5062	0.7516	1.0362	4.0839	0.4867
24/05/2017	1.9386	0.9200	3.3916	0.5116	0.0011	0.5473	3.3741	1.8412
28/06/2017	1.0912	2.7660	2.2135	2.2967	1.3841	3.4178	1.9792	1.1221
26/07/2017	0.4821	2.4439	0.0175	0.9970	1.7201	0.1301	0.0917	1.6538
23/08/2017	0.2384	1.1177	1.4499	0.8387	2.4679	2.3689	1.7943	0.7423
27/09/2017	0.4734	2.1316	3.7710	1.7681	0.0165	2.5831	3.6992	1.7877
25/10/2017	0.4466	0.9302	4.1539	1.5871	0.3065	0.6356	0.2998	0.9678
22/11/2017	0.0656	4.1526	1.4349	2.4258	3.3932	1.1052	5.7239	0.9164
27/12/2017	0.1689	4.5586	5.0013	2.4402	5.3079	1.9189	1.9731	0.4706
Média (MAPE)	0.6775	1.9689	2.3435	2.1499	2.3378	1.9370	2.7487	1.1282
Mediana	0.4600	1.4910	1.8317	2.0324	1.5521	1.5121	2.6766	1.0450
Máximo	1.9386	4.5586	5.0013	6.0370	6.3956	4.3400	5.7239	1.8412
Mínimo	0.0656	0.6935	0.0175	0.5116	0.0011	0.1301	0.0917	0.4706

Tabela A22 Erros relativos e MAD(MW) das previsões semanais geradas nas REV0 para o subsistema Sudeste

Data da REV 0	Semanas (horizonte de previsão inicia na semana 1 e termina na semana 6)						
	corrente	1	2	3	4	5	6
25/01/2017	76.2160	280.7255	550.2567	1224.6426	2107.8471	339.2709	2132.0380
22/02/2017	721.6487	625.0256	1798.9443	2536.0697	533.0138	1685.1317	1752.5867
29/03/2017	40.8214	533.3117	307.2486	927.2243	2388.6524	1532.8323	132.6460
26/04/2017	462.3491	332.8109	92.1510	561.2305	275.3259	381.8862	1541.8445
24/05/2017	710.1774	339.0684	1280.4757	182.6644	0.3911	197.5082	1191.9631
28/06/2017	393.8285	977.1387	789.0077	816.0348	496.2241	1221.8752	719.4326
26/07/2017	172.8488	873.7031	6.3453	365.0991	621.2894	48.1546	33.2787
23/08/2017	86.1258	413.7537	526.1085	325.4322	971.4370	922.9354	673.7578
27/09/2017	184.4278	800.4053	1492.5083	709.2666	6.4584	967.9381	1404.8679
25/10/2017	174.6898	348.5658	1577.5666	609.0873	117.2599	247.4445	116.7521
22/11/2017	25.0810	1616.7615	558.8972	953.8581	1351.2178	407.3075	2119.8896
27/12/2017	62.2264	1688.3236	1922.8434	1001.7982	2268.2126	772.0095	782.5406
Média (MAD)	259.2034	735.7995	908.5295	851.0340	928.1108	727.0245	1050.1331
Mediana	173.7693	579.1686	673.9525	762.6507	577.1516	589.6585	987.2518
Máximo	721.6487	1688.3236	1922.8434	2536.0697	2388.6524	1685.1317	2132.0380
Mínimo	25.0810	280.7255	6.3453	182.6644	0.3911	48.1546	33.2787

A4.2 Resultados para demais revisões semanais

Os erros relativos (%) das previsões semanais geradas ao longo de 38 revisões semanais (não inclui as REV0) são apresentados na Tabela A23 a seguir. Na sequência, na Tabela A24, são apresentados os respectivos erros absolutos (MW). O MAPE na primeira semana das revisões semanais foi da ordem de 2,4%, acima do MAPE das REV0 apresentado na Tabela A21. Os gráficos com as previsões, valores verificados e intervalos de confiança das revisões semanais encontram-se no anexo deste relatório.

