

Centro de Pesquisas de Energia Elétrica - CEPEL



Relatório Técnico

Nº/Ano: 6061/2019 **Nº de Páginas:** 37 **Nº de Anexos:** 0

Título: Modelo de Previsão de Carga para o DESSEM - PrevCargaDESSEM

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 PrevCargaDESSEM, modelo de previsão de carga para o DESSEM.

Autores:
José Francisco Moreira Pessanha (Cepel)
Victor Andrade de Almeida (Cepel)

Palavras-Chave:
Previsão de carga
DESSEM
Classificação: CONTROLADO

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

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

Aprovação

Raul Balbi Sollero
Diretor de Pesquisa, Desenvolvimento e Inovação
29/10/2019

CEPEL

Centro de Pesquisas de Energia Elétrica

MANUAL DO MODELO DE PREVISÃO DE CARGA PARA O DESSEM – VERSÃO 1.22

- PrevcargaDESSEM -

2019

Índice

1. INTRODUÇÃO	4
2. MÉTODOS DE PREVISÃO USADOS NO PREVCARGADESSEM	7
2.1 Introdução.....	7
2.2 Redes Neurais Artificiais	7
2.3 Máquinas de vetor de suporte para regressão.....	12
2.4 Regressão quantílica	15
2.5 Previsão combinada.....	15
3. MODELAGEM DA PREVISÃO DE CARGA NO PREVCARGADESSEM	16
3.1 Introdução.....	16
3.2 Metodologia de tratamento de dados.....	17
3.2.1 Tratamento dos dados de temperatura.....	17
3.2.2 Tratamento dos dados da parcela supervisionada da carga.....	17
3.3 Modelos de previsão de carga	20
3.3.1 Modelo de previsão para dias normais.....	20
3.3.2 Modelo de previsão para feriados e dias especiais.....	22
3.3.3 Avaliação a posteriori.....	25
4. PROGRAMA PREVCARGADESSEM	27
4.1 Instalação	27
4.2 Arquivos de dados.....	27
4.2.1 Histórico da carga global em base horária	27
4.2.2 Pesos das previsões no cálculo da previsão combinada	28
4.2.3 Lista de feriados e dias especiais.....	28
4.2.4 Horário de verão.....	29
4.2.5 Dados do horizonte de previsão.....	29
4.2.6 Patamares de carga	30
4.2.7 Separador decimal.....	30
4.2.8 Histórico das temperaturas horárias.....	30
4.2.9 Histórico das temperaturas horárias.....	31
5. EXECUÇÃO EM AMBIENTE R.....	32
6. ACESSANDO AS PREVISÕES GERADAS PELO PREVCARGADESSEM.....	34
7. REFERÊNCIAS BIBLIOGRÁFICAS	36

1. INTRODUÇÃO

As previsões de carga até 8 (oito) dias à frente constituem informações fundamentais para o Modelo de Despacho Hidrotérmico de Curto Prazo (DESSEM), modelo de referência para a definição do CMO e preços horários na comercialização de energia. As previsões devem ser expressas em MWmédio e fornecidas em intervalos semi-horários para os dois primeiros dias do horizonte de previsão e agregadas em patamares de carga leve, média e pesada (MWmédio por patamar) para os demais dias do horizonte de previsão.

A dinâmica e cronologia da previsão ocorre da seguinte forma: o horizonte de previsão é dinâmico e sempre se inicia com a produção de uma Função de Custo Futuro (FCF) pelo modelo DECOMP para o PMO ou suas revisões. Assim, toda quinta-feira será produzida uma FCF para a semana operativa que começa no sábado e termina na sexta-feira seguinte. Trata-se, portanto, de uma janela de tempo que se fecha até chegar em uma quinta-feira, onde uma nova FCF será produzida.




Figura 1. Dinâmica e Cronologia da Execução do PrevcargaDESSEM.

Seguindo a nomenclatura da Figura 1, para os dias “D” e “D+1” as previsões são disponibilizadas em intervalos semi-horários para cada subsistema, e para os demais dias até o final da semana operativa as previsões da carga são apresentadas em patamares (pesada, média e leve), conforme ilustrado pela curva em azul na Figura 2. Ainda na Figura 2, a linha em preto representa a previsão em base semi-horária. Inicialmente o PrevcargaDESSEM calcula as previsões em base horária e na sequência, por meio de interpolações por *splines* cúbicas (DUBINSKY & ELPERIN, 1997), gera as previsões semi-horárias para todo o horizonte de previsão. Por fim, as previsões semi-horárias são agrupadas por patamar de carga (PESSANHA et al, 2018).

A carga a ser prevista segue o conceito de carga global, que é o mesmo utilizado na Programa Mensal da Operação Energética – PMO. Para isso, se faz necessário que as séries temporais: de geração despachada (relativas às usinas Tipo I, Tipo IIA e Tipo IIC, segundo a definição de modalidade de usina constante no Módulo 26 dos Procedimentos de Rede do ONS), de geração das usinas não supervisionadas (demais modalidades de usinas) e dos correspondentes intercâmbios sejam disponibilizados para que somadas possam constituir os respectivos históricos da carga global das áreas e subsistemas.

De forma a automatizar o processamento da previsão de carga pelo ONS, o CEPEL desenvolveu o programa computacional PrevcargaDESSEM, cujas funções básicas incluem a leitura de dados (geração supervisionada, geração não supervisionada, temperatura, intercâmbio, datas de início e fim do horário de verão e lista de feriados/dias especiais), a composição da carga global verificada, o cálculo das previsões da carga e a exportação das previsões para o modelo DESSEM.




Figura 2. Previsão de carga com resolução semi-horária e por patamar.

Na Figura 3 tem-se uma ilustração do fluxo de processamento dos dados e obtenção das previsões pelo PrecvargaDESSEM. Conforme ilustrado na Figura 3, o modelo de previsão é alimentado com as parcelas que compõem a geração supervisionada (dados horários) e não supervisionada (dados horários e diários), intercâmbio (dados horários), além de dados de temperatura horária, datas de início e fim do horário de verão e a lista de feriados e dias especiais na Tabela 1. A montagem da série histórica da carga global em base horária é realizada internamente pelo PrecvargaDESSEM (carga global = geração supervisionada - intercâmbio + geração não supervisionada). Na sequência por meio de modelos baseados em algoritmos de Máquina de Vetor de Suporte - *Support Vector Machine* (HAMEL, 2009) e Redes Neurais Artificiais (HAYKIN, 2009) são geradas previsões horárias da carga global. Na sequência, as previsões horárias passam por um processo de interpolação por *splines* cúbicas (DUBINSKY & ELPERIN, 1997) com a finalidade de obter previsões em base semi-horária e, por fim, as previsões são agrupadas nos períodos correspondentemente aos patamares de carga indicados na Tabela 2 (PESSANHA et al, 2018).

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, 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) (CHEN et al, 2004; 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).

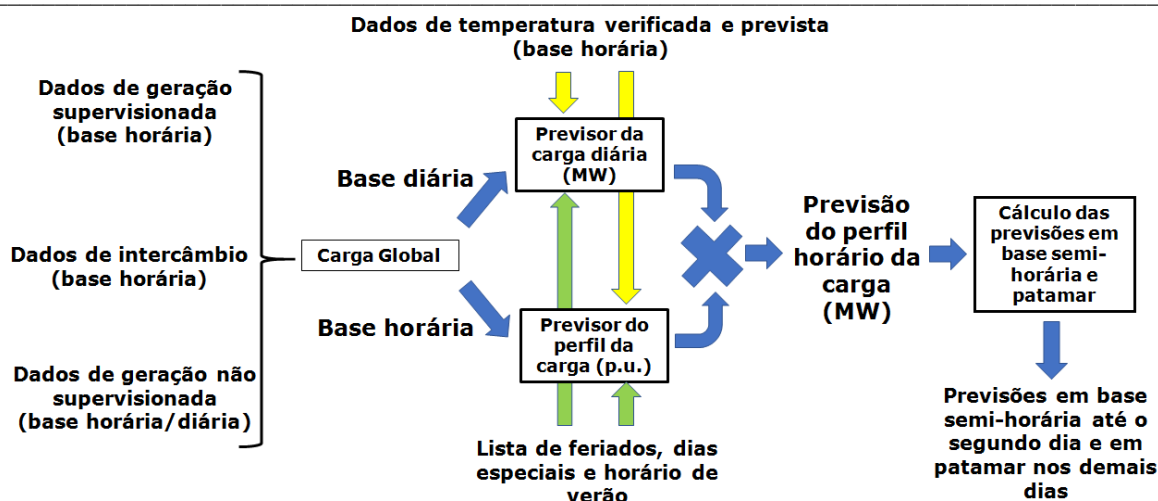


Figura 3. Estratégia de previsão de carga adotada no PrecvargaDessem.

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

Tabela 2. Definição dos patamares de carga (PESSANHA et al, 2018).

Patamar de carga	Inverno Maio, Junho, Julho e Agosto		Intermediário Abril, Setembro e Outubro		Verão Janeiro, Fevereiro, Março, Novembro e Dezembro	
	2ª a 6ª feira	Sábado, Domingo e Feriado	2ª a 6ª feira	Sábado, Domingo e Feriado	2ª a 6ª feira	Sábado, Domingo e Feriado
Pesada	10h00-22h00		10h00-20h00		10h00-18h00	
Média	07h00-10h00 22h00-24h00	18h00-22h00	08h00-10h00 20h00-24h00	18h00-22h00	08h00-10h00 18h00-24h00	20h00-23h00
Leve	00h00-07h00	00h00-18h00 22h00-24h00	00h00-08h00	00h00-18h00 22h00-24h00	00h00-08h00	00h00-20h00 23h00-24h00

O presente relatório técnico tem por objetivo descrever a metodologia de previsão de carga adotada no PrecvargaDESSEM e fornecer instruções básicas para sua utilização e visualização dos resultados.

2. MÉTODOS DE PREVISÃO USADOS NO PREVCARGADESSEM

2.1 Introdução

O PrevcargaDESSEM baseia-se em algoritmos estatísticos e de aprendizagem de máquinas, entre os quais destacam-se as Redes Neurais Artificiais - RNA e as Máquinas de Vetor de Suporte - SVM , mas também inclui em sua programação lógica fuzzy, modelo de regressão quantílica, análise de agrupamentos, estimador de Nadaraya-Watson, classificador Naive Bayes e modelo de programação quadrática. Nesta seção serão introduzidas algumas noções básicas dos métodos supracitados.

