

Uso de redes neurais RBF e GRNN para comparação de previsões de carga de longo prazo de energia elétrica

E. L. Oliveira

Universidade Federal de Minas Gerais - Escola de Engenharia
Avenida Antônio Carlos, 6627
Belo Horizonte/Minas Gerais - Brasil CEP 31270-901
Email: evandrolopes@dcc.ufmg.br

C. L. Castro

Universidade Federal de Minas Gerais
Escola de Engenharia
Email: crislcastro@ufmg.br

Frederico Coelho

Universidade Federal de Minas Gerais
Escola de Engenharia
Email: fredgfc@ufmg.br

R. R. Saldanha

Universidade Federal de Minas Gerais
Escola de Engenharia
Email: rodney@cpdee.ufmg.br

S. Nóbrega

Universidade Federal de Minas Gerais
Departamento de Ciência da Computação
Email: sophia@dcc.ufmg.br

L. D. Tavares

Universidade Federal de Minas Gerais
Escola de Engenharia
Email: tavares@dcc.ufmg.br

H. P. Rocha

Universidade Federal de Minas Gerais
Escola de Engenharia
Email: honovan@gmail.com

Abstract—In planning the electric power sector, where power load forecast is important, methods to improve data prediction should be studied. Neural networks help in this study in finding applications in different scientific areas and exploiting their abilities to generate predictions. This work performs a long-term load prediction of energy in southeastern Brazil by comparing the results of the RBF network and the GRNN network in a forecast range of seven years, with estimates obtained by the autoregression and naïve methods.

Resumo—No planejamento do setor elétrico de potência, onde é importante a previsão de carga de energia, o estudo de métodos que possam melhorar a antecipação de dados é algo a ser estudado. As redes neurais tem ajudado nesse estudo, pois encontram aplicações em diferentes áreas científicas e exploram suas habilidades para gerar previsões. O presente trabalho faz a predição de carga de longo prazo de energia da região sudeste do Brasil comparando o resultado da rede RBF à rede GRNN em um espaço de previsão de sete anos, com estimativas por método de autorregressão e por método naïve.

I. INTRODUÇÃO

Para as concessionárias de energia elétrica, prever o consumo serve de suporte para tomada de decisões e funções de controle do sistema elétrico de potência. O despacho econômico, planejamento da expansão, compra e venda de energia, são efetivadas com a disponibilidade dessas estimativas de previsão a serem atendidas, classificadas de acordo com o cenário e período [1].

Por gerar resultados interessantes na situação atual do sistema elétrico de potência dentro dos horizontes de previsão de médio, longo e curto prazo, [4] o uso de redes neurais é uma boa opção de ferramenta para estimativa de valores de carga elétrica.

As redes neurais são estruturas de processamento passíveis de implementação que ajudam no processamento e organização de informações. São amplamente utilizadas para diferentes áreas de aplicação. Elas podem receber ao mesmo tempo várias entradas e distribuí-las de maneira organizada, assim com a possibilidade de aprendizagem correspondente à identificação de conjuntos apropriados de pesos, de forma que se comporte como o esperado.

A rede neural utilizada para previsão de carga nesse trabalho, possui tipo de função de base radial, *Radial Basis Function Networks* (RBF). Essas redes são de modelagem não-linear e estatística de dados, podendo encontrar padrões em uma coleção de dados, ou serem utilizadas para modelagem de relações complexas entre entrada e saída [2].

Os resultados encontrados pela rede RBF, no processo de predição de carga, estão sendo comparados neste trabalho aos resultados da rede neural de regressão generalizada, *General Regression Neural Network* (GRNN), dentro do mesmo contexto. Essa rede de regressão generalizada, que possui uma estrutura fixa, tem sido utilizada nos últimos anos justamente para resolução de problemas de séries temporais como a de cargas elétricas [11]. Para gerar o resultado das estimativas para as duas redes, foram testados métodos de previsão para obtenção de dados que se aproximassem das informações reais.

