

CONTROLADOR DE DEMANDA DE ENERGIA ELÉTRICA UTILIZANDO REDES NEURAS ARTIFICIAIS

CONTROLLER OF ELECTRICAL ENERGY DEMAND USING ARTIFICIAL NEURAL NETWORKS

Mateus Coelho Vieira¹; Wilian Soares Lacerda²; Joaquim Paulo da Silva³

1. Mestre em Engenharia de Sistemas e Automação, UFLA, 2016. Professor no Centro Federal de Educação Tecnológica de Minas Gerais - CEFET/MG, Campus Nepomuceno, MG. mateuscv1@gmail.com.
2. Doutor em Engenharia Elétrica, UFMG, 2006. Professor associado da Universidade Federal de Lavras, do Departamento de Ciência da Computação, Lavras, MG. lacerda@dcc.ufla.br.
3. Doutor em Engenharia Elétrica, UFMG, 2001. Professor associado da Universidade Federal de Lavras, do Departamento de Física, Lavras, MG. joaquim@dex.ufla.br.

Recebido em: 23/01/2017 - Aprovado em: 09/11/2017 - Disponibilizado em: 30/11/2017

RESUMO: Na atual situação mundial de escassez de recursos, a economia de energia elétrica tornou-se algo relevante. Sendo assim, a Universidade Federal de Lavras, com o objetivo de evitar a ultrapassagem da demanda de energia elétrica contratada, adquiriu um sistema controlador de demanda. O presente trabalho teve como objetivo melhorar o desempenho do controlador de demanda, otimizando, de forma inteligente e dinâmica, a prioridade de desligamento das cargas. Para isso, foram utilizadas técnicas de inteligência computacional para a criação de um sistema automatizado que aliado ao controlador de demanda possa obter um melhor desempenho. Foi desenvolvido um sistema de classificação da prioridade de cada carga, bem como um sistema de previsão da demanda de energia elétrica para os próximos 15 minutos. A metodologia empregada foi baseada em Redes Neurais Artificiais para o desenvolvimento dos dois sistemas computacionais trabalhando paralelamente. Através dos resultados obtidos em simulação verifica-se índices satisfatórios para o sistema de previsão e para o sistema de classificação. Conclui-se através dos resultados obtidos que o controlador de demanda, com a aplicação das técnicas de previsão e classificação, terá uma otimização do processo de desligamento das cargas.

PALAVRAS-CHAVE: Energia elétrica. Rede neural artificial. Controlador de demanda.

ABSTRACT: In the current global situation of scarcity of resources, the saving of electric energy has become relevant. Therefore, the Federal University of Lavras, with the objective of avoiding the surpassing of contracted electric energy demand, acquired a demand controlling system. The present work had as objective to improve the performance of the demand controller, optimizing, intelligently and dynamically, the priority of load disconnection. For this, computational intelligence techniques were used to create an automated system that together with the demand controller can achieve better performance. A priority classification system for each load was developed, as well as a system for forecasting the demand for electricity for the next 15 minutes. The methodology used was based on Artificial Neural Networks for the development of the two computational systems working in parallel. The results obtained in the simulation showed satisfactory indexes for the prediction system and for the classification system. It is concluded through the results obtained that the demand controller, with the application of the forecasting and classification techniques, will have an optimization of the load disconnection process.

KEYWORDS: Electricity. Artificial neural network. Demand controller.

1 INTRODUÇÃO

Partindo de conhecimentos observados ao longo do tempo, percebe-se que o ser humano atingiu o apogeu do seu desenvolvimento em muitos aspectos. Atualmente, ocorre uma valorização demasiada de bens de consumo e o desprezo de outros bens de valor inestimável para a sobrevivência humana no planeta. Entre esses bens valorizados, uma grande maioria encontra-se dependente da energia elétrica.

Segundo a Agência Nacional de Energia Elétrica (BRASIL, 2017), a capacidade de geração instalada e fiscalizada no Brasil, em 2017, chegou a 163.137.722 kilowatts (kW), sendo 64,42% provenientes de usinas hidrelétricas, 26,64% de usinas termelétricas, 7,45% de usinas eólicas, 1,29% de usinas nucleares e 0,2% de usinas solares.

Analisando os dados supracitados, constata-se que o Brasil depende muito da energia elétrica gerada por meio de usinas hidrelétricas. Essas, por sua vez, necessitam dos mananciais dos rios e seus reservatórios, que estão atualmente com níveis muito baixos. Para sanar a demanda de energia no Brasil, medidas foram tomadas pelos governos, as quais trazem um aumento considerável do preço para o consumidor.

A crise do fornecimento de energia afeta todos os níveis da população. O problema não é mais somente o preço das tarifas cobradas pelas concessionárias. A questão apresenta um aspecto bem mais amplo, uma vez que as concessionárias não dispõem de energia suficiente para suprir as atuais necessidades sem a utilização de fontes poluidoras. Essa preocupação afeta as grandes instituições de forma significativa. Para esta pesquisa, tomou-se por base a Universidade Federal de Lavras (UFLA) e suas necessidades. A Instituição encontra-se em pleno crescimento físico e intelectual. Entretanto, a Universidade compreende que todo esse crescimento pode acarretar falta de energia, já que há a

necessidade de aumentar a carga demandada. Assim sendo, a UFLA foi obrigada a procurar soluções para a falta de energia no *campus*.

Uma das medidas adotadas foi a obtenção de um Controlador de Demanda. Esse tem como função limitar o consumo total da instalação, por meio do desligamento automático de algumas cargas de menor necessidade num determinado intervalo temporal (ANDRADE, 2010).

Em sua operação, o controlador de demanda através da saída óptica do medidor de energia, verifica continuamente o consumo das cargas e caso ocorra uma ultrapassagem da demanda máxima permitida, ele desliga gradativamente as cargas por ele controladas seguindo um critério pré-definido. Mas, observando o seu funcionamento, verificou-se que o mesmo deixa a desejar no que tange a prioridade das cargas a serem desligadas. Algumas cargas de maior importância, em um determinado momento, poderiam ser desligadas enquanto outras, com menor importância, poderiam permanecer ligadas. Além disso, algumas cargas são sempre desligadas independentes do último desligamento das mesmas, tornando o sistema repetitivo.

Uma das formas de aperfeiçoar o funcionamento do controlador de demanda é a utilização de um sistema de previsão de demanda e classificação contínua de prioridade das cargas. Para tal, utilizou-se de um sistema de inteligência computacional baseado em Redes Neurais Artificiais (OLIVEIRA, 2016). Essas redes são responsáveis pela previsão e classificação dinâmica de prioridades, avaliando a necessidade de atuação e qual carga será de maior ou de menor prioridade em dado momento quando o controlador necessitar exercer sua função de controle (desligamento).