2.2 Redes Neurais Artificiais

O cérebro humano é composto por cerca de 100 bilhões de células nervosas, conhecidas por neurônios, que se conectam massivamente umas às outras através de ligações eletroquímicas, denominadas sinapses, formando uma grande rede de processamento. Cada neurônio recebe estímulos através dos dendritos, os processa em seu corpo celular e, dependendo do seu estado de ativação, gera e transmite um estímulo pelo seu axônio para que atinja outros neurônios. A estrutura e o funcionamento do neurônio biológico podem ser modeladas pelo neurônio artificial ilustrado na Figura 4.




Figura 4. Neurônio artificial de McCulloch & Pitts (KOVÁCS, 1996).

No neurônio artificial os *N* terminais de entrada representam os dendritos e o único terminal de saída representa o axônio. A intensidade das sinapses é representada pelos pesos (*w*) nos terminais de entrada, cujos valores podem ser negativos ou positivos, definindo sinapses inibidoras ou estimuladoras respectivamente. De forma análoga ao que acontece no cérebro humano, onde as sinapses são reforçadas ou enfraquecidas, os pesos são ajustados durante a evolução do processo de aprendizagem da rede.

O comportamento do corpo celular é emulado por um mecanismo que faz a soma ponderada dos valores recebidos (cálculo do *net*). No modelo mais simples, esta soma ponderada é comparada com um limiar θ . Neste modelo, a função de ativação que relaciona a resposta do neurônio com a soma ponderada dos valores recebidos é uma função degrau: se $x_1w_1 + x_2w_2 + \dots + x_Nw_N \geq \theta$ o neurônio é ativado e produz uma saída igual a 1, caso contrário o neurônio não dispara e a saída é zero. Enfim, o corpo celular é responsável pelo mapeamento dos sinais de entrada em um único sinal de saída. No lugar da função degrau pode-se usar funções contínuas, por exemplo, a função logística.

As RNA são sistemas paralelos distribuídos, compostos por unidades de processamento simples (neurônios) dispostas em uma ou mais camadas que são interligadas por um grande número de conexões geralmente unidirecionais e com pesos para ponderar a entrada recebida por cada neurônio. Através de uma analogia com o cérebro humano, pode-se afirmar que os pesos das conexões armazenam o conhecimento ou a memória da rede neural.

A organização de vários neurônios artificiais em uma estrutura e a forma de como eles se interligam define a arquitetura de uma RNA. A arquitetura mais usual é a rede *perceptron* de múltiplas camadas ou *Multilayer Perceptron* (MLP) com três camadas, conforme mostra a Figura 5.




Figura 5. Rede MLP com três camadas.

A primeira camada da rede é a camada de entrada, sendo a única camada exposta aos sinais externos. Esta camada transmite os sinais recebidos para os neurônios da próxima camada, conhecida como camada escondida. Os neurônios das camadas escondidas extraem as características relevantes ou padrões dos sinais de entrada e transmitem o resultado para a camada de saída, a última camada da rede. A definição da arquitetura envolve a definição dos seguintes parâmetros: número de camadas escondidas, número de neurônios em cada camada e o tipo de conexão entre os neurônios.

A definição do número de camadas escondidas e do número de neurônios em cada camada é feita de forma empírica e depende da distribuição dos padrões de entrada, quantidade de ruído presente nos exemplos de treinamento e da complexidade da função a ser aprendida (HAYKIN, 2009).

O ajuste dos pesos sinápticos é realizado por meio de um processo iterativo denominado aprendizagem. O aprendizado pode acontecer, basicamente, de duas formas distintas: supervisionado e não supervisionado. O primeiro é comum em previsão de séries temporais, enquanto o segundo é utilizado para realizar análise de agrupamentos.

O aprendizado supervisionado consiste em apresentar padrões de entrada e saída desejada à RNA. Quando a saída gerada pela rede, a partir dos cálculos efetuados com o padrão de entrada e os pesos correntes, difere da saída desejada, os pesos são ajustados de forma a reduzir o erro. Essa dinâmica é repetida por todo conjunto de padrões (pares entradas e saídas) inúmeras vezes, até que a taxa de erro esteja dentro de uma faixa considerada satisfatória.

O método de treinamento mais usado no treinamento supervisionado é a retropropagação do erro ou *error backpropagation* (WERBOS, 1990), um algoritmo que utiliza pares (entrada, saída desejada) para através de um mecanismo de correção de erro ajustar os pesos da rede.

O ajuste dos pesos se dá pela execução de um processo de otimização realizado em duas fases: fase *forward* e fase *backward*, conforme ilustrado na Figura 6, onde os pesos são definidos de forma a minimizar a soma dos quadrados dos erros:

$$E = \frac{1}{2} \sum_p \sum_{j=1}^n (d_j^p - y_j^p)^2 \tag{1}$$

onde p é o número de padrões de treinamento (padrões de entrada e saída), n é o número de neurônios da camada de saída, d_j é a saída desejada para o j -ésimo neurônio da camada de saída e y_j é a saída gerada pelo j -ésimo neurônio da camada de saída.

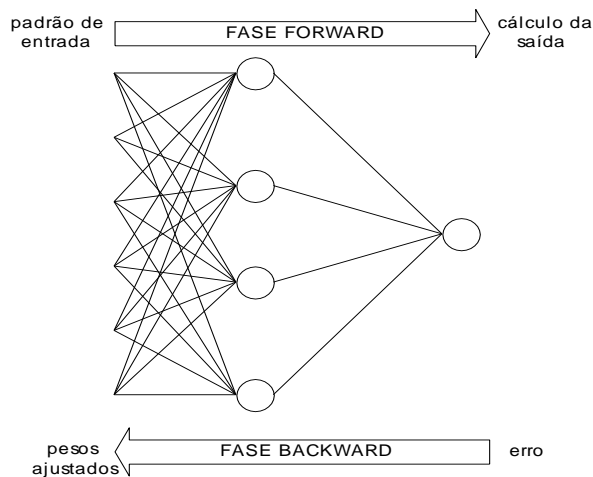


Figura 6. Fases *Forward* e *Backward* do algoritmo de retropropagação do erro.

Na fase *forward* a rede é apresentada à um padrão de entrada e gera uma saída. Na fase *backward* a diferença (erro) entre a saída desejada e a saída gerada pela rede é utilizada para ajustar os pesos das sinapses. Para minimizar a soma dos quadrados dos erros o algoritmo de aprendizagem se baseia no método do gradiente descendente, por isso, afim de que esse método seja utilizado a função de ativação precisa ser contínua, diferenciável e não decrescente, por exemplo, a função logística. O algoritmo *backpropagation* pode ser resumido nas seguintes operações (HAYKIN, 2009):

1º Passo - Inicialize aleatoriamente os pesos da rede e faça o contador de épocas (t) igual a zero.

2º Passo - Apresente uma época de exemplos de treinamento à rede. Uma época indica o número de vezes que os padrões de entrada (x) e o respectivo padrão de saída (y^d) (padrões do conjunto de treinamento) são apresentados à rede. Para cada exemplo de treinamento realizar os passos 3 e 4 a seguir.

3º Passo – Fase forward: Propague o padrão de entrada (X_p) para frente, camada por camada, até chegar na camada de saída. Para cada neurônio calcular a combinação dos sinais recebidos da camada anterior:

$$net_j^l(t) = \sum_{i=0}^m w_{j,i}^l(t) \cdot y_i^{l-1}(t) \tag{2}$$

em que $y_i^{l-1}(t)$ é a saída produzida pelo neurônio i da camada anterior $l-1$ e $w_{j,i}^l(t)$ é o peso sináptico da conexão do neurônio j na camada l com o neurônio i da camada anterior $l-1$.

Para $i=0$ tem-se o viés (bias) aplicado ao neurônio j na camada l : $y_0^{l-1}(t) = 1$ e $w_{j,0}^l(t) = b_j^l(t)$.

Se o neurônio j está na primeira camada oculta, i.e., $l=1$ $y_i^0(t) = x_i(t)$.

Denotando por f_j a função de ativação do neurônio j , o sinal produzido por ele é:

$$y_i^l(t) = f_j(\text{net}_j(t)) \quad (3)$$

No final calcule o erro, ou seja, a diferença entre a resposta desejada e a resposta fornecida pela rede:

$$e_j(t) = y_j^d - y_j \quad (4)$$

4º Passo – Fase backward: Propague o erro calculado no passo 3 para trás, começando na camada de saída e terminando na camada de entrada. Neste processo ajuste os pesos da seguinte forma:

$$w_{j,i}^l(t+1) = w_{j,i}^l(t) + \eta \delta_j^l(t) y_i^{l-1}(t) \quad (5)$$

em que η é a taxa de aprendizagem, $y_i^{l-1}(t)$ é a resposta do neurônio i situado na camada anterior $l-1$ e $\delta_j^l(t)$ é o gradiente local do neurônio j da camada l , definido de acordo com a localização do neurônio na rede.

Se a camada l onde está o neurônio é uma camada de saída tem-se:

$$\delta_j^l(t) = e_j(t) \cdot \frac{df_j(\text{net}_j(t))}{d\text{net}_j} \quad (6)$$

Porém, se a camada l onde o neurônio estiver é uma camada escondida, o seu gradiente local é:

$$\delta_j^l(t) = \frac{df_j(\text{net}_j(t))}{d\text{net}_j} \cdot \sum_{k=1}^m \delta_k^{l+1}(t) \cdot w_{kj}^{l+1}(t) \quad (7)$$

em que m é número de neurônios da camada $l+1$, $\delta_k^{l+1}(t)$ é o gradiente local do neurônio k situado na camada $l+1$ e $w_{kj}^{l+1}(t)$ é o peso sináptico da conexão entre o neurônio j na camada l e o neurônio k na camada $l+1$

5º Passo – Após terminar uma época de exemplos faça $t=t+1$ e itere para frente e para trás os passos 3 e 4. Pare apenas quando o critério de parada¹ for satisfeito.

A construção de um modelo baseado em rede neural artificial envolve a busca da melhor configuração para a rede, i.e., a definição do número adequado de camadas escondidas e a definição da quantidade ideal de processadores nestas camadas. A inexistência de regras que definam claramente a configuração adequada faz desta busca um processo empírico que demanda um longo tempo de processamento, em que diferentes configurações devem ser avaliadas. Entretanto, deve-se sempre empregar o princípio da parcimônia, e saber que uma rede com apenas uma camada oculta é capaz de aproximar qualquer tipo de função contínua (HAYKIN, 2009), embora em algumas situações específicas sejam usadas duas camadas.