A análise da escala de tempo envolvida na previsão e quão longe no futuro está se tentando prever, é determinada nas situações estudadas, e por isso, diferentes métodos de previsão se aplicam em cada situação, sendo que dentre os que usam de dados histórico das variáveis de interesse, pode-se categorizar a série temporal, regressão e a simulação.

Tabela I. PERÍODOS DE PREVISÃO

Escala de tempo	Tipo de Decisão	Exemplos
Curto prazo	Operacional	Controle de estoque, planejamento da produção, distribuição
Prazo médio	Tática	Leasing de planta e equipamento, mudanças de emprego
Longo prazo	Estratégica	Pesquisa e Desenvolvimento, Aquisições e fusões, variações de produto

Um dos métodos avaliados para previsão de carga nesse trabalho é o *naïve*, que é um modelo que toma o último registro conhecido como sendo a previsão para o próximo período, desconsiderando a sazonalidade da variável dependente. Ele é conhecido como preditor ingênuo, justamente por assumir que o passo futuro é o passo anterior [3].

Outro método de previsão quantitativa baseado em séries temporais também avaliado no trabalho é o de auto regressão, que faz a previsão baseada no comportamento dos resultados passados da série [13].

Esse trabalho tem o foco nas metodologias aplicáveis à previsão de carga de energia elétrica através da identificação do comportamento da demanda por hora como fator exógeno. Os modelos propostos serão baseados em redes neurais artificiais e as abordagens propostas serão implementadas e aplicadas à previsão do comportamento futuro de carga própria da região sudeste.

Os dados utilizados da região sudeste do Brasil são extraídos do consumo, e tem por objetivo a previsão de carga por incorporação de novos dados anuais a partir de relatórios do Operador Nacional do Sistema (ONS).

O restante do trabalho está organizado da seguinte maneira: Na Seção 2 são descritos os métodos de previsão; As redes RBF e GRNN serão apresentadas na seção 3; Os resultados e avaliações realizadas na seção 4; Trabalhos futuros e conclusões na seção 5.

II. METODOLOGIAS DE PREVISÃO DE CARGAS

As metodologias baseadas em sistemas inteligentes vem apresentando bons resultados na solução de problemas de previsão de carga dentro de seus horizontes de previsão [9].

Segundo diferentes horizontes, a classificação da previsão se dá em três tipos, a saber: previsão de carga a longo prazo, médio prazo e curto prazo, como pode ser visualizado na Tabela 1.

A previsão se classifica, conforme o intervalo estimado. Essa classificação segue a contagem de períodos estimados para curto prazo em 3 intervalos futuros, médio prazo em um horizonte de 3 a 20 períodos, e longo prazo acima de 20 períodos. Em função disso, os períodos curtos em unidade de tempo variam em 3 meses, os médios de 3 meses a 2 anos e os de longo prazo com tempo superior a 2 anos [12].

O objetivo das previsões de demanda pelas concessionárias de energia está na definição do montante da energia elétrica, comercialização, subsidio de programas de investimento no setor e redução de perdas [7]. Esses objetivos são alcançados buscando atividades como elaboração de cenários da atividade

econômica e do comportamento demográfico, o desempenho histórico do mercado e o uso de métodos de previsão.

A. Método de previsão por autorregressão

Autorregressão é o processo de estimar o valor futuro de uma variável com base no valor que esta mesma variável apresentou no passado em escala de progressão. Esse tipo de modelo foi primeiramente apresentado em 1926 e posteriormente complementada através do esquema de média móvel [18].

O modelo autorregressivo (AR(p)) é definido por:

$$Z_t = \sum_{i=1}^p \Phi_i Z_{t-i} + \varepsilon_t \quad (1)$$

Os coeficientes Φ_i e ε_t são desconhecidos e estimados através dos dados. As estimativas são utilizadas para fazer previsão e usualmente são sujeitas a revisão [14]. Isso se dá por que mesmo que o modelo de estimação autorregressivo seja bom, sempre haverá erros de estimação. Muitas vezes estes erros podem impactar no resultado final da estimação.