Dentre os objetivos deste trabalho estão:

- Desenvolver e testar um sistema de previsão de cargas com um horizonte de previsão de 15

minutos, utilizando os dados de medição de consumo de energia da Universidade Federal de Lavras;

- Desenvolver e testar um sistema de definição de prioridade dinâmica de desligamento de cargas para evitar a ultrapassagem da demanda de energia contratada baseado no conhecimento de especialista da área;
- Testar o funcionamento do sistema desenvolvido em conjunto com o controlador de demanda instalado na Universidade Federal de Lavras e verificar seu funcionamento e eficiência obtida.

Como objetivo geral, pretende-se investigar e aperfeiçoar um sistema automático para controle de demanda de cargas elétricas na Universidade Federal de Lavras, com capacidade de previsão da demanda futura e definição de prioridade de desligamento utilizando técnicas de inteligência computacional do tipo Redes Neurais Artificiais (RNAs).

1.1 DEMANDA DE ENERGIA

A Resolução 414 da ANEEL, traz o seguinte conceito: “Demanda é a média das potências elétricas ativas ou reativas, solicitadas ao sistema elétrico pela parcela da carga instalada em operação na unidade consumidora, durante um intervalo de tempo especificado” (BRASIL, 2010). Esse intervalo de tempo (ou período de integração) corresponde no Brasil a 15 minutos.

O faturamento do consumo de energia elétrica pode ser determinado em três casos distintos, e, a estes, aplicado formas diferentes de cobrança:

- Demanda registrada inferior à demanda contratada: aplica-se a tarifa de consumo e demanda correspondente ao valor contratado;
- Demanda registrada superior à demanda contratada, mas dentro da tolerância de ultrapassagem: aplica-se

a tarifa de consumo e de demanda correspondente à demanda registrada;

- Demanda registrada superior à demanda contratada e acima da tolerância: aplica-se a tarifa consumo e de demanda correspondente à demanda contratada, e soma-se a isto a aplicação da tarifa de ultrapassagem, correspondente à diferença entre a demanda registrada e a demanda contratada. Ou seja, paga-se tarifa normal pelo contratado e tarifa de ultrapassagem sobre todo o excedente.

A tarifa de ultrapassagem geralmente tem um valor bem elevado em relação à tarifa contratada, causando prejuízos financeiros ao consumidor. A ultrapassagem de demanda contratada deve ser evitada pelo consumidor que deve tomar medidas próprias para minimizá-la.

1.2 CONTROLADOR DE DEMANDA

Uma vez identificada a necessidade do controle de demanda, a Universidade adquiriu um controlador de demanda GDR4000 da empresa EMBRASUL, para sanar o problema do sistema de energia elétrica da UFLA.

O Controlador de demanda é um equipamento eletrônico que tem como função principal manter a demanda de energia ativa de uma unidade consumidora, dentro de valores limites pré-determinados, atuando, se necessário, sobre alguns dos equipamentos (cargas) da instalação e operando segundo as regras de faturamento vigentes.

A Figura 1 mostra o controlador de demanda adotado pela Universidade.

Figura 1 - Controlador de Demanda



Fonte - Próprio autor.

O GDE4000 é fornecido sempre com um software de parametrização SPG4000, o qual permite programar uma enorme gama de funções, dentre as quais se destacam o controle de carga. O GDE4000 permite o controle de até 120 cargas acionadas localmente pelas saídas do controlador (8 saídas) ou pelas remotas na rede de comunicação. As remotas podem estar conectadas em qualquer uma das interfaces de comunicação que podem ser usadas simultaneamente se desejado. O controlador atua sobre as cargas respeitando um sistema de prioridades e sua potência, podendo ainda verificar o estado atual da mesma, por meio das entradas digitais, ligadas ou desligadas.

O controlador em questão é dividido em três partes:

- a) Sistema de Gestão de Energia (POWER4000 STANDARD/SERVER);
- b) Unidade Central de Controle (GDR4000);
- c) Unidades Remotas (RTA4000).

A demanda de energia elétrica medida é passada a Unidade Central de Controle (GDR4000), que interligada ao Sistema de Gestão de Energia (POWER4000 STANDARD/SERVER), determina a ação a ser efetuada. Essa ação é realizada pelas Unidades Remotas (RTA4000).

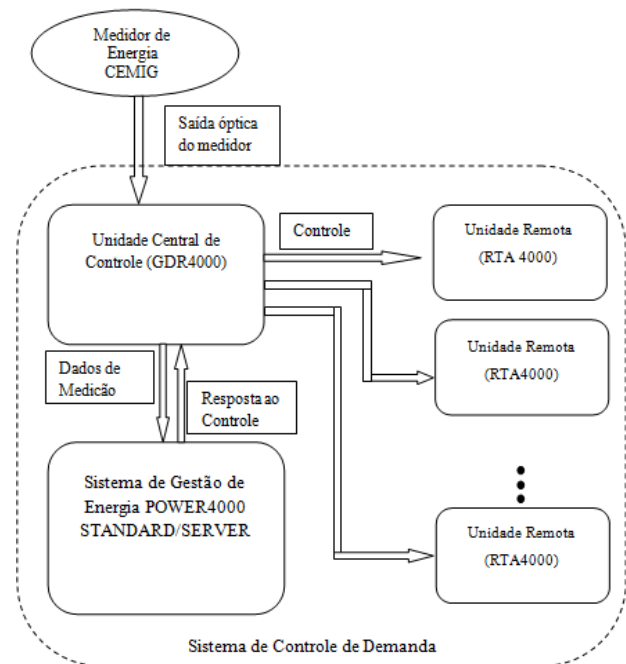
O funcionamento do controlador de demanda, demonstrado na Figura 2, retrata que o valor da demanda de energia elétrica medida pela CEMIG (Medidor de Energia Elétrica), por meio de sua saída

óptica é passado à Unidade Central de controle (GDR4000) que, por sua vez, repassa ao Sistema de Gestão de Energia (POWER4000 STANDARD/SERVER), que faz um comparativo com a Demanda Contratada (Contrato UFLA/CEMIG).

Caso essa demanda seja de valor igual ou maior ao especificado, o sistema passa à Unidade Central de Controle (GDR4000) a resposta que se deve atuar. O GDR4000, recebendo a resposta de atuação irá, por sua vez, emitir o sinal de qual saída da Unidade Remota (RTA - ou das RTAs dependendo da implantação) deve ser desligada. As remotas podem estar conectadas em qualquer uma das interfaces, pois possui uma ampla cobertura de comunicação de dados por quatro enlaces diferentes: Porta serial, RS485, Ethernet, WI FI ou 3G.

O controlador atua sobre as cargas respeitando um sistema de prioridades previamente definido e sua potência, podendo verificar o estado atual da mesma, por meio das entradas digitais, ligadas ou desligadas, otimizando o controle.

Figura 2 - Diagrama de blocos do controlador de demanda



Fonte - Próprio autor.