Embora não existam leis que definam a configuração ótima, existem algumas propriedades que regem a convergência do algoritmo de treinamento, bem como a capacidade de generalização das RNA. O conhecimento destas propriedades orienta o processo de busca da configuração ótima e permite obter melhores resultados.

¹ Usualmente o critério de parada fixa um determinado número de iterações ou estabelece uma tolerância para o erro.

Em uma rede neural pequena há dificuldade de armazenar todos os padrões necessários e por isso a convergência do algoritmo de treinamento é mais lenta. Em uma rede pequena os processadores ficam sobrecarregados e lidam com muitas restrições na tentativa de encontrar uma representação ótima. Porém, deve-se ter o cuidado de não utilizar processadores demais, pois a rede pode memorizar os padrões de treinamento, ao invés de extrair as características gerais que permitirão o reconhecimento de padrões não vistos durante o treinamento.

Com relação às redes com mais de uma camada escondida é importante observar que cada vez que o erro é propagado para a camada anterior, ele se torna menos útil e preciso. Apenas a camada imediatamente anterior à camada de saída tem uma noção precisa do erro, todas as camadas escondidas anteriores recebem uma estimativa do erro. Por esta razão a convergência dos pesos destas camadas é mais lenta.

No método *backpropagation*, o peso sináptico i do elemento processador j é atualizado de acordo com a seguinte regra entre as iterações t e $t+1$:

$$w_{ij}(t+1) = w_{ij}(t) + \Delta w_{ij} \quad (8)$$

onde

$$\Delta w_{ij} = -\eta \frac{\delta E}{\delta w_{ij}} = -(\text{taxa de aprendizado}) \times \text{derivado do erro em relação a } w_{ij} \quad (9)$$

O *backpropagation* é inspirado no método do gradiente descendente: dado um ponto w no espaço dos pesos sinápticos, a taxa de aprendizagem η controla o tamanho do passo na direção oposta ao gradiente, a ser dado a partir deste ponto, visando minimizar o erro. Desta forma, um valor pequeno para η resulta em uma convergência lenta, enquanto um valor de maior magnitude para η acelera a convergência do treinamento, seja em redes com apenas uma camada escondida, ou em redes mais complexas, como a rede com duas camadas escondidas.

Entretanto, a taxa de aprendizagem não deve ser nem muito pequena e nem muito grande, pois com uma taxa pequena pode-se ficar preso em um mínimo local e a rede neural não conseguir aprender com a precisão especificada, por outro lado, valores grandes para a taxa de aprendizado tornam o treinamento instável, com fortes oscilações nos pesos de uma iteração para outra e o algoritmo de treinamento pode não convergir.

Para acelerar o treinamento, porém evitando a instabilidade no ajuste dos pesos, adiciona-se o termo momento (α) no incremento dos pesos a cada iteração:

$$\Delta w_{ij}(t+1) = -\eta \frac{\delta E}{\delta w_{ij}} + \alpha \Delta w_{ij}(t) \quad (10)$$

Nas regiões em que o gradiente aponta no mesmo sentido, a consideração do termo momento reforça o sinal dado pelo gradiente e acelera o treinamento, por sua vez, nas regiões em que o gradiente muda de direção, o termo momento suprime a oscilação nos pesos.

A previsão de valores futuros de uma série temporal, por meio de uma RNA (WERBOS, 1990, ZHANG et al, 1998), inicia-se com a montagem do conjunto de treinamento, que depende da definição do tamanho da janela de tempo para os valores passados das variáveis explicativas e do horizonte de previsão.

O padrão de entrada é formado pelos valores passados das variáveis explicativas e a saída desejada é o valor da observação da série temporal no horizonte de previsão. A Figura 7 ilustra como deve ser construído o conjunto de treinamento no caso da previsão um a passo à frente basear-se nos quatro últimos valores passados. A construção dos padrões de treinamento da rede consiste em mover as janelas de entrada e saída ao longo de toda série

temporal. Cada par de janelas entrada/saída funciona como um padrão de treinamento e deve ser apresentado repetidas vezes até que o algoritmo de aprendizado alcance a convergência.




Figura 7. Montagem do conjunto de treinamento.


2.3 Máquinas de vetor de suporte para regressão

Proposta 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 (SMOLA & SCHOLKOPF, 2004), neste último caso denomina-se Regressão por Vetores de Suporte (*Support Vector Regression – SVR*).

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:

$$f(X) = w^T X + b \tag{11}$$

Conforme ilustrado na Figura 8a, a equação de regressão em (11) pode ser tratada como um hiperplano no centro de um hipertubo (*hypertube*) de largura 2ε com $\varepsilon > 0$ que envolve todas as observações.



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

$$\begin{aligned}
 \underset{w, b}{\text{Min}} \quad & \frac{1}{2} w^T w \\
 & y_i - (w^T X_i + b) \leq \varepsilon \\
 & (w^T X_i + b) - y_i \leq \varepsilon
 \end{aligned} \tag{12}$$

Contudo, não se pode garantir que todos os dados estejam dispostos dentro de um hipertubo de largura 2ε . Para acomodar estas situações o modelo em (12) deve ser modificado com a adição de variáveis de folga ξ indicadas no modelo em (13). Geometricamente, as variáveis de folga representam os desvios entre as paredes do hipertubo e as observações exteriores ao hipertubo, conforme indicado na Fig. 8b.

$$\begin{aligned}
 \underset{w, b, \xi^-, \xi^+}{\text{Min}} \quad & \frac{1}{2} w^T w + C \sum_{i=1}^n (\xi_i^+ + \xi_i^-) \\
 & y_i - (w^T X_i + b) \leq \xi_i^+ + \varepsilon \\
 & (w^T X_i + b) - y_i \leq \xi_i^- + \varepsilon \\
 & \xi_i^-, \xi_i^+ \geq 0
 \end{aligned} \tag{13}$$

No problema de otimização em (13) a constante C é positiva e permite controlar o *trade-off* entre a maximização da margem e a minimização das variáveis de folga, um mecanismo de prevenção ao sobreajuste (*overfitting*). Adicionalmente, a solução do problema de otimização em (13) na sua forma dual em (14) é mais simples de ser alcançada.

$$\begin{aligned}
 \underset{\lambda_i^+, \lambda_i^-}{\text{Max}} \quad & -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (\lambda_i^+ - \lambda_i^-) (\lambda_j^+ - \lambda_j^-) X_i^T X_j + \sum_{i=1}^n y_i (\lambda_i^+ - \lambda_i^-) - \varepsilon \sum_{i=1}^n (\lambda_i^+ - \lambda_i^-) \\
 \text{s.a.} \quad & \sum_{i=1}^n (\lambda_i^+ - \lambda_i^-) = 0 \\
 & 0 \leq \lambda_i^+, \lambda_i^- \leq C
 \end{aligned} \tag{14}$$

em que λ denota os multiplicadores de Lagrange associados com as restrições do problema de otimização em (13).

As relações entre as soluções dos problemas primal em (13) e dual em (14) são estabelecidas pelas equações (15) e (16) a seguir:

$$w = \sum_{i=1}^n (\lambda_i^+ - \lambda_i^-) X_i \tag{15}$$

$$b = \frac{1}{n} \sum_{i=1}^n w^T X_i - y_i \tag{16}$$

Substituindo a equação (15) em (11) tem-se a seguinte equação de previsão para uma entrada X:

$$f(X) = \sum_{i=1}^n (\lambda_i^+ - \lambda_i^-) X_i^T X + b \tag{17}$$

Uma vantagem do algoritmo SVR é a facilidade com que se pode estender o modelo de regressão linear no modelo de regressão não linear. A transformação da equação de previsão em (17) e do problema de programação matemática em (14) 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:

$$\Phi(X_i, X_j) = \phi(X_i)\phi(X_j) \tag{18}$$

O modelo de regressão resultante é ilustrado a seguir em (19). Na sequência, em (20) tem-se a equação de previsão para o caso não linear:

$$\begin{aligned} \text{Max}_{\lambda_i^+, \lambda_i^-} & -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (\lambda_i^+ - \lambda_i^-)(\lambda_j^+ - \lambda_j^-) \Phi(X_i^T X_j) + \sum_{i=1}^n y_i (\lambda_i^+ - \lambda_i^-) - \varepsilon \sum_{i=1}^n (\lambda_i^+ - \lambda_i^-) \\ \text{s. a.} & \sum_{i=1}^n (\lambda_i^+ - \lambda_i^-) = 0 \\ & 0 \leq \lambda_i^+, \lambda_i^- \leq C \end{aligned} \tag{19}$$

$$f(X) = \sum_{i=1}^n (\lambda_i^+ - \lambda_i^-) \Phi(X_i^T X) + b \tag{20}$$

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.

A definição dos valores ótimos para os hiperparâmetros, em especial a constante C e a largura ε consiste em aplicar a validação cruzada ou *k-fold cross validation* (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 9 ilustra o processo de validação cruzada *K-fold* para um k=10.

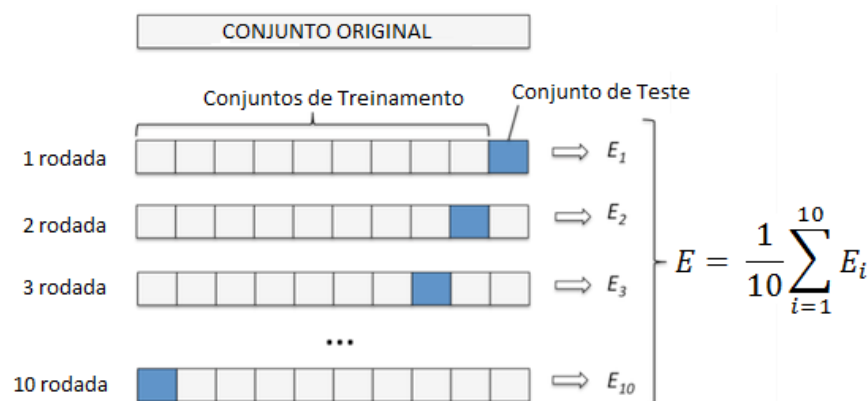


Figura 9. Exemplo de validação cruzada para k=10.

2.4 Regressão quantílica

Em um modelo de regressão linear, a equação de regressão estimada fornece uma estimativa do valor esperado da variável resposta y em função da variável explicativa X . Já em um modelo de regressão quantílica, a equação de regressão fornece uma estimativa do quantil τ (por exemplo, $\tau=0,5$ para a mediana) da variável resposta em função da variável explicativa. Assim, o conjunto de equações de regressão estimadas para diferentes valores de τ , permite caracterizar a distribuição de probabilidade da variável resposta condicionada aos valores das variáveis explicativas.