Os modelos autorregressivos parte do pressuposto de que a observação da série Z_t pode ser explicada como uma função das p observações passadas, $Z_{t-1}, Z_{t-2}, \dots, Z_{t-p}$, onde p determina o número de passos entre as observações passadas e a previsão da próxima observação [10].

B. Método de previsão ingênua (*naïve*)

O modelo de previsão *naïve* estima que a demanda do próximo período é igual à demanda do período atual, ou seja, um período à frente. A previsão de Z_{t+1} é apenas a última observação de Z_t [6].

Esse método é uma forma de estimação que leva em conta o erro de medida. Consiste em substituir uma variável de interesse x_i pela variável w_i na estimação usual do modelo de regressão logística, isso significa ajustar o modelo para os dados (w_i, y_i) , $i = 1, \dots, n$ [15] com base em:

$$w_i = x_i + u_{ij} \quad i = 1, 2, \dots, n \quad j = 1, \dots, r_i \quad (2)$$

A estrutura da Equação 2 mostra que w_{ij} é a j -ésima réplica r_i para a variável observada considerando erro u_{ij} .

III. REDES NEURAIS ARTIFICIAIS

As Redes Neurais Artificiais (RNA) são sistemas computacionais constituídos por unidades neurais, consistindo de elementos de processadores interligados. Os neurônios ligados em paralelo desempenham determinadas tarefas e fazem com que os modelos de redes neurais artificiais RNA's sejam uma importante técnica de estatística não-linear capaz de resolver um grande número de problemas complexos [16].

A RNA pode ser vista como uma estrutura de processamento em rede com um circuito composto por uma quantidade de unidades de processamento simples inspiradas na rede neural biológica [17].

A. Rede Neural de Função de Base Radial (RBF)

A rede RBF é um modelo de rede neural em que a ativação de uma unidade oculta é determinada pela distância entre o vetor de entrada e um vetor protótipo [8].

A forma básica da rede consiste em uma camada de entrada, que conecta a RNA ao seu ambiente, uma camada oculta e uma camada de saída como na Figura 1.

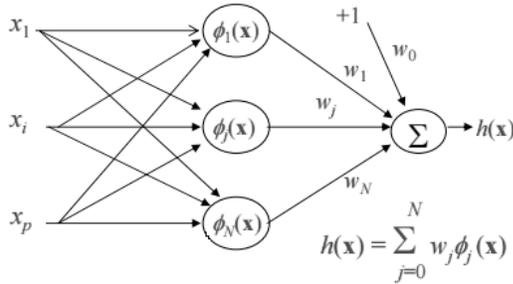


Figura 1. Arquitetura da rede RBF [8]

As redes RBF, tem como principal característica a utilização de funções de base radial em todos os nós da camada oculta. Ao contrário de utilizar como argumento a função de produto escalar entre os valores do vetor de entrada e os valores do vetor de peso dos neurônios, essa rede utiliza a distância entre os valores do vetor de entrada e o seu centro [5].

B. Rede Neural de Regressão Generalizada (GRNN)

A rede neural GRNN é uma rede que estima variáveis dependentes a partir de variáveis independentes, envolvendo um conjunto de variáveis finito. O treinamento é supervisionado e possui uma estrutura fixa, dada por uma camada de entrada, duas intermediárias e uma de saída como mostra a Figura 2. O número de neurônios tem dependência com o padrão de treinamento, nas entradas e saídas da rede [11].