1.3 Redes Neurais Artificiais (RNAs)

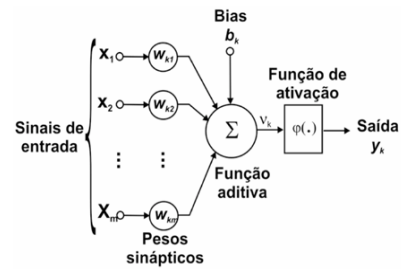
A Inteligência Computacional objetiva buscar por meio de técnicas inspiradas na natureza, o desenvolvimento de sistemas inteligentes computacionais que apresentem modelos matemáticos que visem a solução de problemas existentes. O conceito primordial é que as RNAs sejam capazes de aprender e tomar decisões baseadas na aprendizagem, adquirindo conhecimento por meio da experiência, ou seja, aprendendo, errando e fazendo novas descobertas a cada vez que a elas é apresentado um problema.

Assim como o sistema nervoso humano é composto por vários neurônios biológicos, a Rede Neural Artificial (RNA) é também formada por unidades que nada mais são que pequenos módulos que venham a simular o funcionamento de um neurônio (ALECRIM, 2004). Esses módulos devem funcionar de acordo com os elementos em que foram inspirados, recebendo e retransmitindo informações (HAYKIN, 2001).

Na Figura 3, ilustra-se um modelo de neurônio utilizado em Redes Neurais Artificiais, demonstrando, sinais de entradas, pesos sinápticos, junção somadoras, função de ativação, bias e, por fim, a saída.

O funcionamento básico do neurônio artificial consiste no somatório de cada entrada (x_1, x_2, \dots, x_n) multiplicado pelo peso associado (w_1, w_2, \dots, w_n), além de uma entrada sempre com valor +1 (bias), produzindo um nível de atividade. O resultado passa por uma função de ativação ($\varphi(u_k)$), que é disparada produzindo uma resposta de saída (y), que é submetida aos nós da camada seguinte. O resultado consiste em um valor numérico a ser interpretado pelo programador.

Figura 3 - Modelo de um neurônio usado em Redes Neurais Artificiais



Fonte - Próprio autor.

As redes neurais são tipicamente organizadas em camadas que definem sua estrutura topológica ou sua arquitetura (maneira como os elementos de processamento são organizados). Haykin (2001), explica que existem redes neurais de camada simples (Perceptron) constituídas por um grupo de neurônios arranjados em apenas uma camada, e as redes *multilayerperceptron (feedforward)*, formadas por várias camadas intermediárias ou pela combinação de várias redes de camadas simples.

Observa-se que uma das características mais importantes das RNAs é a sua capacidade de aprendizado por meio de exemplos. Pode-se observar que o conhecimento é adquirido, por meio do ajuste das intensidades das conexões entre os neurônios (BRAGA; CARVALHO; LUDERMIR, 2007).

Essa etapa pode ser considerada como uma adaptação da RNA às diferentes características de um problema. Por sua vez, a generalização de uma RNA está associada à sua capacidade de dar respostas coerentes para dados não apresentados a ela durante o treinamento. Espera-se que uma RNA treinada tenha uma boa capacidade de generalização, independentemente de ter sido controlada durante o treinamento.

O aprendizado supervisionado se aplica a problemas em que se deseja obter um mapeamento entre padrões de entrada e saída (BRAGA; CARVALHO; LUDERMIR, 2007).

O objetivo do algoritmo de treinamento é minimizar o erro médio quadrático (EMQ) entre a saída da rede e a saída desejada. A soma dos erros quadráticos para um determinado padrão i é dada pela Equação 1.

$$E = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (d_i - y_i)^2 \tag{1}$$

Na qual:

e_i - erro da amostra de entrada i

d_i - valor desejado para um padrão de entrada i

y_i - valor obtido para um padrão de entrada i

As redes *feedforward* usam o treinamento supervisionado realizado por um algoritmo chamado *errorbackpropagation* (retro-propagação de erro). Esse algoritmo, derivado da Regra Delta Generalizada (HAYKIN, 2001), permite um ajuste de pesos em cada uma das camadas da rede e é projetado para minimizar a soma do erro médio quadrático entre a saída calculada por uma arquitetura de múltiplas camadas e a saída desejada.

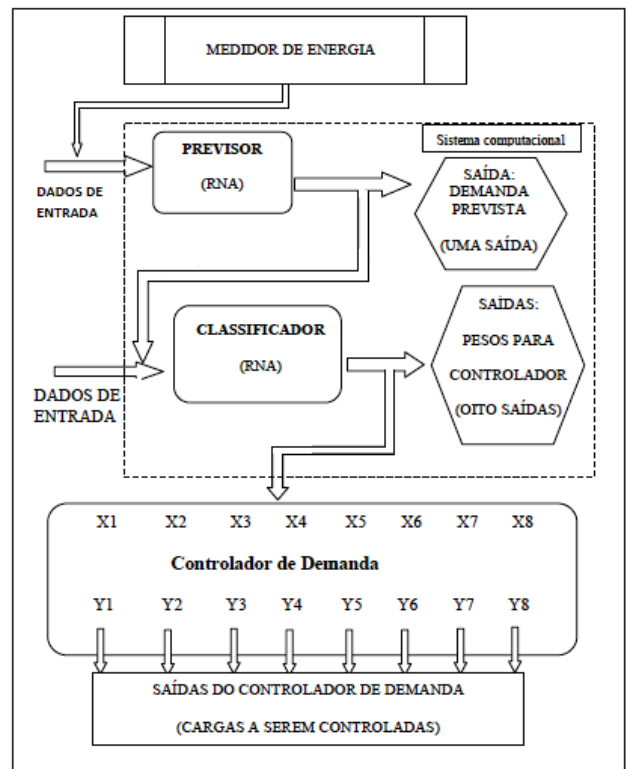
2 METODOLOGIA

Neste trabalho, propõe-se um sistema computacional para controle inteligente de demanda de carga com capacidade de previsão da demanda de energia elétrica, em um intervalo de 15 em 15 minutos, definindo de forma automática a prioridade das cargas a serem desligadas pelo controlador de demanda. Para implementar o sistema, dividiu-se o trabalho em duas partes: a primeira denominada de “sistema de previsão de carga” e a segunda de “sistema de classificação de cargas”, ambas baseadas em Redes Neurais Artificiais (RNA). O sistema foi implementado em um computador tipo PC com processador Intel Core i5 5200U de 2,2 GHz, Memória Cachê de 3 MB, Sistema Operacional Linux, HD com 1TB e Memória RAM de 6GB, utilizando linguagem de programação

Python (pyscience-brasil). Uma vez implementado o sistema computacional, este foi interligado a um controlador de demanda na forma de teste para o controle das cargas elétricas. Na Figura 4, apresenta-se em diagrama em blocos a estrutura completa do sistema proposto.