Tabela A23 - Erros relativos e MAPE (%) das previsões semanais geradas nas REVO para o subsistema Sudeste

Data das revisões / Revisão		Semanas (horizonte de previsão inicia na semana 1 e termina na semana 6)							U-Theil
		Corrente	1	2	3	4	5	6	
12/01/2017	2	0.8845	4.5096	3.1014	3.3633	0.6594	1.2157	3.8396	0.5787
19/01/2017	3	0.0023	0.1154	0.8867	0.2629	1.9156	3.9450	1.1997	0.4047
02/02/2017	1	0.0082	1.2839	2.2673	4.0788	0.4478	4.3506	5.1373	0.6040
09/02/2017	2	0.7563	3.3170	4.3067	0.3030	4.3136	4.7081	2.4040	0.8052
15/02/2017	3	0.0311	4.4341	5.0301	3.8534	4.2312	4.5239	3.0557	1.7210
02/03/2017	1	4.3938	5.9371	3.6229	2.0852	1.6650	4.2509	0.7591	0.7321
09/03/2017	2	0.5355	3.9693	3.3326	4.1029	3.0695	1.6563	4.8207	0.8542
16/03/2017	3	0.3554	2.8792	3.3095	4.5291	1.2094	5.7685	8.6466	1.1619
23/03/2017	4	0.5694	0.3503	2.4208	2.6904	0.4992	4.7858	5.6221	0.4781
06/04/2017	1	0.9054	4.3688	0.0866	3.3738	3.8025	0.7148	1.4322	2.3163
13/04/2017	2	0.2695	0.1402	3.7649	2.8746	0.5395	0.9546	0.0445	1.2507
20/04/2017	3	0.6787	0.0241	1.5207	0.4590	0.8954	0.1052	1.1848	0.0827
04/05/2017	1	1.0466	0.8890	2.9627	1.7244	1.8957	5.8026	5.5264	0.8910
11/05/2017	2	0.4864	1.4708	0.0106	1.5466	3.7774	0.6569	2.1693	0.5389
18/05/2017	3	0.5926	0.6390	0.5203	3.1055	0.3531	0.0108	1.0559	0.5336
01/06/2017	1	1.8885	6.0517	0.2034	1.7152	0.6343	2.7665	1.8302	3.0097
08/06/2017	2	0.0880	0.2505	0.8447	2.1452	4.2459	3.4814	3.0946	1.4881
14/06/2017	3	1.2243	0.4110	1.2190	3.1183	3.1820	2.6197	1.5262	0.6586
22/06/2017	4	0.9340	1.8168	2.7843	2.0094	2.1749	1.1148	3.5117	1.1961
06/07/2017	1	0.9470	0.2879	1.4771	0.9041	2.0700	1.2547	0.7862	0.3886
13/07/2017	2	0.4464	0.7275	0.7305	1.5504	0.4957	0.8083	1.6043	0.7252
20/07/2017	3	0.3341	0.4864	1.1076	0.0788	0.9322	1.2087	0.1585	0.5160
03/08/2017	1	1.3067	0.4225	0.2982	0.3683	0.4277	0.2588	2.1364	0.7404
10/08/2017	2	0.7872	0.6623	1.1008	0.3181	0.0289	3.2379	3.1141	1.3705
17/08/2017	3	0.1886	2.3548	0.0252	0.0274	2.7286	2.9506	2.0061	1.0126
31/08/2017	1	1.0058	1.4539	0.2150	0.0503	0.1356	1.2146	3.0104	0.3261
06/09/2017	2	0.4251	3.3996	3.1269	2.0233	0.1839	3.5865	0.1773	1.5849
14/09/2017	3	1.6255	6.4178	2.1320	1.9590	2.3874	2.2352	0.7643	1.2401
21/09/2017	4	0.3504	0.5988	4.0699	2.3849	0.1563	0.5115	2.2035	1.0151
05/10/2017	1	0.7198	6.2019	2.0693	0.6953	1.7518	2.4642	3.3819	1.9483
11/10/2017	2	1.6204	1.2377	0.2808	3.2695	2.9155	1.6018	3.0167	0.8564
19/10/2017	3	2.5516	0.6252	3.6339	2.8092	2.1585	0.7890	1.2841	1.2826
01/11/2017	1	0.4857	1.2821	2.1516	2.8625	0.6012	1.3609	1.8974	0.5126
09/11/2017	2	0.4167	6.6802	2.6863	1.5287	1.1709	2.2303	4.4797	0.8728
16/11/2017	3	1.5112	3.5453	0.8610	0.9216	1.5880	3.3950	0.9890	0.4762
30/11/2017	1	0.0301	2.5529	2.9038	4.5073	2.6521	7.2971	4.2657	0.8848
14/12/2017	3	2.2577	0.6729	0.9317	7.0279	4.0232	3.1211	7.2679	0.7340
21/12/2017	4	1.7536	7.9835	8.5341	5.5845	1.9805	5.4524	1.5033	1.0981
Média (MAPE)		0.9056	2.3803	2.1192	2.2687	1.7868	2.5898	2.6555	0.9708
Mediana		0.6993	1.3689	2.1007	2.0543	1.7084	2.3497	2.1529	0.8553
Máximo		4.3938	7.9835	8.5341	7.0279	4.3136	7.2971	8.6466	3.0097
Mínimo		0.0023	0.0241	0.0106	0.0274	0.0289	0.0108	0.0445	0.0827