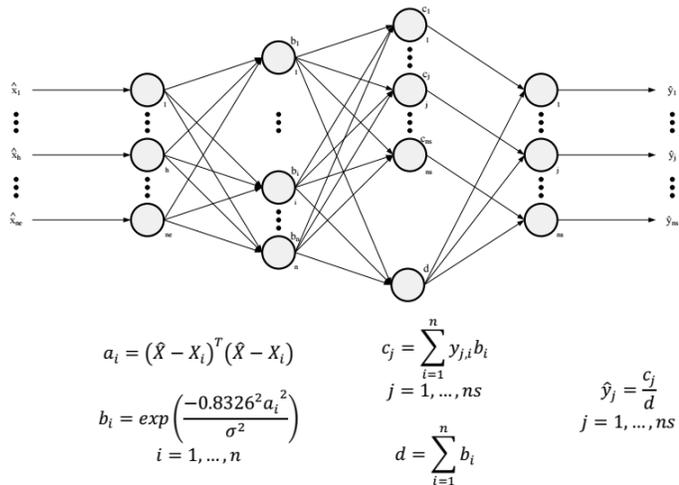


Figura 2. Arquitetura da rede GRNN [11]

A rede GRNN, é uma alternativa à rede RBF. A camada oculta da rede se conecta à de saída por meio de pesos de valor igual aos valores desejados e o valor de saída é dado pela média ponderada das ativações intermediárias [8].

Tabela II. PERCENTUAIS POR CLASSE DE CONSUMO

Subgrupo	Total
A1	20,38%
A3	0,74%
A3A	0,45%
A4	21,02%
A2	20,38%
RES	19,62%
RUR	4,35%
IND	1,42%
IP	2,53%
COM	9,11%
	100,00%

IV. PREVISÃO DE CARGA

A. Dados que foram trabalhados

O objetivo principal do trabalho é a previsão da demanda do Sistema Interligado Nacional (SIN) no período do ano de 2010 à 2017 para a região sudeste. Os dados de consumo da região sudeste de 2000 à 2010 foram utilizados para treinamento e os dados de 2010 a 2015 foram utilizados para validação das redes. Os dados de consumo do ONS foram distribuídos nas classes de consumo de acordo com os percentuais médios observados para a região sudeste que estão relacionados na Tabela 2.

Curvas de carga típicas médias da região sudeste para cada uma das classes de consumo foram utilizadas na proporção de consumo da Tabela 2 para compor a carga própria da região sudeste. A curva de carga própria obtida estava em escala horária uma vez que as curvas típicas são em base horária, e foram convertidas para base mensal para a sua utilização neste trabalho.

A curva de carga própria mensal pode ser observada na Figura 3. Esses foram os dados usados para a predição no uso da rede RBF e GRNN, sendo que os dados compreendidos no período de 2000 a 2010 (com uma janela de 2 meses) foram utilizados para o treinamento das redes. Cada pico do gráfico corresponde ao término de um ano (12 meses), e o vale seguinte a ele corresponde ao início de um novo ano.

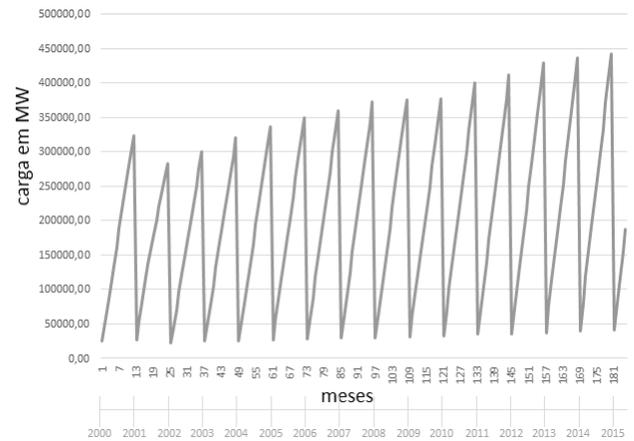


Figura 3. Dados de carga dos meses dos anos 2000 à 2015

B. Resultados para rede RBF

Para aproximação dos anos de 2000 a 2010, usando a rede RBF, o procedimento que foi tomado seguiu a implementação

em que foi montada uma matriz de amostras contendo duas janelas, foi feito o agrupamento das mesmas com o k-means, que é um algoritmo de agrupamento de dados popular, e em seguida foram obtidas as médias das funções de ativação. Foi montada a matriz de distância euclidiana entre os centros dos agrupamentos e calculada a largura tirando a média das distancias. O valor de saída foi a entrada para a primeira camada da RBF treinada por uma rede de camada única Adalaine, para que então fosse calculada a saída da RBF.