O sistema de previsão de carga tem como objetivo verificar a demanda futura (próximos 15 minutos), que a Universidade solicitará do sistema energético fornecido pela concessionária (CEMIG), baseado no histórico de demanda dos últimos anos e sempre sendo atualizado com as medições atuais. Os valores obtidos através da saída óptica do medidor e acrescentando outras variáveis, formam as entradas do previsor. Caso essa solicitação resultante do sistema previsor seja maior que a contratada no momento, o sistema de classificação de prioridades de cargas deverá entrar em operação para classificar as cargas que representem menor prioridade para o funcionamento da Universidade.

Figura 4 - Diagrama de blocos do sistema proposto



Fonte - Próprio autor.

O sistema de classificação de prioridades fazendo o uso de suas entradas, juntamente com a situação de cada carga no momento e através da rede neural implementada a ele, fornecerá oito saídas, que por sua vez, servirão como valor de peso a entrada do controlador de demanda (todos esse sistemas e valores resultantes estão dentro do mesmo computador juntamente com o sistema de gestão do controlador de demanda). O controlador de demanda observa os valores de peso a ele incrementados, realizando a função de desligamento às cargas mais adequadas naquele momento.

Depois dos valores implementados à rede neural de previsão e classificação, o resultado obtido deve satisfazer as necessidades da universidade. Assim, o sistema completo é capaz de controlar, de forma automática e inteligente, as funções de desligamento de cargas quando ultrapassada a demanda contratada.

Para validar o sistema computacional implementado, modelos estatísticos foram utilizados como forma de comprovação numérica dos resultados. Os modelos utilizados neste trabalho foram: Erro médio quadrático (EMQ); Coeficiente de determinação (R^2); Matriz de confusão; Índice Kappa e comparativos gráficos.

2.1 DADOS DE ENTRADA

O medidor de energia elétrica encontra-se instalado em um dos prédios da Universidade e através de sua saída óptica é obtida a demanda de energia a cada 15 minutos. Essa, por sua vez, é coletada pelo sistema computacional do controlador de demanda e armazenada em um banco de dados para uso futuro.

Para criação do banco de dados foram coletados valores da demanda solicitada pelas cargas instaladas na Universidade Federal de Lavras, durante alguns meses (Tabela 1). Os mesmos foram coletados de 15 em 15 minutos, por meio de relatórios emitidos pela

Companhia Energética de Minas Gerais (CEMIG, 2016), e fornecido pelo gestor do sistema da universidade.

Tabela 1 - Período de coletas dos dados

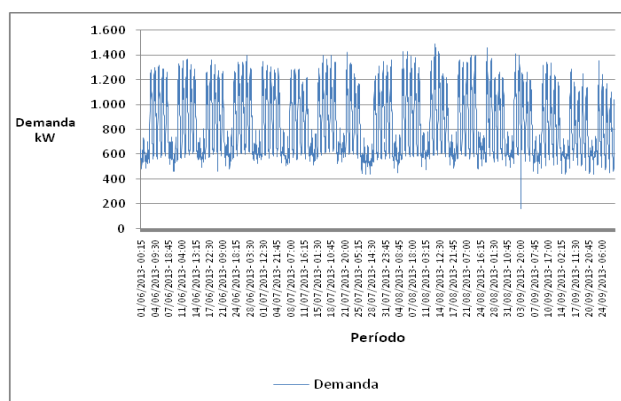
Ano	Meses
2012	Março e Abril
2013	Março, Junho, Julho, Agosto e Setembro
2015	Julho, Agosto e Setembro

Fonte - Próprio autor.

Em uma avaliação prévia, foi possível observar que a demanda de energia elétrica coletada mantém um padrão de comportamento. Ocorre uma variação de consumo no decorrer dos meses, ou seja, mês a mês, e também dentro de um só mês, como demonstrado na Figura 5.

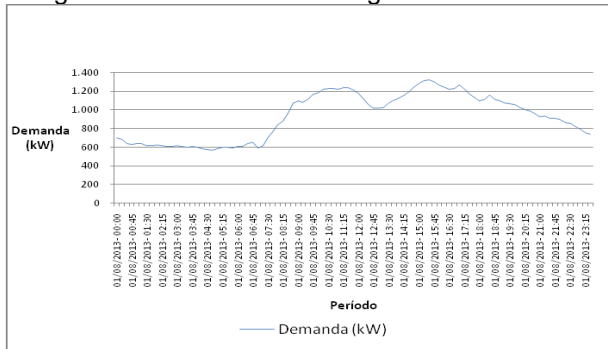
Em observância a essas tendências de repetibilidade e crescimento, fez-se o uso dos anos e meses como variáveis de entrada para a rede neural. Foi observada uma variação da demanda no decorrer dos dias da semana, e também em um mesmo dia. Há também uma variação com o horário, como pode ser observado na Figura 6. Cabe ressaltar que a demanda no horário de ponta contratado pela universidade é de 1200kW e no horário fora de ponta é de 1900kW.

Figura 5 - Demanda de energia durante os meses



Fonte - Próprio autor.

Figura 6 - Demanda de energia durante um dia



Fonte - Próprio autor.

As variáveis “dias da semana” e “horário” também compuseram as entradas da rede neural para fins de previsão e classificação de carga.

Alguns outros fatores como “temperatura” e “umidade relativa do ar” podem também influenciar a oscilação da demanda. Sabendo-se que mais de 1/3 das cargas instaladas na Universidade são aparelhos de ar condicionado e a utilização dos mesmos se torna maior com o aumento da temperatura e da umidade relativa do ar, as variáveis “temperatura” e “umidade relativa do ar” também fizeram parte das variáveis de entrada do sistema de previsão com redes neurais.

De posse das variáveis acima citadas, foi montado um banco de dados conforme pode ser observado na Tabela 2.

Tabela 2 - Dados de entrada do sistema previsor

Anos	2012	2013	2014	2015	2016
Meses	Janeiro	Fevereiro	Março	...	Dezembro
Dia do	1	2	3	...	31
Mês					
Horas	0	1	2	...	24
Minutos	0	15	30	45	
Dia da	Domingo	Segunda	Terça	...	Sábado
Semana		Feira	Feira		
Temperatura	00 horas	12 horas	18 horas		
Umidade Relativa do Ar	00 horas	12 horas	18 horas		
Demanda	60 minutos	45 minutos	30 minutos	15 minutos	
Anteriores					

Fonte - Próprio autor.

Sendo assim, formou-se o vetor de dados de entrada para o sistema computacional definido como:

$V_n = \text{ano, mês, dia, horas, minuto, dia da semana, temperatura, unidade reativa do ar, demanda (d-60, d-45, d-30, d-15)}$.