Tabela A24 - Erros absolutos e MAD (MW) das previsões semanais geradas nas REV0 para o subsistema Sudeste

Data das revisões / Revisão		Semanas (horizonte de previsão inicia na semana 1 e termina na semana 6)						
		Corrente	1	2	3	4	5	6
12/01/2017	2	364.18	1786.39	1223.17	1361.52	269.29	508.13	1640.98
19/01/2017	3	0.92	45.49	358.94	107.34	800.69	1686.01	466.03
02/02/2017	1	3.34	524.29	947.73	1743.22	173.95	1820.27	2158.14
09/02/2017	2	308.84	1386.47	1840.60	117.71	1804.81	1977.82	930.43
15/02/2017	3	12.98	1895.05	1953.97	1612.26	1777.49	1750.89	1186.46
02/03/2017	1	1706.81	2484.07	1521.96	807.05	646.49	1651.11	293.89
09/03/2017	2	224.06	1667.47	1289.83	1593.04	1192.23	641.27	1816.70
16/03/2017	3	149.29	1114.35	1285.02	1759.18	468.22	2173.90	3229.36
23/03/2017	4	220.36	136.01	940.28	1041.64	188.12	1787.42	2009.74
06/04/2017	1	351.67	1691.46	32.64	1260.07	1359.29	265.50	533.64
13/04/2017	2	104.34	52.85	1406.15	1027.57	200.38	355.71	16.29
20/04/2017	3	255.76	9.01	543.59	170.48	333.63	38.54	436.66
04/05/2017	1	374.14	330.19	1103.94	631.72	698.67	2190.73	1973.00
11/05/2017	2	180.64	548.05	3.90	570.01	1426.12	234.51	787.26
18/05/2017	3	220.83	234.09	191.77	1172.46	126.06	3.93	381.07
01/06/2017	1	696.04	2284.75	72.63	622.45	228.93	977.31	652.37
08/06/2017	2	33.23	89.45	306.54	774.19	1499.92	1240.92	1099.55
14/06/2017	3	437.10	149.15	439.95	1101.59	1134.21	930.79	547.17
22/06/2017	4	338.95	655.66	983.59	716.22	772.75	399.69	1255.45
06/07/2017	1	334.53	102.63	524.82	324.16	740.05	456.09	287.89
13/07/2017	2	159.13	258.48	261.89	554.26	180.19	296.00	579.49
20/07/2017	3	118.70	174.38	395.98	28.65	341.37	436.59	58.66
03/08/2017	1	467.14	153.59	109.19	133.04	158.34	93.91	828.97
10/08/2017	2	286.17	242.53	397.60	117.75	10.47	1256.34	1225.81
17/08/2017	3	69.06	850.57	9.31	9.95	1058.75	1161.43	781.58
31/08/2017	1	372.34	527.56	83.42	19.80	52.82	456.10	1191.46
06/09/2017	2	154.26	1319.09	1230.84	788.26	69.05	1419.47	71.11
14/09/2017	3	630.71	2526.22	830.63	735.61	944.88	896.62	298.94
21/09/2017	4	137.92	233.31	1528.25	943.91	62.69	200.05	825.69
05/10/2017	1	270.29	2454.61	830.08	271.94	656.46	935.86	1297.92
11/10/2017	2	641.34	496.49	109.81	1225.16	1107.25	614.75	1154.18
19/10/2017	3	1023.53	244.51	1361.70	1066.88	828.42	301.85	499.95
01/11/2017	1	182.00	486.89	825.76	1095.18	234.06	530.06	746.09
09/11/2017	2	158.25	2563.76	1027.78	595.16	456.05	877.01	1783.88
16/11/2017	3	579.96	1356.42	335.23	358.96	624.43	1351.93	364.49
30/11/2017	1	11.74	994.35	1141.80	1794.86	977.38	2702.56	1640.04
14/12/2017	3	887.76	267.95	343.36	2602.86	1546.79	1281.36	3105.79
21/12/2017	4	698.29	2942.16	3160.69	2147.06	813.09	2329.97	604.80
Média (MAD)		346.49	928.41	814.59	868.50	683.26	1006.12	1020.02
Mediana		263.03	525.93	827.92	781.23	651.48	913.71	806.48
Máximo		1706.81	2942.16	3160.69	2602.86	1804.81	2702.56	3229.36
Mínimo		0.92	9.01	3.90	9.95	10.47	3.93	16.29