A aproximação alcançada pela rede RBF pode ser observada na Figura 4, que mostra o valor alcançado em comparação ao valor real. A aproximação dos dados de saída com o real chegam à 99,68%.

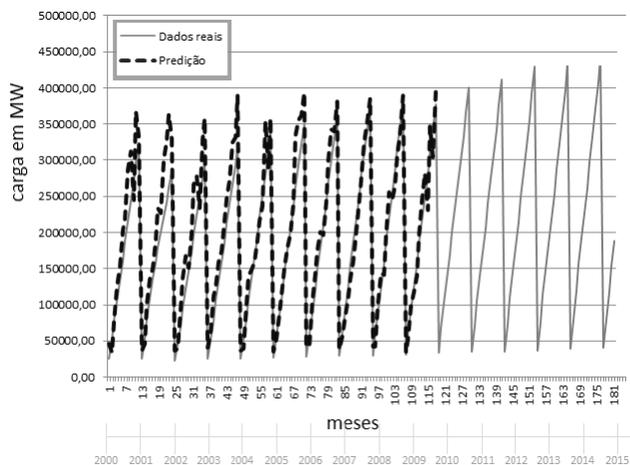


Figura 4. Predição da rede RBF de 2000 à 2010

Com base na aproximação alcançada de 2000 à 2010 foi feita a previsão para os próximos 7 anos usando dois métodos de previsão que foram a autorregressão e o naïve.

Com o método de autorregressão foram obtidos os resultados que podem ser observados na Figura 5, com previsão para os 5 primeiros anos em 96,8% para o real. Já com o método naïve para a mesma faixa observada obteve-se uma previsão de 97,01% para o real, também podendo ser observado na Figura 5.

C. Resultados para rede GRNN

Para a aproximação dos anos de 2000 a 2010, usando a rede GRNN, o procedimento que foi tomado seguiu a passagem dos parâmetros de período a ser aproximado com um espaçamento de 2 meses.

A aproximação alcançada pela rede GRNN poder observada na Figura 6, que mostra o valor alcançado em comparação ao valor real. Os valores de aproximação chegam à 97,21%.

Da mesma forma que com o experimento feito com a rede RBF, utilizou-se o modelo gerado pela GRNN a partir do período compreendido entre 2000 à 2010 e foi feita a previsão dos últimos 7 anos usando os dois métodos de previsão de autorregressão e naïve.

Com o método de autorregressão foram obtidos os resultados que podem ser observados na Figura 7, com previsão para os 5 primeiros anos em 97,85% de acerto com relação