RNAs trabalham com valores numéricos. Sendo assim, as variáveis como ano, mês, dia, hora, minuto e dia da semana foram expostas utilizando sistema binário. Tomando como exemplo o ano, quando o dado se refere ao ano de 2015, esse recebe o valor um e os demais anos valores zero. As demais variáveis (temperatura, umidade relativa do ar e demanda de energia elétrica) foram utilizadas com valores numéricos, os quais foram normalizados aplicando a divisão pelo maior valor da variável. Dessa forma, formaram-se as 93 entradas para a rede neural de previsão.

Do conjunto total de dados, 70% foram utilizados para treinamento do sistema de previsão e 30% foram utilizados para teste.

Para o classificador de prioridades de cargas, foram coletados 20480 dados de entradas. Desse modo, foi montado um banco de dados respeitando as cargas a serem ligadas e desligadas pelo controlador de demanda.

Sabe-se que as cargas a serem ligadas ao controlador de demanda da UFLA são exclusivamente para aparelhos de ar condicionado e que os mesmos se encontram espalhados em diversos setores da Instituição. Muitas variáveis foram verificadas, e, a cada uma das variáveis, foi inserido um valor a ser utilizado como peso. A primeira variável foi o local onde se encontra o ar condicionado: laboratório, sala de aula, sala de professores, secretaria e outras. Cada local recebe um peso de acordo com sua importância para o funcionamento de Universidade. Vale ressaltar que quanto maior o peso menor a sua influência.

A segunda variável verifica o sol. Assim, quanto maior a incidência de sol no local, maior a necessidade do uso do ar condicionado.

A terceira variável é a potência dos aparelhos de ar condicionado, a qual foi definida em três situações: alta, média e baixa.

A quarta variável levou em consideração o momento do último desligamento, fazendo que assim não haja repetitividade de cargas a serem desligadas.

A quinta e última variável leva em conta qual a situação da carga no momento de um possível desligamento: desligada ou ligada.

Todas as variáveis e seus respectivos pesos encontram-se na Tabela 3.

Tabela 3 - Variáveis de entrada do classificador e seus respectivos pesos

Local	Peso
Laboratório	0,25
Sala de aula	0,35
Sala de professores	0,50
Secretaria	0,50
Outras	0,50

Sol	Peso
Sol o dia todo	0,25
Sol da tarde	0,35
Sol da manhã	0,50

Potência	Peso
Alta	0,50
Médio	0,35
Baixa	0,25

Dia(s)	Peso
Mesmo dia	0,00
1 dia atrás	0,15

2 dias atrás	0,25
3 dias atrás	0,35
4 dias atrás	0,45
Mais de 4 dias	0,55

Condição de Carga	Peso
Ligada	1
Desligada	0

Fonte - Próprio autor.

Para formar o sistema de teste utilizou-se o sistema implantado atualmente na Universidade, e para se formar as variáveis de entrada utilizaram-se os pesos dos dados coletados seguindo a Tabela 3. A saída do classificador formou-se em 8 valores que foram incrementados na entrada do controlador de demanda. O controlador atua sobre as cargas respeitando um sistema de prioridades e sua potência, podendo, ainda, verificar o estado atual da mesma, por meio das entradas digitais, ligadas ou desligadas, otimizando o controle.

É nesse ponto que se faz o uso da classificação de prioridades das cargas, visto que, o controlador aceita a entrada de pesos para cada carga e respeita esse para atuar no desligamento.

2.2 PREVISOR DE CARGA

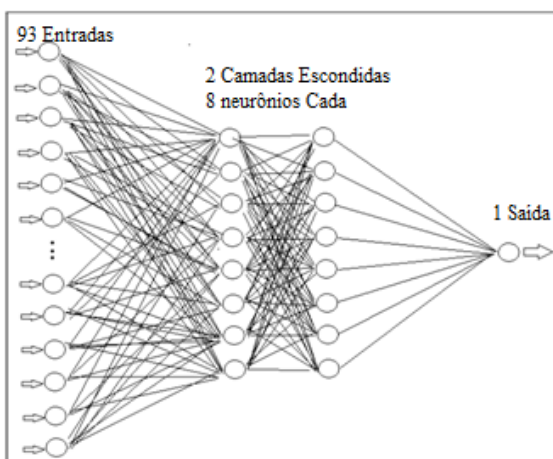
Em análise de demanda de energia elétrica, a previsão é fundamental para a tomada de decisões, e a utilização das RNAs poderá trazer significativa contribuição nessa atividade assim como exposto em vários estudos como, por exemplo, em Villamagna (2013). Nesse sentido, um sistema de previsão de energia foi implantado, utilizando uma RNA treinada com os dados históricos das demandas de energia. Dessa forma, o previsor tem como função a previsão da demanda nos próximos 15 minutos que será

utilizada como informação para o sistema de classificação de prioridade de cargas.

A RNA para previsão foi instalada utilizando linguagem Python em um computador tipo PC. Os parâmetros utilizados para implementação e treinamento da RNA são os seguintes: Dados normalizados; Aprendizado Supervisionado; Redes de múltiplas camadas; Algoritmo de Retropropagação (backpropagation); 93 entradas na 1ª camada; Duas camadas escondidas com 8 neurônios em cada; Uma saída na última camada; Função de ativação sigmóide; Taxa de aprendizagem = 0,1; Taxa de momento = 0,5; Épocas de treinamento = 2000.

A normalização dos dados é feita matematicamente efetuando-se a divisão dos valores das variáveis, pelo maior valor encontrado dentro da mesma. Quanto ao critério de parada da rede, utilizaram-se das 2000 épocas de treinamento ou quando o valor do EMQ atinge zero. Na Figura 7, apresenta-se a topologia da Rede Neural Artificial utilizada como previsor de carga.

Figura 7 - Rede neural de previsão



Fonte - Próprio autor.

O resultado de saída da RNA é a previsão de demanda de energia elétrica para os próximos 15 minutos. Os dados de entrada para treinamento e testes foram apresentados à rede neural de forma

aleatória. Sendo assim, todas as vezes que a rede neural é colocada para treinamento e teste utiliza-se um conjunto de dados diferentes. Partindo-se desse raciocínio, a rede foi treinada e testada por 10 vezes. Dessa maneira, obtiveram-se os 10 valores do erro médio quadrático e também o valor do coeficiente de determinação (R^2) para fase de treinamento e teste durante 10 vezes.

2.3 CLASSIFICADOR DE CARGAS

O GDE4000 é fornecido sempre com um software de parametrização SPG4000, o qual permite programar uma enorme gama de funções, dentre as quais se destacam o controle de carga. O GDE4000 permite o controle de até 120 cargas acionadas localmente pelas saídas do controlador (8 saídas) ou pelas remotas na rede de comunicação. As remotas podem estar conectadas em qualquer uma das interfaces de comunicação que, por sua vez, podem ser usadas simultaneamente se desejado.