De forma distinta do estimador mínimos quadrados, na regressão quantílica para um quantil τ o estimador dos coeficientes de regressão busca minimizar a seguinte função objetivo em uma amostra com n pares $(y_i, X_i) \forall i=1, n$:

$$\text{Min}_{\beta} \sum_{i=1}^n \rho_{\tau}(y_i - X_i^T \beta) \tag{21}$$

em que $\rho_{\tau}(z)=z \cdot [\tau - I(z < 0)]$ e $I(z < 0)$ é uma função indicadora que assume valor unitário para $z < 0$, caso contrário, é igual a zero.

A função objetivo (21) pode ser inserida no seguinte problema de programação linear (PPL), cuja solução fornece as estimativas dos $K+1$ coeficientes de regressão:

$$\begin{aligned} &\text{Min}_{u,v,\beta} \tau \sum_{i=1}^n u_i + (1-\tau) \sum_{i=1}^n v_i \\ &\text{s.a} \\ &y_i - X_i^T \beta = u_i - v_i \forall i = 1, n \\ &u_i \geq 0 \forall i = 1, n \\ &v_i \geq 0 \forall i = 1, n \\ &\beta \in R^{K+1} \end{aligned} \tag{22}$$

Para $\tau = 0,5$ (mediana) o PPL em (22) corresponde ao estimador *least absolute deviations* (LAD)

2.5 Previsão combinada

O Prevcargadessem oferece 12 possibilidades para a previsão da demanda média diária, resultantes da combinação de 3 métodos de previsão (RNA, SVM com kernel linear e SVM com kernel radial) vezes 4 modelagens para a variável temperatura (sem temperatura, temperatura média, temperatura máxima e temperaturas mínima e máxima). O Prevcargadessem permite que o usuário execute cada uma das 12 modelagens disponíveis e obtenha a previsão por cada método (previsão individual) ou faça uma execução em lote dos 12 modelos e ao final calcule a média ponderada das previsões (previsão combinada), com ponderações calculadas previamente pelo ONS. Bates e Granger (1969) mostram que previsão combinada é melhor que as previsões individuais.

3. MODELAGEM DA PREVISÃO DE CARGA NO PREVCARGADESSEM

3.1 Introdução

O modelo PrevcargaDessem produz previsões de carga até 192 horas à frente com resolução temporal semi-horária e por patamar. As previsões de carga são obtidas por meio de um processo organizado em cinco etapas:

Etapa 1: Tratamento de dados.

Etapa 2: Montagem da série de carga global (em base horária) a partir da combinação dos dados de geração supervisionada, intercâmbio e geração não supervisionada. A carga global é definida pela seguinte equação

$$\text{carga global} = \text{geração supervisionada} - \text{intercâmbio} + \text{geração não supervisionada} \quad (23)$$

Etapa 3: Previsão do perfil horário da carga global em base horária.

Etapa 4: Cálculo das previsões em base semi-horária por meio de interpolação com *splines* cúbicas.

Etapa 5: Cálculo das previsões de carga por patamar.

Ressalta-se que na Etapa 1 todos os dados de geração supervisionada e não supervisionada, intercâmbio e temperatura são previamente tratados antes de serem utilizados pelas rotinas responsáveis pelo ajuste dos modelos de previsão. A metodologia de tratamento de dados é descrita na seção 3.2. Na sequência, o PrevcargaDESSEM calcula as previsões com base na metodologia descrita na seção 3.3.

O PrevcargaDESSEM é um pacote desenvolvido para o ambiente “R” (R CORE TEAM, 2017). A interface do programa é realizada por meio de arquivos no formato “csv” (arquivo texto com colunas separadas por “,”) ou por objetos “data.frame”. O programa produz os seguintes resultados:

- Composição da carga global por subsistema/área em base horária.
- Previsões de carga global em base semi-horária/patamar para os subsistemas/áreas listadas na Tabela 3.
- Arquivo com previsões de carga no formato do modelo DESSEM.

Tabela 3. Áreas e Subsistemas.

Subsistema SE/CO	Subsistema SUL	Subsistema NORDESTE	Subsistema NORTE
RJ – área RJ	RS – área RS	NEC – área Centro	AM – Amazonas
ES – área ES	SC – área SC	NEL – área Leste	PA – Pará
SP – área SP	PR – área PR	NES – área Sul	MA - Maranhão
MG - área MG	S – Subsistema SUL	NEO – área Oeste	TO – Tocantins
MT – área MT		NEN – área Norte	N – Subsistema Norte
DF – área DF		NESO - área Sudoeste	
GO – área GO		NE – Subsistema Nordeste	
MS – área MS			
AC – área AC			
RO – área RO			
SE – Subsistema SE/CO			

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* remanescentes 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:

$$Y(t) = \frac{\sum_{i=1}^N K\left(\frac{t-t_i}{h}\right) y_i}{\sum_{i=1}^N K\left(\frac{t-t_i}{h}\right)} \quad (24)$$

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:

$$\text{Limite superior: } LS(t) = Y(t) + 3,5 DP \quad (25)$$

$$\text{Limite inferior: } LI(t) = Y(t) - 3,5 DP \quad (26)$$

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 a lacunas e *outliers* e merecem passar por um tratamento prévio. 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 diárias 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 PrecvargaDESSEM 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:

$$d_{ij} = \frac{p_i p_j}{p_i + p_j} d^2(c_i, c_j) \quad (27)$$

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):

$$P(\text{dia da semana } i \mid \text{cluster } j) = P(i \mid j) \quad \forall i=1,7 \text{ e } j=1,k \quad (28)$$

$$P(\text{mês } m \mid \text{cluster } j) = P(m \mid j) \quad \forall m=1,9 \text{ e } j=1,k \quad (29)$$

$$P(\text{tipo de dia } n \mid \text{cluster } j) = P(n \mid j) \quad \forall n=1,9 \text{ e } j=1,k \quad (30)$$

$$P(\text{horário } h \mid \text{cluster } j) = P(h \mid j) \quad \forall h=1,2 \text{ e } j=1,k \quad (31)$$

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 posteriori* for verificada para o *cluster* j , conforme descrito pela desigualdade a seguir:

$$P(i \mid j) * P(m \mid j) * P(n \mid j) * P(h \mid j) * P(j) > P(i \mid w) * P(m \mid w) * P(n \mid w) * P(h \mid w) * P(w) \quad \forall j \neq w=1,K \quad (32)$$

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

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 explicativas:

- 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* remanescentes, identificados pelo *boxplot* da série de carga, são substituídos pelo 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) para suavizar a série de carga:

$$Y(t) = \frac{\sum_{i=1}^N K\left(\frac{t-t_i}{h}\right) y_i}{\sum_{i=1}^N K\left(\frac{t-t_i}{h}\right)} \quad (33)$$

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 obtém-se os limites dos intervalos de confiança para a carga em cada hora:

$$\text{Limite superior: } LS(t) = Y(t) + 3,5 DP \quad (34)$$

$$\text{Limite inferior: } LI(t) = Y(t) - 3,5 DP \quad (35)$$

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

3.2.2.5. 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 obtém-se os limites dos intervalos de confiança para a geração não supervisionada em cada dia:

$$\text{Limite superior: } LS(t) = Y(t) + 3,0 DP \tag{36}$$

$$\text{Limite inferior: } LI(t) = Y(t) - 3,0 DP \tag{37}$$

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

3.3 Modelos de previsão de carga

Para a previsão do perfil de carga em um dia *D* o *PrevcargaDessem* emprega modelos específicos para os dias normais e dias especiais/feriados.

3.3.1 Modelo de previsão para dias normais

Se o dia *D* da previsão é um dia normal, o *PrevcargaDESSEM* treina modelos SVM ou RNA para a previsão da demanda média diária em MW e na sequência treina 24 SVM, um para cada hora do dia, para previsão do respectivo perfil de carga em p.u. da demanda média diária. A previsão horária é obtida pelo produto entre a previsão da demanda média diária (MW) e a previsão do perfil horário (em p.u.).

Para a previsão da demanda média diária (em MW), em um dia *D* normal, precedido de dias normais em *D-1* e *D-7*, o programa oferece três métodos: RNA (com dois neurônios em uma camada escondida), SVM com *kernel* linear e SVM com *kernel* radial. Nas três opções disponíveis as variáveis explicativas incluem as demandas médias dos dias *D-1* e *D-7* e a temperatura, sendo que para esta última variável o programa oferece quatro especificações possíveis: sem temperatura, média da temperatura diária, máxima temperatura diária e valores mínimo e máximo da temperatura diária. Portanto, o *PrevcargaDESSEM* oferece 12 modelagens possíveis para a previsão da demanda média diária em um dia *D* normal.

No caso de um dia *D* normal, precedido por dias normais em *D-1* e *D-7*, em um mês *M*, o conjunto de treinamento envolve os padrões entrada/saída em todos os dias do histórico no mesmo mês *M* e nos meses imediatamente anterior e posterior ao mês *M*, portanto, uma janela Ω de 3 meses ao redor do mês *M* (Figura 10). Por exemplo, para a previsão de um dia *D* em junho, o conjunto de treinamento é formado por padrões dos meses de maio, junho e julho coletados ao longo de todo o histórico. Naturalmente, os limites da janela devem respeitar o período do horário de verão ou horário normal dependendo do mês em que a previsão é realizada. Esta estratégia para seleção dos padrões entrada/saída é utilizada no treinamento dos modelos de previsão da demanda média diária (apenas se dia normal precedido de dias normais) e do perfil de carga em base horária para os dias normais. Ressalta-se que as observações relativas aos dias marcados com feriado tipo 12 não fazem parte do conjunto de treinamento.




Figura 10. Janela trimestral para formação do conjunto de treinamento.

Para a previsão da demanda média diária, os padrões de saída correspondem aos valores da demanda média diária em todos os dias na janela Ω , mas apenas nos dias $d \in \Omega$ que ocorrem no mesmo dia da semana do dia *D* da previsão. Já os padrões de entrada incluem as demandas médias nos dias *d-1* e *d-7*, bem como a temperatura

verificada no dia d (média, máxima ou mínima & máxima, conforme selecionado pelo usuário), caso a variável temperatura tenha sido incluída entre as variáveis explicativas.