A5. Conclusões

A seguir, na Tabela A25, apresenta-se um resumo do desempenho dos resultados encontrados ao longo dos 50 casos avaliados. O PrevCargaPMO aplica a mesma estratégia de previsão para todos os subsistemas, porém os resultados obtidos para o subsistema Sul apontam para a necessidade de revisar o modelo para este subsistema. Adicionalmente, os resultados alcançados indicam que a prioridade das previsões semanais calculadas pelo modelo SVM deve ser reavaliada, bem como a estratégia para seleção entre das previsões calculadas pelos dois modelos SVM para previsão semanal. Vale destacar o desempenho diferenciado do previsor entre as revisões tipo REV0 e demais revisões semanais.

Tabela A25 MAPE (%) na primeira semana e no primeiro mês

Subsistema	MAPE % da primeira semana da REV0 (12 casos)	MAPE % da primeira semana das revisões semanais (38 casos)	MAPE % do primeiro mês da REV0 (12 casos)
Norte	2.37	3.73	1.58
Nordeste	2.05	2.54	1.45
Sul	3.98	3.30	2.72
Sudeste	1.97	2.38	1.47

No total dos 50 casos analisados para cada subsistema, 12 correspondem à revisões tipo REV0 e 38 são para as demais revisões. Nas revisões tipo REV0 foram apresentados os erros absolutos e relativos de 36 previsões mensais (mês corrente mais dois meses de horizonte vezes 12 casos REV0) e 77 previsões semanais (semana corrente mais horizonte de seis semanas vezes 11 meses). A seguir, na Tabela A26, apresentam-se os percentuais de previsões com erros abaixo de 3% no conjunto de previsões realizadas.

Tabela A26 - Previsões semanais e mensais com erros menores que 3% nas revisões tipo REV0

Subsistema	Total de previsões semanais com erros relativos menores que 3%	Percentual de previsões semanais com erros relativos menores que 3%	Total de previsões mensais com erros relativos menores que 3%	Percentual de previsões mensais com erros relativos menores que 3%
Norte	61	73%	31	86%
Nordeste	66	79%	34	94%
Sul	45	54%	28	78%
Sudeste	63	75%	33	92%

Nos 38 casos referentes às revisões semanais foram apresentados os erros absolutos e relativos de 266 previsões semanais (semana corrente mais seis semanas de horizonte vezes x 38 casos). A seguir, na Tabela A27, apresentam-se os percentuais de previsões com erros abaixo de 3% no conjunto de previsões realizadas.

Tabela A27 - Previsões semanais com erros menores que 3% nas revisões semanais (exceto REV0)

Subsistema	Total de previsões semanais com erros relativos menores que 3%	Percentual de previsões semanais com erros relativos menores que 3%
Norte	189	71%
Nordeste	200	75%
Sul	181	68%
Sudeste	190	71%

Nas Tabelas 28 e 29 apresentam-se os totais de previsões com erros menores que 3% apenas para o primeiro mês e primeira semana. Os resultados sugerem a necessidade de revisar a previsão para a primeira semana, sobretudo nos subsistemas Norte e Sul.