O classificador de prioridades das cargas determina, por meio de uma RNA treinada, a prioridade de desligamento das cargas por meio do ajuste dos pesos de cada carga. Objetiva-se obter o valor dos pesos ajustados continuamente de forma automática pelo sistema que está sendo proposto. Caso contrário, o controlador de demanda atuará sempre nas mesmas cargas, desligando-as para evitar a ultrapassagem da demanda.

De posse da previsão da demanda de carga, inicia-se uma classificação de cargas (módulo classificador), por meio de dados previamente obtidos e também por dados obtidos pelo controlador em tempo real (cargas que estão ligadas ou desligadas no momento). O resultado obtido (pesos das cargas) servirá de entrada para o controlador de demanda. O controlador então desligará as cargas necessárias para não ocorrer a

ultrapassagem da demanda de acordo com a prioridade calculada definida pelo valor dos pesos.

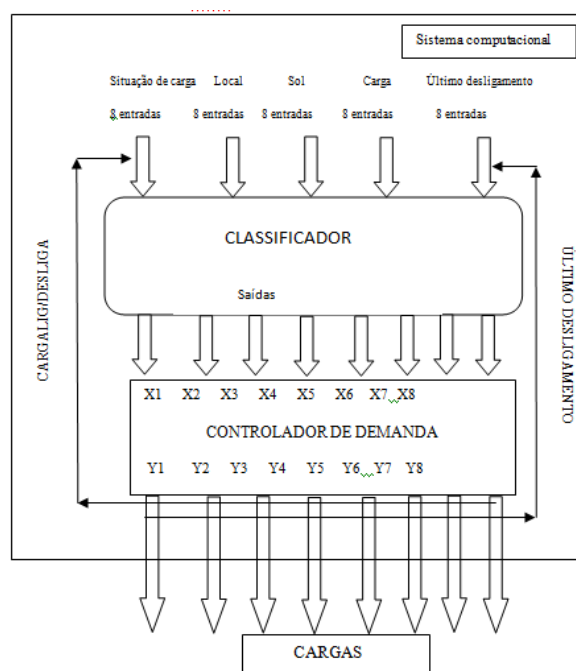
De posse dos valores dos pesos das cargas do controlador, no momento do desligamento, a carga com maior somatória de peso irá se desligar primeiro. A colocação desses valores na entrada do controlador determinará a forma de sua ação no desligamento de cargas.

Como os valores das variáveis podem ser alterados de acordo com o último desligamento e a situação da carga no momento do desligamento também, passa a ser função do sistema computacional mudar os valores das variáveis. Também esse sistema tem a função de fornecer esses novos valores à entrada da rede neural para cada carga e a rede neural calcula novos pesos a serem acrescentados ao controlador de demanda.

2.3.1 IMPLEMENTAÇÃO E TREINAMENTO

Para montar o classificador utilizou-se o especialista que, além de definir valores dos pesos, definiu as variáveis de entrada. Foram utilizadas 5 variáveis e a cada uma das variáveis foram colocados 8 valores que representam cada uma das cargas ligadas ao controlador de demanda. As variáveis: local, potência e sol não se alteram, pois, representam condições fixas das cargas. Já as variáveis último desligamento e condição da carga podem se alterar por várias vezes no decorrer do dia. Sendo assim, esses valores são sempre atualizados na entrada do classificador. Para essa atualização, utiliza-se uma das funções do controlador de demanda que é a informação do último desligamento de cada uma das saídas. Outra característica do controlador, relevante para o processo, é a de fornecer a situação da carga no momento. Todas essas etapas são realizadas através do sistema computacional e podem ser observadas na Figura 8.

Figura 8 - Sistema classificador de cargas



Fonte - Próprio autor.

Para projetar o classificador de cargas utilizou-se também o especialista que, além de definir a ordem de prioridade de desligamento das cargas, definiu também quais as variáveis de entrada necessárias (vide Tabela 2). Um exemplo dos possíveis valores das variáveis de entrada e saída do classificador pode ser observada na Tabela 4.

Tabela 4 - Exemplo das variáveis de entrada do classificador

Local	Sol	Carga	Último Desligamento	Situação	Saída
0,5	0,5	0,5	0	0	1,500
0,5	0,5	0,5	0	0	1,500
0,5	0,5	0,5	0,55	0	2,050
0,5	0,5	0,5	0	1	2,500
0,5	0,5	0,5	0	0	1,500
0,5	0,5	0,5	0	1	2,500
0,5	0,5	0,5	0	0	1,500
0,5	0,5	0,5	0	1	2,500
0,5	0,5	0,5	0	0	1,500
0,5	0,5	0,5	0,55	1	3,050

Fonte - Próprio autor.

Esses valores são sempre atualizados na entrada do classificador. Para essa atualização, utiliza-se uma das funções do controlador de demanda que é a informação do último desligamento de cada uma de

suas saídas e a situação (ligada/desligada) da carga no momento.

Uma RNA para classificação das cargas foi incorporada no mesmo computador PC utilizado para o previsor de carga. Utilizou-se também a linguagem de programação Python, e a rede foi treinada com os seus dados de entrada de forma supervisionada. Os parâmetros utilizados para a implementação da RNA foram: Dados normalizados; Aprendizado Supervisionado; Tipo de Rede Neural com múltiplas camadas; Algoritmo de Retro-propagação (backpropagation); 40 entradas na 1ª camada; Duas camadas escondidas com 8 neurônios em cada; 8 saídas na última camada; Função de ativação sigmóide; Taxa de aprendizagem = 0,1; Taxa de momento = 0,5; Épocas de treinamento = 2000.

A normalização dos dados como no sistema previsor, efetuou-se matematicamente com a divisão dos valores das variáveis pelo maior valor encontrado dentro da mesma. Quanto ao critério de parada da rede, utilizaram-se 2000 épocas de treinamento ou quando o valor do EMQ chegasse à zero.

A rede neural do classificador de cargas fornece 8 respostas para cada amostra de dados de entrada, que consiste no peso de cada carga implementada no controlador de demanda. Assim, os resultados da saída são os pesos de cada carga a ser implementado no controlador de demanda.

2.4 VALIDAÇÃO DO SISTEMA PROPOSTO

Para avaliação do sistema desenvolvido, realizou-se uma análise separada para o previsor de demanda e outra para o classificador de prioridade de cargas. Para o sistema previsor, a rede forneceu um valor da demanda em função de cada conjunto das entradas. Sabendo-se o valor que era esperado, uma análise estatística foi realizada para a comprovação de sua eficiência. As análises estatísticas dos resultados

fornecidos pelo sistema previsor durante os testes para a validação dos resultados obtidos foram as seguintes: erro médio quadrático (EMQ), coeficiente de determinação (R^2) e gráfico comparativo dos resultados obtidos e desejados (PRADO, 2015).

O classificador fornece em sua saída, 8 classes diferentes. Sabendo a sequência das classes que eram esperadas, realizou-se a validação da rede por meio dos números de acertos e erros entre cada uma das sequências de resultados.