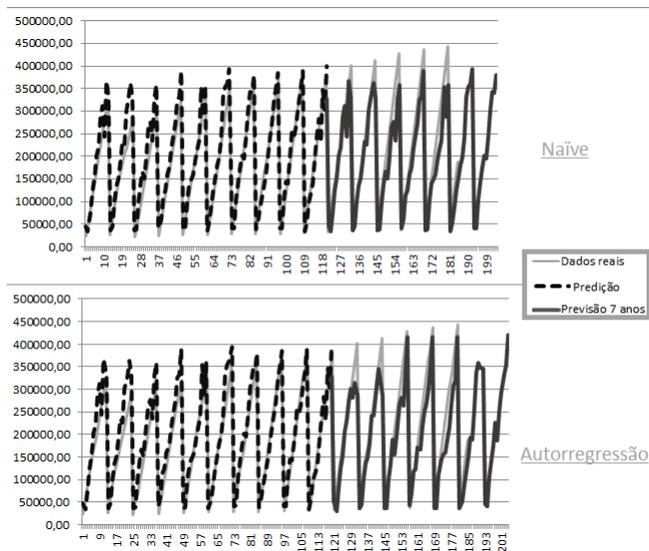


Figura 5. Previsão naïve e autorregressão para rede RBF de 2010 à 2017

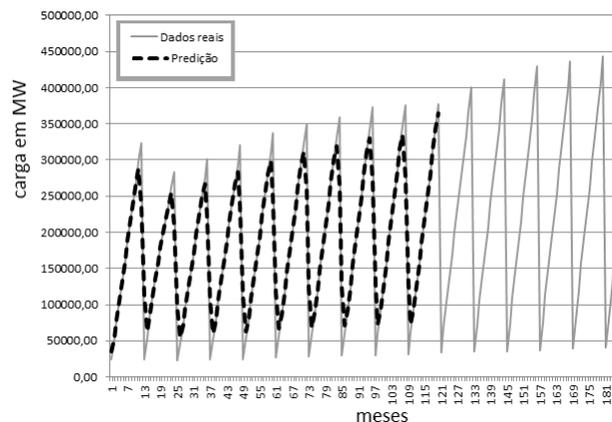


Figura 6. Predição da rede GRNN de 2000 à 2010

aos dados reais. Já com o método naïve para a mesma faixa observada obteve-se uma aproximação de 91,41% para o real, também podendo ser observado na Figura 7.

D. Comparativo entre as redes

Foi gerada uma estimativa por ajuste de curvas polinomiais buscando a tendência da série de dados reais e comparada aos valores de predição alcançados pelas 2 redes. A tendência pode ser observada na Figura 8.

Essas curvas de tendência não foram baseadas nos resultados gerados a partir das redes RBF e GRNN no uso dos respectivos métodos autorregressão e naïve. A projeção da Figura 8 é feita usando apenas os dados reais.

Observou-se que a rede RBF obteve valores com uma diferença média total de 2,07% em relação a GRNN quando considerada a previsão para os anos de 2015 à 2017, o que não é proporcionalmente diferente. A Tabela 3 mostra os dados em que essa diferença é mais evidente na estimativa de previsão pelos 2 métodos, autorregressão e naïve. Para que fosse mostrado qual das duas redes obteve um melhor

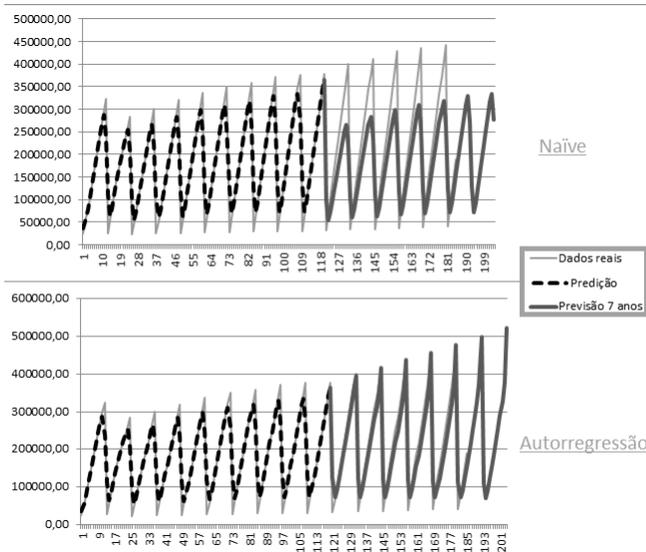


Figura 7. Previsão naïve e autorregressão para rede GRNN de 2010 à 2017

Tabela III. APROXIMAÇÃO DA TENDÊNCIA POR REDE NEURAL E MÉTODOS DE PREVISÃO

Tendência	RBF		GRNN	
	naïve	auto regressão	naïve	auto regressão
Linear	75,36%	75,37%	83,54%	76,43%
Quadrática	75,30%	75,01%	83,30%	76,09%

resultado, aquele que se aproximasse mais das curvas de tendência, foi calculado a aproximação em relação às 2 redes e mostrado o resultado da estimativa de tendência para os anos previstos.