Tabela A28 - Previsões para a primeira semana e primeiro mês com erros menores que 3% nas revisões tipo REV0

Subsistema	Total de previsões para a primeira semana com erros relativos menores que 3%	Percentual de previsões para a primeira semana com erros relativos menores que 3%	Total de previsões para o primeiro mês com erros relativos menores que 3%	Percentual de previsões para o primeiro mês com erros relativos menores que 3%
Norte	8	67%	11	92%
Nordeste	10	83%	11	92%
Sul	5	42%	7	58%
Sudeste	10	83%	11	92%

Tabela A29 - Previsões para a primeira semana com erros menores que 3% nas revisões semanais (exceto REV0)

Subsistema	Total de previsões para a primeira semana com erros relativos menores que 3%	Percentual de previsões para a primeira semana com erros relativos menores que 3%
Norte	18	47%
Nordeste	26	68%
Sul	24	63%
Sudeste	25	66%

Na Tabela A30 apresentam-se as médias dos erros relativos (MAPE) para a primeira semana ao longo de todos os 49 casos analisados (REV0 e demais revisões) em cada subsistema. Na Figura A5, os *boxplots* ilustram as distribuições dos erros relativos para a primeira semana do horizonte e em cada subsistema. Ainda na Figura A5, a linha em azul indica o patamar de 3%. Ressalta-se que em todos os subsistemas as medianas dos erros relativos das previsões para a primeira semana estão abaixo do patamar de 3%. Ao contrário da média (MAPE), a mediana não é afetada pelos erros extremos de algumas previsões. Na Tabela A31 apresenta-se um resumo estatístico dos erros relativos das previsões para a primeira semana. Os resultados mostram um resultado satisfatório para as previsões para primeira semana nos subsistemas Nordeste e Sudeste, inclusive nestes a dispersão dos erros é menor. No subsistema Nordeste, apesar de dois erros extremos o MAPE é menor que 3%. Vale ressaltar a similaridade entre as distribuições dos subsistemas Norte e Sul.

Tabela A30 - MAPE (%) na primeira semana de todas as revisões, inclusive as REV0

Subsistema	MAPE % da primeira semana (49 casos)
Norte	3.40
Nordeste	2.42
Sul	3.46
Sudeste	2.28

Figura A4 - *Boxplots* dos erros relativos para a primeira semana em cada subsistema

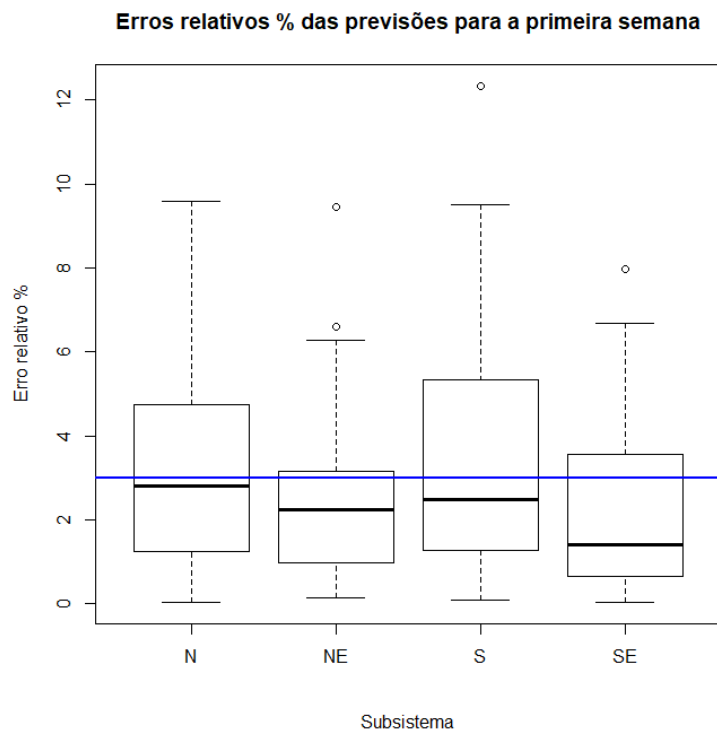


Tabela A31 - Resumo estatístico dos erros relativos (%) das previsões para a primeira semana

Subsistema	Casos	Mínimo	1º Quartil	Mediana	Média (MAPE)	3º Quartil	Máximo
Norte	50	0.0301	1.2436	2.7971	3.4036	4.7363	9.5913
Nordeste	50	0.1357	0.9636	2.2448	2.4209	3.1413	6.2900
Sul	50	0.0953	1.2751	2.4841	3.4630	5.3268	9.5177
Sudeste	50	0.0241	0.6623	1.4135	2.2816	3.5453	6.6801