3 RESULTADOS E DISCUSSÃO

Os resultados obtidos foram dispostos em duas partes: previsão de série de consumo de energia elétrica da UFLA; classificação de prioridades de cargas ligadas ao controlador de demanda.

3.1 PREVISÃO DA SÉRIE DE CONSUMO

A rede neural da previsão utilizou 26343 amostras de dados para o sistema da previsão, e os mesmos foram separados em 70% para treinamento e 30% para validação da rede. O treinamento durou 14643 segundos (04:04:03h) utilizando as 2000 épocas pré-determinadas. A rede de previsão utilizada era supervisionada, ou seja, para os resultados da previsão havia o valor pretendido. A previsão foi feita para os 15 minutos adiante, e durante a fase de treinamento da rede foi obtido o valor do erro médio quadrático (EMQ) e coeficiente R^2 . Depois de treinada, foram apresentados à rede os valores de teste e verificado o valor do coeficiente de determinação (R^2), sabendo-se que para cada treinamento e teste os 26343 dados eram embaralhados e retirados aleatoriamente. Esse processo foi proposto por 10 vezes. Para os resultados, calcularam-se a média aritmética e o desvio padrão das 10 etapas de treinamento e testes, valores estes apresentados na Tabela 5.

Tabela 5 - Valores EMQ e R² no treinamento e teste

	EMQ Treinamento	EMQ Teste	R ² Treinamento	R ² Teste
	0,000068135	0,000058241	0,9568321	0,9886532
	0,000067542	0,000067142	0,96354201	0,9845674
	0,000064263	0,000063102	0,96385601	0,98872512
	0,000067785	0,000064256	0,964956	0,9856159
	0,000068752	0,000063178	0,9598354	0,98758921
	0,000065823	0,000063457	0,96572	0,989776406
	0,000067566	0,000063443	0,96524511	0,987542
	0,000063592	0,000058692	0,9645231	0,9873242
	0,00006856	0,000063782	0,96572581	0,98678872
	0,000068115	0,000061542	0,96456102	0,986935742
Média aritmética	0,00006701	0,0000627	0,96347966	0,9873518
Desvio padrão	0,00000182	0,0000026272	0,00289127	0,0015205

Fonte - Próprio autor.

Observando os valores do EMQ e o coeficiente R² para treinamento e teste, pode-se afirmar que a rede é robusta ao que tange a previsão de demanda de energia elétrica. O erro tende a zero e valor do R² demonstra o quanto o valor previsto explica o valor desejado. Observando a média aritmética do EMQ de teste o valor do erro é de 0,000627, ou seja, praticamente zero. Os resultados previstos explicam o desejado em 98,7% conforme R². O desvio padrão vem explicar que em todas as vezes que a rede foi submetida a dados novos, os valores eram praticamente os mesmos. A variação do R² não ultrapassa 0,15% do valor médio. Sendo assim, os

valores previstos sempre explicam os valores desejados em 98,7%, com uma variação para mais ou para menos de no máximo 0,15%.

Na Tabela 6, pode ser observada uma parte dos resultados fornecidos pela rede neural, valores da demanda desejada, demanda obtida, diferença da desejada pela obtida em kW e também em porcentagem dessa diferença ao desejado. A maior porcentagem de erro encontrada entre o esperado e obtido foi de 3,8632%, ou seja, valor esse que mesmo que o esperado seja a demanda contratada, não haverá multa na ultrapassagem da demanda, pois a mesma tem uma tolerância de 5%.

Tabela 6 - Saída desejada X Saída Obtida

Demanda Desejada kW	Demanda Obtida kW	Desejada - Obtida kW	Desejada - Obtida %
687,12	680,60	6,52	0,9489
1527,00	1557,03	-30,03	1,9666
915,60	897,68	17,92	1,9572
510,72	520,46	-9,74	1,9071
1120,56	1091,60	28,96	2,5844
922,30	886,67	35,63	3,8632
1394,00	1362,39	31,61	2,2676

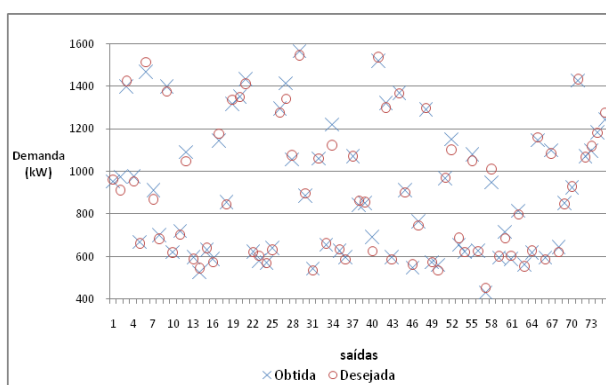
584,64	565,29	19,35	3,3097
1396,00	1412,42	-16,42	1,1762
517,00	516,84	0,16	0,0309
559,44	571,09	-11,65	2,0824
1572,48	1520,97	51,51	3,2757
1253,00	1256,27	-3,27	0,2610
614,88	604,79	10,09	1,6410
1075,20	1083,14	-7,94	0,7385
922,32	933,75	-11,43	1,2393
937,00	922,31	14,69	1,5678
876,96	856,28	20,68	2,3581
559,44	563,81	-4,37	0,7811
962,64	953,63	9,01	0,9360
1421,00	1397,48	23,52	1,6552
954,24	973,36	-19,12	2,0037
658,56	668,94	-10,38	1,5762
1513,68	1465,91	47,77	3,1559
679,00	696,29	-17,29	2,5464

Fonte - Próprio autor.

Em observância da fase de testes do sistema de previsão, pode-se analisar os resultados da demanda prevista em comparação com a demanda desejada (Figura 9).

de energia elétrica futura da Universidade Federal de Lavras (UFLA). A demanda contratada pela universidade é de 1200 kW. Portanto, a diferença entre os valores previstos e obtidos é pequeno em

Figura 9 - Demanda Prevista X Demanda Desejada




Fonte - Próprio autor.

É possível observar que os resultados das demandas previstas são muito próximos aos das demandas desejadas. Os resultados reforçam a comprovação da eficiência da rede neural para a previsão da demanda

comparação ao da demanda contratada, o que pode ser observado no gráfico da Figura 10, reforçando a eficiência do sistema de previsão de demanda por RNAs.

Figura 10 - Diferença Demanda Prevista X Demanda Desejada



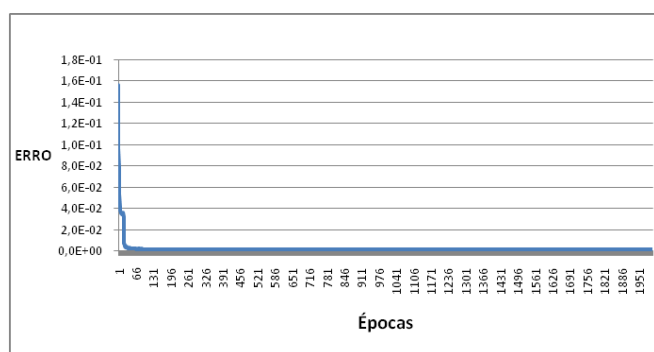
Fonte - Próprio autor.