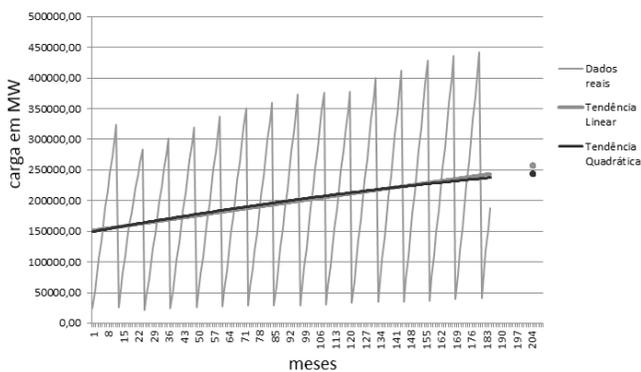


Figura 8. Tendência da série de dados reais para 2017

V. TRABALHOS FUTUROS E CONCLUSÕES

Foi constatado que muitos dos problemas enfrentados pelas concessionárias de energia, em específico as complexidades associadas à demanda de energia elétrica futura, podem ser solucionados a partir da utilização de conceitos e métodos adequados ao uso de redes neurais, sendo possível prever um cenário futuro com menores erros.

É considerado que ainda possa existir a necessidade de revisão e atualização dos métodos utilizados para consolidar os

resultados, visando aprimorar o trabalho, porém os resultados obtidos tem aproveitamento para aplicação em previsões reais, mesmo trabalhando com uma variável exógena.

Para esse trabalho não foram consideradas outras variáveis exógenas se não o histórico de carga, mas algo a ser trabalhado futuramente é o emprego de outros pontos de importância e que tem influência direta na previsão de carga, como o produto interno bruto.

O trabalho apresenta uma comparação final entre as redes e os métodos de previsão empregados. A forma como foi desenvolvido fornece mecanismos para previsão de carga de energia elétrica com certa precisão garantida pelos dados que foram expostos.

Pode ser observado que a rede RBF faz uma aproximação melhor da carga de energia quando comparada à rede GRNN. Essa predição é concisa e segue bem a tendência da série.

A rede GRNN mesmo com sua aproximação inicialmente inferior, mantém o mesmo ritmo para os anos seguintes e faz uma predição com maior exatidão, além da previsão por autorregressão ter mostrado melhores resultados do que a previsão por método ingênuo.

Nota-se que a predição feita com dados detalhados, por hora convertidos para meses, faz com que o resultado final se torne mais confiável e preciso, visto que não é algo trivial a disponibilidade de tais informações e os recursos hoje existentes, em sua grande maioria, se faz de dados a nível mensal ou anual.

Como o presente trabalho traz em seu conteúdo informações comparativas, pretende-se trabalhar com as ferramentas que geram melhores resultados, e também mesclar novas ferramentas para que o mesmo possa ser refinado. Na literatura, alguns trabalhos se valem de modelos híbridos para previsão de carga no uso de redes neurais artificiais [11].

Uma aposta possível seria mesclar o que foi obtido de melhor uso das redes neurais e métodos de previsão no presente trabalho empregando novas variáveis pra que se pudesse obter uma previsão de carga a nível nacional.

A previsão feita está voltada para uma região específica e vale a pena fazer o experimento com dados de outras regiões ou de todo o Brasil, porque mesmo a região sudeste apresentando o maior consumo de energia elétrica, inclusive com o distanciamento maior para com as outras regiões conforme o ONS, seria importante o mapeamento do consumo futuro para planejamento de inclusão de novas fontes de energia.