Ainda na previsão da demanda média, caso a temperatura máxima prevista para o dia $D+1$ situe-se abaixo do primeiro quartil ou acima do terceiro quartil da distribuição das temperaturas máximas no conjunto de treinamento, a previsão da demanda média diária é fornecida por um modelo de regressão quantílica, ajustado para o quantil da temperatura máxima prevista com as seguintes variáveis explicativas:

- valores da demanda média diária nos dias $D-1$ e $D-7$
- temperatura, segundo uma das quatro especificações possíveis: não considera temperatura, média da temperatura diária no dia D , máxima temperatura diária no dia D e valores mínimo e máximo da temperatura diária no dia D .

Já a previsão do perfil horário de carga para um dia D normal, em p.u. da demanda média, conta com 24 SVM, um para cada hora $h \forall h=1,24$. Para a previsão da demanda horária na hora h , os padrões de saída correspondem aos valores da demanda da hora h em todos os dias na janela Ω , mas apenas nos dias $d \in \Omega$ que ocorrem no mesmo dia da semana do dia D da previsão. Já os padrões de entrada incluem as demandas horárias na hora h nos dias $D-7$ e $D-14$, bem como a temperatura verificada na hora h do dia D , caso a variável temperatura tenha sido incluída entre as variáveis explicativas.

Caso o dia D seja normal, porém, os dias $D-1$ ou $D-7$ não sejam normais a previsão da demanda média diária para o dia D , em um dia da semana s ($s=1$ se dia D é domingo, $s=2$ se dia D é segunda-feira e assim sucessivamente até $s=7$ se dia D é sábado) é realizada por RNA (com dois neurônios na camada escondida) ou SVM, porém com as seguintes variáveis explicativas:

- valores da demanda média diária nos dias $D-1$ e $D-7$
- tipo do feriado no dia D , 10 variáveis indicadoras (*dummy*), conforme indicado na Tabela 4. As observações relativas aos dias marcados com feriado tipo 12 não fazem parte do conjunto de treinamento. Nos dias normais todas as variáveis indicadoras são nulas.
- variável indicadora que assume valor 1 se dia D pertence ao período do horário de verão e 0 caso contrário.
- temperatura, segundo uma das quatro especificações possíveis: sem temperatura, média da temperatura diária no dia D , máxima temperatura diária no dia D e valores mínimo e máximo da temperatura diária no dia D .

Tabela 4. Variáveis indicadoras dos tipos de feriados.

Dummy	Tipo do feriado									
	1	2	3/4	5	6	7	8	9	10	11
1	1									
2		1								
3			1							
4				1						
5					1					
6						1				
7							1			
8								1		
9									1	
10										1

Ressalta-se que neste último caso a previsão do perfil horário de carga em p.u. segue a mesma estratégia descrita acima para os dias normais precedidos por dias normais, i.e., envolve o ajuste de 24 SVM.

3.3.2 Modelo de previsão para feriados e dias especiais

Se o dia D da previsão for um feriado/dia especial o PrecvargaDESSEM faz uma previsão por similaridade, i.e., busca nos históricos de carga e temperatura um perfil de carga com características semelhantes às verificadas no momento da previsão.

Para ilustrar a ideia central da previsão por similaridade adotada no PrecvargaDESSEM considere a previsão do perfil de carga para o Natal (dia D da previsão), dado uma previsão do perfil de temperatura para o dia 25 de dezembro (temperatura no dia D) e que o perfil de carga do dia 24 de dezembro é conhecido (carga no dia D-1).

Assim, busca-se no histórico todos os perfis de carga correspondentes ao mesmo feriado do dia D, neste caso o Natal. Cada perfil identificado forma o consequente de uma regra de associação do tipo "Se Antecedente Então Consequente".

Por sua vez, o antecedente de cada regra é formado pelo perfil de temperatura prevista para o dia D e o perfil de carga no dia D-1.

Para um histórico com três anos de dados há apenas três regras para o Natal, cujos antecedentes (temperatura em D e carga em D-1) e consequentes (carga em D) são apresentados graficamente na Figura 11.

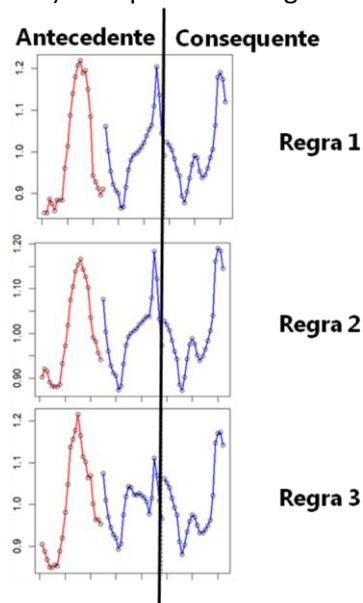


Figura 11. Regras de associação para o Natal.

Conforme ilustrado na Figura 12, para o dia D da previsão tem-se apenas os elementos que correspondem aos antecedentes da regras, i.e., a carga do dia anterior (D-1), em azul, e a previsão de temperatura para o dia D, em vermelho.




Figura 12. Antecedentes das regras para previsão do Natal.

A previsão obtida por similaridade é a média dos consequentes das três regras (perfis C1, C2 e C3) ilustrados na Figura 11, ponderados pelos respectivos graus de similaridade (w) entre o antecedente do dia D (perfil X) e os antecedentes das regras (perfis A1, A2 e A3).

$$\frac{w_1 C_1 + w_2 C_2 + w_3 C_3}{w_1 + w_2 + w_3} \tag{38}$$

O grau de similaridade entre o antecedente do dia D e o antecedente de uma regra (A1, A2 e A3) é calculado da mesma forma que o grau de pertinência no algoritmo *Fuzzy C-Means* (CANNON et al, 1986), um algoritmo para análise de agrupamentos:

$$w_i = \frac{1}{\left(\sum_{k=1}^3 \frac{\|X - A_i\|}{\|X - A_k\|} \right)^{\frac{2}{m-1}}} \quad \forall i = 1,3 \tag{39}$$

Na equação (39) m é a constante de fuzzyficação e no *PrevcargaDESSEM* foi fixada em 1,25.

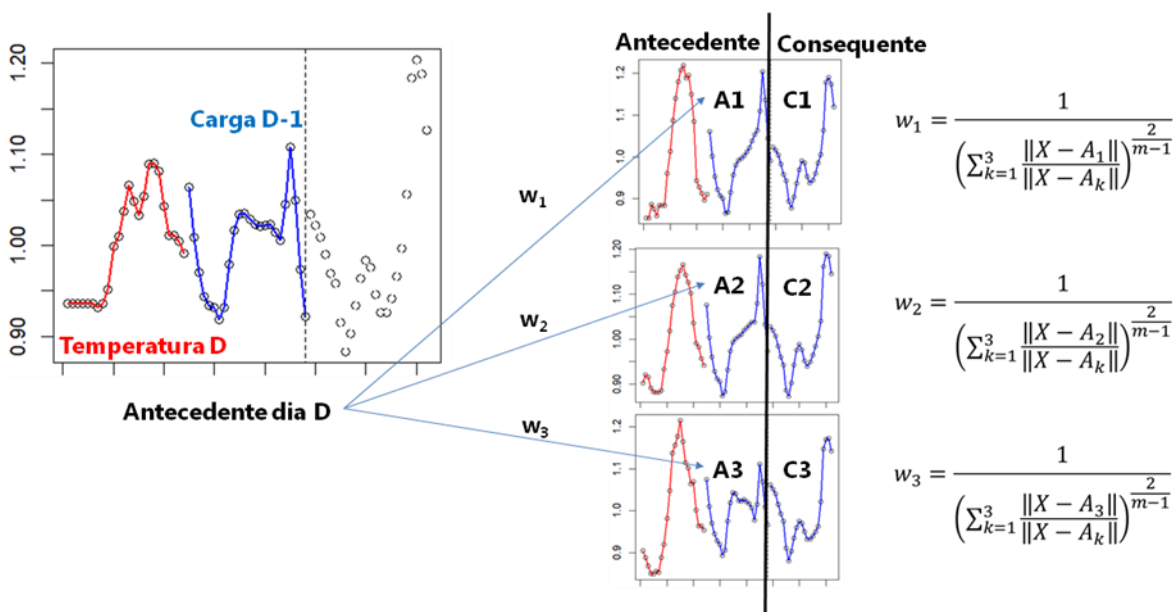


Figura 13. Antecedentes das regras para previsão do Natal.

Relatório Técnico – 6061 / 2019

Portanto a previsão do dia D é dada pela média ponderada em (38). Conforme ilustrado na Figura 13, para o dia D da previsão tem-se apenas os elementos que correspondem aos antecedentes das regras, i.e., a carga do dia anterior (D-1), em azul, e a previsão de temperatura para o dia D, em vermelho.

Vale destacar que no exemplo ilustrativo o antecedente de cada regra de associação é formado pelo perfil da temperatura prevista para o dia D e pelo perfil de carga para o dia D-1. A mesma especificação é usada na previsão dos feriados tipos 1, 2 e 6. Nos demais tipos de feriados e dias especiais o antecedente é formado pelo perfil da temperatura prevista para o dia D e pelo perfil de carga para o dia D-7. Exceto para os feriados tipo 6, 7 e 8 (relativos ao período do Natal e 1º de janeiro), para os demais feriados a formação do conjunto de regras de associação pode abranger feriados em uma janela de três meses centrada no mês do dia da previsão.

A ideia central do previsor por similaridade pode ser implementada de diferentes formas e no PrecvargaDESSEM são avaliadas duas maneiras distintas e o próprio programa escolhe a melhor delas. Inicialmente, o PrecvargaDESSEM aplica a ideia do previsor por similaridade nos perfis padronizados pela média e a previsão resultante é multiplicada pela previsão da demanda média oriunda de um modelo (RNA ou SVM) descrito na seção 3.3.2.1. Na sequência o PrecvargaDESSEM aplica a mesma ideia do previsor por similaridade diretamente aos dados em MW, portanto, sem normalizá-los. Assim, ao final tem-se duas previsões e por se tratarem de previsões para feriados, o programa escolhe a previsão que apresentar o perfil de carga em MW mais próximo do último sábado (no caso de feriado tipo 1) ou do último domingo (demais feriados).

3.3.2.1 Modelo para previsão da demanda média diária para feriados e dias especiais

A demanda média diária para feriados e dias especiais conta com duas modelagens distintas: uma modelagem simplificada para os tipos de feriados 1 e 2 e outra para os demais feriados. Para ambos os casos o usuário pode escolher uma RNA (com dois neurônios na camada escondida), um SVM com *kernel* linear ou um SVM com *kernel* radial.

Para os feriados tipo 1 e 2 o PrecvargaDESSEM treina um modelo específico para a previsão da demanda média nos feriados com perfis de sábado e domingo. O conjunto de treinamento desse modelo é formado apenas por perfis de feriados tipo 1 e 2 presentes no histórico. Neste caso, a previsão da demanda média diária para o dia D é função das seguintes variáveis explicativas:

- valores da demanda média diária nos dias D-1 e D-7
- tipo do feriado no dia D, uma variável indicadora (*dummy*) que assume valor 1 para feriado com perfil de sábado e 0 para feriado com perfil de domingo. As observações relativas aos dias marcados com feriado tipo 12 não fazem parte do conjunto de treinamento.
- variável indicadora que assume valor 1 se dia D é feriado em dia útil e 0 caso contrário.
- variável indicadora que assume valor 1 se dia D pertence ao período do horário de verão e 0 caso contrário
- temperatura, segundo uma das quatro especificações possíveis: não considera temperatura, média da temperatura diária no dia D, máxima temperatura diária no dia D e valores mínimo e máximo da temperatura diária no dia D.

Já no caso dos demais tipos de feriados a previsão da demanda média é obtida por um outro modelo ajustado separadamente para cada dia da semana. Neste caso, a previsão da demanda média diária para o dia D, em um dia da semana s ($s=1$ se dia D é domingo, $s=2$ se dia D é segunda-feira e assim sucessivamente até $s=7$ se dia D é sábado), é função das seguintes variáveis explicativas:

- valores da demanda média diária nos dias D-1 e D-7

- tipo do feriado no dia D, 10 variáveis indicadoras (*dummy*), conforme indicado na Tabela. As observações relativas aos dias marcados com feriado tipo 12 não fazem parte do conjunto de treinamento. Nos dias normais todas as variáveis indicadoras são nulas.
- variável indicadora que assume valor 1 se dia D pertence ao período do horário de verão e 0 caso contrário.
- temperatura, segundo uma das quatro especificações possíveis: não considera temperatura, média da temperatura diária no dia D, máxima temperatura diária no dia D e valores mínimo e máximo da temperatura diária no dia D.

Tabela 5. Variáveis indicadores dos tipos de feriados.

Dummy	Tipos de feriado									
	1	2	3/4	5	6	7	8	9	10	11
1	1									
2		1								
3			1							
4				1						
5					1					
6						1				
7							1			
8								1		
9									1	
10										1

3.3.3 Avaliação a posteriori

As previsões dos perfis de carga passam por uma avaliação a posteriori com o objetivo de avaliar a sua razoabilidade. A avaliação consiste na aplicação de um conjunto de heurísticas.

3.3.3.1 Avaliação a posteriori das previsões para feriados e dias especiais

As previsões dos perfis de carga para os feriados e dias especiais passam por uma avaliação a posteriori. Caso o dia D seja um feriado ou dia especial busca-se no histórico todos os dias com o mesmo tipo de feriado do dia D para formar um conjunto de padrões, os padrões selecionados podem pertencer a qualquer ano do histórico, mas devem ser do mesmo mês, ou meses imediatamente adjacentes ao mesmo mês do dia D de previsão. Na sequência ajusta-se um modelo de regressão linear simples em que a média da carga no dia do feriado é função da média da carga no dia imediatamente anterior ou na semana anterior. A partir da equação de regressão estimada pode-se obter um intervalo de previsão de 90% e uma nova estimativa para a demanda média diária no dia D da previsão. De forma resumida, se a demanda média prevista inicialmente para o dia D (previsão calculada na seção 3.3.2) estiver fora dos limites do intervalo de confiança, uma nova previsão da demanda média para o dia D é definida pelo limite do intervalo de previsão que estiver mais próximo da previsão inicial (previsão calculada na seção 3.3.2), caso contrário a nova previsão da demanda média para o dia D é definida pela média entre a previsão inicial e a estimativa gerada pelo modelo de regressão.

Na sequência, com os mesmos dados selecionados no histórico e usados na regressão descrita acima calcula-se θ , i.e., a média da razão da demanda média diária entre dois dias consecutivos e o respectivo intervalo com 95% de confiança. Se a razão entre a previsão inicial da demanda média do dia D (previsão calculada na seção 3.3.2) pela demanda média do dia D-1 estiver fora dos limites do intervalo de confiança, a nova previsão da demanda média diária para o dia D é igual a θ vezes a demanda média do dia D-1.

3.3.3.2 Correção de degrau entre as previsões de dois dias consecutivos

Eventualmente a previsão para a primeira hora do dia D pode superar a previsão para a última hora do dia D-1, i.e., há um degrau indevido entre as previsões. A correção deste problema pode ser efetuada pelo modelo de programação quadrática em (39), cujo objetivo consiste em encontrar uma previsão x_h ($\forall h=1,24$) muito próxima do perfil de carga previsto p_h ($\forall h=1,24$) para o dia D, mas que não apresente um degrau em relação ao dia D-1.

$$\begin{aligned} \text{Min}_{x_h \forall h = 1,24} & \sum_{h=1}^{24} (x_h - p_h)^2 \\ & \alpha_h \leq \frac{x_h}{x_{h-1}} \leq \beta_h \quad \forall h = 1,24 \\ & 0,98\bar{p} \leq \frac{1}{24} \sum_{h=1}^{24} x_h \leq 1.02\bar{p} \end{aligned} \quad (40)$$

Em (39) os limites das 24 restrições para a razão x_h/x_{h-1} ($\forall h=1,24$) são definidos com base na previsão inicial p_h ($\forall h=1,24$) e em x_0 , i.e., a carga do último intervalo horário do dia anterior (D-1). Estas restrições visam garantir que o perfil de carga resultante da otimização x_h ($\forall h=1,24$) tenha variações horárias próximas das encontradas na previsão inicial. Por fim, a última restrição visa garantir que a demanda média prevista da curva resultante da otimização seja próxima de p -barra, i.e., a demanda média inicialmente prevista para o dia D.

4. PROGRAMA PREVCARGADESSEM

4.1 Instalação

Para instalar o PrecvargaDESSEM copie o arquivo prevcargadessem.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 14) para instalar o pacote prevcargadessem disponibilizado no arquivo prevcargadessem.tar.gz. Adicionalmente, os pacotes e1071, neuralnet, quantreg e quadprog devem ser previamente instalados.

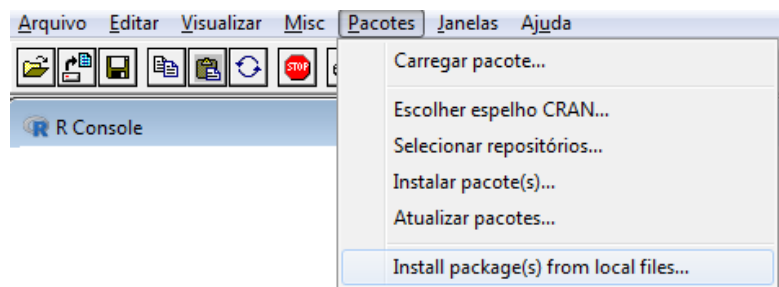


Figura 14. Menu Pacotes e opção *Install packages(s) from local files*.

4.2 Arquivos de dados

Os arquivos com os dados de entrada para o PrecvargaDESSEM são disponibilizados no Portal Sintegre do ONS (sintegre.ons.org.br), 9 arquivos para cada carga, conforme ilustrado na Tabela 6, em que XX denota o acrônimo identificador da carga e AAAA-MM-DD a data do arquivo no formato ano/mês/dia.

Tabela 6. Arquivos de entrada do PrecvargaDESSEM.

Nome do arquivo	Conteúdo
XX_AAAA-MM-DD_CARGAHIST.CSV	Dados históricos da carga global em base horária
XX_AAAA-MM-DD_COMBINA.CSV	Pesos das previsões no cálculo da previsão combinada
XX_AAAA-MM-DD_FERIADOS.CSV	Datas de feriados nacionais e estaduais
XX_AAAA-MM-DD_HORAVERAO.CSV	Datas de início e fim do horário de verão
XX_AAAA-MM-DD_HORIZONTE.CSV	Informações sobre o horizonte de previsão
XX_AAAA-MM-DD_PATAMARES.CSV	Patamares de carga
XX_AAAA-MM-DD_SEPARADOR.CSV	Separador decimal
XX_AAAA-MM-DD_TEMP HIST.CSV	Dados históricos de temperatura equivalente em base horária
XX_AAAA-MM-DD_TEMP PREV.CSV	Previsões de temperatura equivalente em base horária

4.2.1 Histórico da carga global em base horária

Os dados de carga são disponibilizados em bases horárias e organizados em arquivos ".csv" com colunas separadas por ponto e vírgula. Cada média horária da carga deve ser acompanhado da respectiva data de ocorrência (ano/mês/dia/hora/minuto), conforme ilustrado na Figura 15.

	A	B	C	D	E	F
1	Ano	Mes	Dia	Hora	Min	Carga
2	2014	1	1	2	0	4880,6
3	2014	1	1	3	0	4829,4
4	2014	1	1	4	0	4824,5
5	2014	1	1	5	0	4811,9
6	2014	1	1	6	0	4758,4
7	2014	1	1	7	0	4681,2
8	2014	1	1	8	0	4474,4
9	2014	1	1	9	0	4425,1
10	2014	1	1	10	0	4397,3
11	2014	1	1	11	0	4365,6
12	2014	1	1	12	0	4368,4
13	2014	1	1	13	0	4386,1
14	2014	1	1	14	0	4379,3
15	2014	1	1	15	0	4425,5
16	2014	1	1	16	0	4500,4
17	2014	1	1	17	0	4538,6
18	2014	1	1	18	0	4507,3
19	2014	1	1	19	0	4478,7
20	2014	1	1	20	0	4734,7
21	2014	1	1	21	0	5162,1
22	2014	1	1	22	0	5284,9
23	2014	1	1	23	0	5314,9
24	2014	1	2	0	0	5321,9

Figura 15. Exemplo de arquivo XX_AAAA-MM-DD_CARGAHIST.CSV.

4.2.2 Pesos das previsões no cálculo da previsão combinada

Os pesos atribuídos às previsões obtidas pelos diferentes modelos disponibilizados no PrevcargaDESSEM são organizados em arquivos ".csv" com colunas separadas por vírgula, conforme ilustrado na Figura 16.