REFERÊNCIAS

- [1] ALTRAN, Alessandra Bonato. "Sistema Inteligente Para Previsão de Carga Multinodal em Sistemas Elétricos de Potência". Tese de Doutorado - Faculdade de Engenharia - UNESP – Campus de Ilha Solteira, 2010.
- [2] ALIAGA, Daniel Kraemer. "Redes Neurais Artificiais RBF". Artigo do Programa de Pós-Graduação em Engenharia de Automação e Sistemas - Universidade Federal de Santa Catarina, 2013.
- [3] ALMEIDA, Fernando Carvalho de Almeida; PASSARI, Antônio Fabrício Lima. "Previsão de vendas no varejo por meio de redes neurais". R.Ad., São Paulo, v.41, n.3, p.257-272 - Departamento de Administração da Faculdade de Economia, Administração e Contabilidade da Universidade de São Paulo, 2005.

- [4] ANDRADE, Luciano Carli Moreira de. "Abordagem Neurofuzzy para previsão de energia elétrica no curtíssimo prazo". Dissertação de mestrado - Escola de Engenharia de São Carlos - Universidade de São Paulo, 2010.
 - [5] BONIFÁCIO, Fernando Nunes. "Comparação entre as Redes Neurais Artificiais MLP, RBF e LVQ na Classificação de Dados". Monografia em ciência da computação - Universidade Estadual do Oeste do Paraná, 2010.
 - [6] CARVALHO, Carlos Alexandre Vieira de. "Análise de Previsão de Itens de Demanda Intermitente Utilizando o Modelo SyntetosBoylan Approximation (SBA)". Artigo para XXXVI Encontro da ANPAD, Rio de Janeiro, 2012.
 - [7] DIAS, Robson da Silva. "Metodologia de Previsão de Carga de Longo Prazo de Energia Elétrica". Monografia em Engenharia Elétrica - Universidade Federal do Ceará, 2010.
 - [8] ENGEL, Paulo Martins. "A rede RBF". Pós graduação em computação - Disciplina : CMP 121: Redes Neurais - Informática - Universidade Federal do Rio Grande do Sul.
 - [9] FERREIRA, Vitor Hugo. "Técnicas de regularização de modelos neurais aplicadas à previsão de carga a curto prazo". Tese de doutorado - Universidade Federal do Rio de Janeiro, 2005.
 - [10] FIGUEIREDO, Clodoaldo José. "Previsão de Séries Temporais Utilizando a Metodologia Box e Jenkins e Redes Neurais para Inicialização de Planejamento e Controle de Produção". Dissertação de mestrado - Universidade Federal do Paraná, 2008.
 - [11] FILHO, Kenji Nose. "Previsão de carga multinodal utilizando redes neurais de regressão generalizada". Dissertação de mestrado - Universidade Estadual Paulista, 2011.
 - [12] LEMOS, Fernando Oliveira. "Metodologia para seleção de métodos para previsão de demanda". Dissertação de mestrado - Universidade Federal do Rio Grande do Sul, 2006.
 - [13] MODENESI, Gustavo. "Modelo de previsão de demanda de gás natural". Monografia em Engenharia de Produção - Escola Politécnica da Universidade de São Paulo, 2007.
 - [14] MORETTIN, Pedro Alberto; TOLOI, Célia Maria de Castro. "Modelo para previsão de séries temporais". Instituto de matemática pura e aplicada. Rio de Janeiro, 1981.
 - [15] RODRIGUES, Agatha Sacramento. "Regressão lógica com erro de medida: comparação de métodos de estimação". Dissertação de mestrado - Instituto de matemática e estatística. Universidade de São Paulo, 2013.
 - [16] VELLASCO, Marley Maria Bernardes Rebuszi. "Redes Neurais". Laboratório de inteligência computacional aplicada - ICA - Introdução pag.3 - PUC Rio de Janeiro, 2007.
 - [17] NIGRIN, A. "Neural Networks for Pattern Recognition" Cambridge, MA: The MIT Press, 1993.
 - [18] ZOUCAS, Fabio Augusto Mollik. "Aplicação de redes neurais para previsão de séries temporais em segmentos industriais". Dissertação de mestrado - Centro Universitário da FEI, São Bernardo do Campo, 2009.
- Nigrin, A. (1993),