	A	B	C	D
1	Temperatura	Kernel	Modelo	Coeficientes
2	NA	NA	(Intercept)	167,0733007
3	3	1	Linear.TmpMaxMin	0,109184477
4	1	1	Linear.TmpMaxima	-0,75349304
5	2	1	Linear.TmpMedia	1,320650741
6	0	1	Linear.Univariado	0,372927521
7	1	0	Radial.TmpMaxima	0,664559545
8	2	0	Radial.TmpMedia	-1,329916001
9	0	0	Radial.Univariado	0,193426246
10	1	2	RedeNeural.TmpMaxima	0,229924509
11	2	2	RedeNeural.TmpMedia	0,093888001
12	0	2	RedeNeural.Univariado	0,086768775

Figura 16. Exemplo de arquivo XX_AAAA-MM-DD_COMBINA.CSV.

4.2.3 Lista de feriados e dias especiais

A tabela com informações de feriados e dias especiais deve conter 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 nomenclatura indicada na Figura 17a. Na Figura 17b tem-se um exemplo do arquivo XX_AAAA-MM-DD_FERIADOS.CSV com dados 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

a) Codificação de feriados e dias especiais

	A	B	C	D
1	Ano	Mes	Dia	Tipo
2	2014	1	1	6
3	2014	1	2	7
4	2014	2	28	9
5	2014	3	3	3
6	2014	3	4	4
7	2014	3	5	5
8	2014	4	17	9
9	2014	4	18	2
10	2014	4	20	2

b) Arquivo XX_AAAA-MM-DD_FERIADOS.CSV

Figura 17. Arquivo XX_AAAA-MM-DD_FERIADOS.CSV com datas de feriados e dias especiais.

4.2.4 Horário de verão

As datas de início e fim do horário de verão devem ser informadas no arquivo XX_AAAA-MM-DD_HORAVERAO.CSV, cujo formato ano/mês/dia para cada edição do horário de verão ao longo do período do histórico de carga deve seguir o padrão indicado na Figura 18.

	A	B
1	Data.inicial	Data.final
2	20/10/2013	16/02/2014
3	19/10/2014	22/02/2015
4	18/10/2015	21/02/2016
5	16/10/2016	19/02/2017
6	15/10/2017	18/02/2018
7	04/11/2018	17/02/2019

Figura 18. Exemplo do arquivo XX_AAAA-MM-DD_HORAVERAO.CSV.

4.2.5 Dados do horizonte de previsão

As informações sobre o horizonte de previsão são disponibilizadas no arquivo XX_AAAA-MM-DD_HORIZONTE.CSV e incluem as datas dos instantes inicial e final do horizonte de previsão no formato ano/mês/dia/hora/minuto e as datas dos feriados no período de previsão no formato ano/mês/dia, acompanhadas da indicação do tipo do feriado. Na Figura 19 tem-se um exemplo do arquivo XX_AAAA-MM-DD_HORIZONTE.CSV.

	A	B	C	D	E	F	G
1	Variável	Ano	Mês	Dia	Hora	Minuto	Feriado/Dia Especial
2	Instante inicial da previsão	2017	4	1	0	0	
3	Data final da previsão	2017	6	1	1	0	
4	Início do horário de verão	2016	10	16	0	0	
5	Fim do horário de verão	2017	2	19	0	0	
6	feriado	2017	4	14	0	0	0
7	feriado	2017	4	16	0	0	0
8	feriado	2017	4	21	0	0	0
9	feriado	2017	4	23	0	0	1

Figura 19. Exemplo do arquivo XX_AAAA-MM-DD_HORIZONTE.CSV.

4.2.6 Patamares de carga

O arquivo XX_AAAA-MM-DD_PATAMARES.CSV deve conter a associação das horas do dia aos patamares de carga, conforme ilustrado na Figura 20, cujos valores 1, 2, e 3 denotam os patamares de carga pesada, média e leve respectivamente, conforme indicado na Tabela 2.

	A	B	C	D	E	F	G
1	Hora	dia util inverno	fds inverno	dia util intermediario	fds intermediario	dia util verao	fds verao
2	00:00	3	3	3	3	3	3
3	01:00	3	3	3	3	3	3
4	02:00	3	3	3	3	3	3
5	03:00	3	3	3	3	3	3
6	04:00	3	3	3	3	3	3
7	05:00	3	3	3	3	3	3
8	06:00	3	3	3	3	3	3
9	07:00	2	3	3	3	3	3
10	08:00	2	3	2	3	2	3
11	09:00	2	3	2	3	2	3
12	10:00	1	3	1	3	1	3
13	11:00	1	3	1	3	1	3
14	12:00	1	3	1	3	1	3
15	13:00	1	3	1	3	1	3
16	14:00	1	3	1	3	1	3
17	15:00	1	3	1	3	1	3
18	16:00	1	3	1	3	1	3
19	17:00	1	3	1	3	1	3
20	18:00	1	2	1	2	2	3
21	19:00	1	2	1	2	2	3
22	20:00	1	2	2	2	2	2
23	21:00	1	2	2	2	2	2
24	22:00	2	3	2	3	2	2
25	23:00	2	3	2	3	2	3

Figura 20. Arquivo XX_AAAA-MM-DD_PATAMARES.CSV.

4.2.7 Separador decimal

O arquivo XX_AAAA-MM-DD_SEPARADOR.CSV deve conter o tipo de separador decimal usado nos dados, conforme indicado na Figura 21.

	A
1	x
2	,

Figura 21. Arquivo XX_AAAA-MM-DD_SEPARADOR.CSV.

4.2.8 Histórico das temperaturas horárias

O arquivo com dados históricos de temperatura deve conter os valores médios da temperatura equivalente (°C) em base horária. Adicionalmente, cada valor médio deve ser acompanhado da respectiva data de ocorrência, especificada em termos de ano/mês/dia/hora/minuto, conforme ilustrado na Figura 22.

	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 22. Exemplo do arquivo XX_AAAA-MM-DD_TEMP HIST.CSV.

4.2.9 Histórico das temperaturas horárias

O arquivo com previsões de temperatura deve conter os valores médios da temperatura equivalente (°C) em base horária ao longo do período de previsão. Cada linha do arquivo deve conter uma previsão da média horária de temperatura equivalente e sua respectiva data especificada como ano/mês/dia/hora/minuto, conforme ilustrado na Figura 23.

	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 23. Exemplo do arquivo XX_AAAA-MM-DD_TEMP PREV.CSV com previsões de temperatura equivalente.

5. EXECUÇÃO EM AMBIENTE R

O programa `PrevcargaDESSEM` é disponibilizado como um pacote para execução em ambiente R. Após instalar o pacote `PrevcargaDESSEM` no R, digite `library(prevcargadessem)` e pressione a tecla *Enter* para carregar o pacote. Na sequência digite o comando abaixo e pressione *Enter*.

```
resultados = previsordessem(caminho="diretório dados",caminhosaida="diretório resultados",tipoinput=c1,tipotemp=c2,horizonteprevisao=c3,diasprevisaosemihora=c4,tipokernel =c5,tipocombinada=c6,prefixo="XX_AAAA-MM-DD")
```

em que

"diretório dados" é o diretório onde estão localizados os arquivos de dados em formato csv, por exemplo, "c:/prevcargadessem/dados" (atenção para as barras) ou o nome do objeto `data.frame` com todos os dados necessários.

"diretório resultados" é o diretório onde serão gravados os arquivos com os resultados gerados pelo predictor, pode ser idêntico ao informado em "local dos dados" (atenção para as barras) ou o nome do objeto `data.frame` com os resultados gerados pelo predictor.

c1 (chave 1): 1 para leitura de dados no formato `data.frame` e 0 para leitura de dados no formato csv.

c2 (chave 2): especificação da variável temperatura na previsão da demanda média diária, abrange 4 possibilidades: 0 para ignorar os dados de temperatura, 1 para considerar apenas temperatura máxima diária, 2 para considerar apenas a temperatura média e 3 para considerar as temperaturas mínima e máxima.

c3 (chave 3): 1 para horizonte de previsão de oito dias, 0 para horizonte de previsão variável em função do dia da previsão e 2 para horizonte até a data informada no arquivo `HORIZONTE.csv`.

c4 (chave 4): Número de dias do horizonte de previsão com resolução semi-horária, entre 1 e 8.

c5 (chave 5): Tipo da função núcleo: 0 para SVM com *kernel* radial, 1 para SVM com *kernel* linear e 2 para RNA *feed forward* com dois neurônios na camada intermediária.

c6 (chave 6): Previsão combinada: 0 para execução do modelo de previsão correspondente à configuração das chaves c2 e c5 e 1 para execução de todos os 12 modelos e ponderação das previsões com base em pesos fornecidos no arquivo `XX_AAAA-MM-DD_COMBINA.CSV`.

prefixo: informe a área XX, o ano AAAA, mês MM e dia da previsão DD, conforme o padrão `XX_AAAA-MM-DD`, por exemplo, "NE_2019-09-20".

As opções apresentadas executam os arquivos de dados para o `PrevcargaDESSEM` disponibilizados na página do Sintegre ONS (<https://sintegre.ons.org.br/>). Para mais opções de execução digite `help(previsordessem)` no *prompt* do R. A seguir, tem-se a saída apresentada no ambiente R durante a execução do programa.

CEPEL - Centro de Pesquisas de Energia Eletrica

```
PPPP RRRR EEEEE V V CCCC AAA RRRR GGGG AAA DDDD EEEEE SSSSS SSSSS EEEEE M M
P P R R E V V C A A R R G A A D D E S S E MM MM
PPPP RRRR EEEEE V V C A A RRRR G GG A A D D EEEEE SSSSS SSSSS EEEEE M M M
P R R E V V C AAAAA R R G G AAAAA D D E S S E M M
P R R EEEEE V CCCC A A R R GGGG A A DDDD EEEEE SSSSS SSSSS EEEEE M M
```

- [1] "VERSAO 1.22"
- [1] "Opcoes de execucao"
- [1] "Treina modelos"
- [1] "Dados em arquivos CSV"
- [1] "Temperaturas maxima e minima no modelo de previsao da temperatura media diaria"
- [1] "redes neurais artificiais para previsao da demanda media diaria"
- [1] "previsao dos perfis dos dias especiais por semelhanca"
- [1] "Nome da serie: NE_2019-09-20_"
- [1] "CONCLUIDA LEITURA DO ARQUIVO PARAMETROS.CSV"
- [1] "Mensagem: Horizonte de previsao informado 2019-09-27"
- [1] "Mensagem: Horizonte de previsao alterado para 2019-09-27"
- [1] "CONCLUIDA LEITURA DO ARQUIVO c:/sintegre/NE_2019-09-20_HORIZONTE.csv"
- [1] "CONCLUIDA LEITURA DO ARQUIVO c:/sintegre/NE_2019-09-20_CARGAHIST.csv"
- [1] "CONCLUIDA LEITURA DO ARQUIVO c:/sintegre/NE_2019-09-20_FERIADOS.csv"
- [1] "CONCLUIDA LEITURA DO ARQUIVO c:/sintegre/NE_2019-09-20_HORAVERAO.csv"
- [1] "CONCLUIDA LEITURA DO ARQUIVO c:/sintegre/NE_2019-09-20_TEMP HIST.csv"
- [1] "CONCLUIDA LEITURA DO ARQUIVO c:/sintegre/NE_2019-09-20_TEMP PREV.csv"
- [1] "CONCLUIDA LEITURA DO ARQUIVO COM HORARIOS DOS PATAMARES DE CARGA"
- [1] "CONCLUIDA LEITURA DO ARQUIVO DOS PESOS PARA A RODADA COMBINADA"
- [1] "MONTAGEM DA SERIE DE CARGA GLOBAL"
- [1] "TRATAMENTO DE DADOS"
- [1] "TREINA MODELOS E EXECUTA PREVISAO"
- [1] "Previsao para o dia 2019-09-20"
- [1] "Previsao para o dia 2019-09-21"
- [1] "Previsao para o dia 2019-09-22"
- [1] "Previsao para o dia 2019-09-23"
- [1] "Previsao para o dia 2019-09-24"
- [1] "Previsao para o dia 2019-09-25"
- [1] "Previsao para o dia 2019-09-26"
- [1] "Previsao para o dia 2019-09-27"
- [1] "CALCULA PREVISAO SEMI HORARIA"
- [1] "AGREGA PREVISOES EM PATAMARES"
- [1] "GRAVANDO ARQUIVOS DE SAIDA"
- [1] "GRAVA ARQUIVO COM PREVISOES NO FORMATO DESSEM"
- [1] "EXECUCAO CONCLUIDA COM SUCESSO"

6. ACESSANDO AS PREVISÕES GERADAS PELO PREVCARGADESSEM

Após a execução do `PrevcargaDessem`, as previsões de carga global e de geração não supervisionada são armazenadas em objetos R `data.frames`, arquivos ".csv" e arquivo ".txt". Os arquivos ".csv" e ".txt" são gravados no diretório informado em "caminho_saída" na execução do `PrevcargaDESSEM`. Mais especificamente, os seguintes resultados são exportados pelo programa:

- Previsões de carga global em MW médio para cada área/subsistema em base semi-horária e patamar (arquivo `prevcargadessem_carga_global.csv` e `data.frame $CARGA_GLOBAL`).
- Previsões de carga global em MW médio para cada área/subsistema em base semi-horária e patamar no formato DESSEM (arquivo `saidadessem.txt`).
- Previsões da geração não supervisionada em MW médio para cada área/subsistema em base semi-horária e patamar.
- Previsões de carga global em MW médio para cada área/subsistema em base horária (arquivo `prevcargadessem_carga_global_horaria.csv` e `data.frame $PREVHORARIA`).

As previsões da carga global em base semi-horária e por patamar são gravadas no arquivo `prevcargadessem_carga_global.csv`. Na Figura 24 tem-se um extrato do arquivo. O arquivo possui quatro colunas, a primeira mostra o dia e horário das previsões, a segunda coluna (MW Dessem) mostra a previsão de carga com resolução semi-horária nas primeiras 48 ou 72 horas do horizonte (conforme definido na chave 4 na página 32) e por patamar nas demais horas, a terceira coluna mostra as previsões em base semi-horária ao longo de todo o horizonte de previsão e a quarta coluna exibe as previsões por patamar, ao longo do horizonte. Para acessar os mesmos resultados em uma versão `data.frame` digite `resultados$CARGA_GLOBAL`. Um arquivo semelhante denominado `prevcargadessem_carga_global_horaria.csv`, mostra as previsões em base horária, cuja versão em formato `data.frame` pode ser acessada pelo comando `resultados$PREVHORARIA` (com exceção da previsão combinada, chave 6 igual a 1 na página 32).

	A	B	C	D
1		MW Dessem	MW semi horaria	MW patamar
2	18/01/2018 00:30	38,080	38,080	37,144
3	18/01/2018 01:00	37,395	37,395	37,144
4	18/01/2018 01:30	36,698	36,698	37,144
5	18/01/2018 02:00	36,029	36,029	37,144
6	18/01/2018 02:30	35,469	35,469	37,144
7	18/01/2018 03:00	35,088	35,088	37,144
8	18/01/2018 03:30	34,957	34,957	37,144
9	18/01/2018 04:00	35,146	35,146	37,144
10	18/01/2018 04:30	35,700	35,700	37,144
11	18/01/2018 05:00	36,573	36,573	37,144
12	18/01/2018 05:30	37,693	37,693	37,144
13	18/01/2018 06:00	38,989	38,989	37,144
14	18/01/2018 06:30	40,388	40,388	37,144
15	18/01/2018 07:00	41,809	41,809	37,144
16	18/01/2018 07:30	43,167	43,167	46,487
17	18/01/2018 08:00	44,380	44,380	46,487
18	18/01/2018 08:30	45,379	45,379	46,487
19	18/01/2018 09:00	46,164	46,164	46,487
20	18/01/2018 09:30	46,750	46,750	46,487
21	18/01/2018 10:00	47,152	47,152	46,487
22	18/01/2018 10:30	47,394	47,394	46,487
23	18/01/2018 11:00	47,539	47,539	46,487
24	18/01/2018 11:30	47,656	47,656	46,487
25	18/01/2018 12:00	47,816	47,816	46,487

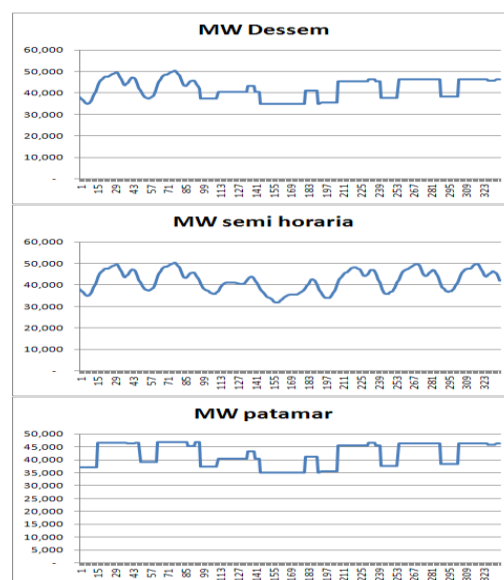
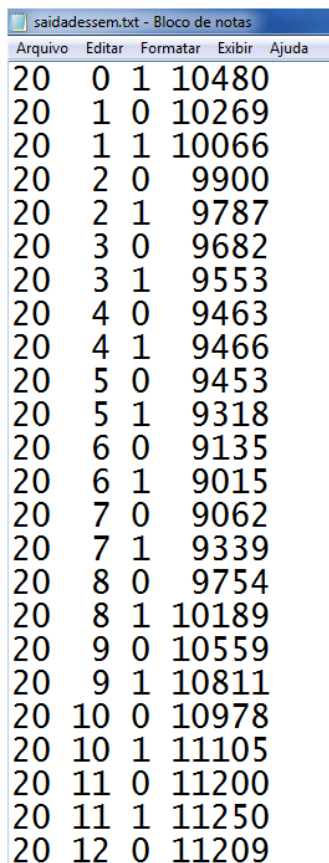


Figura 24. Arquivo `PREVCARGADESSEM_CARGA_GLOBAL.csv`.

Adicionalmente, o programa produz o arquivo `saidadesse.txt` ilustrado na Figura 25 com as previsões semi-horárias no formato para o `DESSEM`.



Arquivo	Editar	Formatar	Exibir	Ajuda
20	0	1	10480	
20	1	0	10269	
20	1	1	10066	
20	2	0	9900	
20	2	1	9787	
20	3	0	9682	
20	3	1	9553	
20	4	0	9463	
20	4	1	9466	
20	5	0	9453	
20	5	1	9318	
20	6	0	9135	
20	6	1	9015	
20	7	0	9062	
20	7	1	9339	
20	8	0	9754	
20	8	1	10189	
20	9	0	10559	
20	9	1	10811	
20	10	0	10978	
20	10	1	11105	
20	11	0	11200	
20	11	1	11250	
20	12	0	11209	

As colunas são separadas por espaço e cada linha do arquivo texto tem a seguinte codificação:

Dia / Hora / Dummy Meia-Hora / Valor da carga

A *dummy* Meia-Hora vale 0 para a hora cheia e 1 para a meia hora.

Assim, para a carga de 10480 MW em 00:30 h do dia 20 tem-se que Dia = 20, Hora = 0, *dummy* Meia-hora = 1 e Valor da carga = 10480 MW

Analogamente, para a carga de 10269 MW para a primeira hora (01:00 h) do dia 20, tem-se a seguinte codificação: Dia = 20, Hora = 1, *dummy* Meia-hora = 0 e Valor da carga = 10269 MW

Figura 25. Arquivo saidadessem.txt com previsões semi-horárias no formato DESSEM.

7. 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.

Bates, J. M.; Granger, C. W. J. The combination of forecasts. *Operations Research Quarterly*, 20:451–468, 1969.

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

Cannon, R.L.; Dave, J.V.; Bezdek, J.C. Efficient Implementation of the Fuzzy c-Means Clustering Algorithms, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 8, n. 2, pp. 248-255, March, 1986.

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. *O Algoritmo Mestre*, São Paulo: Novatec, 2017

Dubinsky, A.; Elperin, T. A method for calculating a load curve using average values of load over time intervals, *International Journal of Electrical Power & Energy Systems*, v. 19, n. 6, pp. 393-395, August, 1997.

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

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

Haykin, S. *Neural networks and learning machines*, Third Upper Saddle River, NJ: Pearson Education, 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.

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.

Kovács, Z.L. *Redes Neurais Artificiais: fundamentos e aplicações*, São Paulo: Edição Acadêmica, 1996.

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.

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.

Relatório Técnico – 6061 / 2019

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.

Pessanha, J.F.M.; Melo, A.C.G.; Justino, T.C.; Maceira, M.E.P. Combining Statistical Clustering Techniques and Exploratory Data Analysis to Compute Typical Daily Load Profiles - Application to the Expansion and Operational Planning in Brazil, IEEE International Conference on Probabilistic Methods Applied to Power Systems (PMAPS), 24-28 June, Boise-ID, USA, 2018.

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 Classiers, 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.

Werbos, P.J. Backpropagation through time: What it does and how to do it, Proceedings of the IEEE, v. 78, n. 10, October, 1990.

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.

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.