3.2 CLASSIFICADOR DE CARGAS

Durante a fase de treinamento da rede neural de classificação de cargas, foi obtido o erro médio quadrático (EMQ), durante as 2000 épocas de treinamento. Ao fim do processo de treinamento, o valor obtido do erro médio quadrático foi de 0,001443. O valor baixo do erro obtido indica a convergência do treinamento da rede neural.

A curva do erro (EMQ) durante as épocas de treinamento podem ser observada na Figura 11.

Figura 11 - EMQ durante o treinamento



Fonte - Próprio autor.

Após o processo de treinamento, foram apresentados a rede neural os 30% dos dados que encontravam-se em separado para teste e a ela eram desconhecidos.

Posteriormente, aos valores obtidos na saída da rede neural, observou-se de forma significativa a sequência de resultados obtidos em conformidade com os resultados esperados. Os resultados obtidos e esperados mantiveram a mesma sequência, confirmando assim, um bom funcionamento na rede de classificação.

A validação se fez pela matriz de confusão e o índice Kappa (HUDSON; RAMM, 1987). Congalton, Oderwald e Mead (1983) afirmam que a estatística Kappa pode ser utilizada na avaliação de

classificadores. De acordo com os autores, essa estatística é uma medida do acerto real, exceto o acerto por acaso.

Para que o índice Kappa seja calculado, há a necessidade da construção da matriz de confusão. Para calcular a matriz de confusão:

- 1º passo: Realiza-se um comparativo do resultado obtido com o resultado esperado, para todos os dados da fase de teste. Parte desses resultados é demonstrada na Tabela 7.

- 2º passo: Ocorre a denominação das cargas. As cargas são aparelhos de ar condicionados, assim sendo, usou-se a sigla "AR" e correspondentes numéricos para cada carga em questão, colocados em ordem decrescente de acordo com os valores obtidos e esperados, como apontados na Tabela 8.

- 3º passo: Realiza-se um comparativo entre os resultados esperados e os obtidos pela rede neural de classificação. Esse comparativo foi efetuado carga a carga, e todas as vezes que o resultado foi igual colocou-se uma resposta "Verdadeiro", e quando diferente "Falso".

- 4º passo: Utiliza-se o sistema binário para a classificação dos acertos e erros do sistema. Cada acerto é representado pelo valor numérico "1" e cada erro, representado pelo valor numérico "0", em cada uma das linhas de carga. Ao resultado final de cada linha de carga, incorpora-se o valor numérico "1" quando não encontrado nenhum erro na mesma linha. O valor numérico "0" foi usado quando percebe-se ao menos um erro na sequência da linha.

Tabela 7 - Saída desejada X Saída Obtida do classificador

Obtido								Esperado							
Carga 1	Carga 2	Carga 3	Carga 4	Carga 5	Carga 6	Carga 7	Carga 8	Carga 1	Carga 2	Carga 3	Carga 4	Carga 5	Carga 6	Carga 7	Carga 8
2,694	2,484	1,06	2,002	1,347	2,496	1,239	0,605	2,65	2,1	1	2,1	2	2,2	1,1	0,95
2,642	2,352	0,87	1,381	2,631	1,339	1,154	1,652	2,85	2,3	0,95	1,1	2,4	1	0,95	2,2
1,526	1,223	1,992	1,672	1,628	2,052	1,797	0,857	1,5	1,05	2,4	1,95	1,85	2,45	2,1	0,95
1,932	1,594	1,227	1,808	1,672	2,339	2,212	1,223	2,5	1,5	1,1	2,5	2,4	2,6	2,55	0,95
2,691	1,304	2,259	1,205	1,428	2,415	1,388	1,575	2,85	1	2,4	0,95	1,85	2,4	1,1	1,95
1,672	2,055	2,193	1,178	1,718	2,213	1,668	1,957	2,4	2,35	1,5	0,95	2,2	2,45	0,95	2,3
3,091	1,184	1,293	1,995	1,96	0,742	0,97	1,68	3,05	0,95	1,05	2,55	2,4	0,95	0,95	2,35
2,153	1,964	1,613	2,247	1,521	1,207	1,481	1,624	2,2	2	1	2,25	0,95	0,95	0,95	1,5
1,808	1,037	2,096	1,292	1,294	1,891	1,723	1,616	1,5	0,85	2,2	2,1	0,95	0,95	1,1	1
1,809	1,291	1,058	1,616	2,287	1,715	0,899	1,523	2,55	1,05	0,95	2,5	2,65	2,5	0,85	1,5
0,845	1,627	1,336	1,905	1,888	1,869	1,435	1,73	0,95	1	1,1	2,5	2,5	2,4	1,05	1,5
2,306	2,045	1,255	1,565	1,816	2,133	1,804	1,595	3,05	2,5	2,25	2,4	2,5	2,6	2,5	2,45
2,141	1,932	0,917	1,064	1,478	1,737	1,132	1,248	2,05	1,25	0,85	1	1,1	1,2	1,05	1,1
1,957	0,851	1,555	2,05	1,296	1,248	1,884	1,519	2,4	0,85	1,5	2,45	1,4	1,05	1,95	1,45
1,079	1,406	0,867	2,085	2,01	1,804	1,309	1,343	1	1,5	0,85	2,5	1,95	1,5	1,05	1,25
2,094	1,953	2,058	1,119	1,431	2,193	1,439	1,634	2,4	1,95	2,4	0,85	1	2,45	1,5	1,95
1,523	1,929	1,898	1,697	1,935	1,783	1,451	1,48	1,2	2,1	2,05	1,5	2,25	1,85	0,95	0,95
1,767	1,809	2,16	1,543	1,764	2,242	1,157	1,403	2	2,1	2,3	1,5	1,85	2,4	0,95	1,4
1,023	1,223	2,155	1,55	1,548	2,199	2,05	1,697	0,95	1,05	2,5	2,25	1,5	2,5	2,45	2,4

Fonte - Próprio autor.

Tabela 8 - Sequência desejada X Saída Obtida do classificador

Sequência Esperada								Sequência Obtida							
1ª	2ª	3ª	4ª	5ª	6ª	7ª	8ª	1ª	2ª	3ª	4ª	5ª	6ª	7ª	8ª
AR1	AR6	AR2	AR4	AR5	AR7	AR3	AR8	AR1	AR6	AR2	AR4	AR5	AR7	AR3	AR8
AR1	AR5	AR2	AR8	AR4	AR6	AR7	AR3	AR1	AR5	AR2	AR8	AR4	AR6	AR7	AR3
AR6	AR3	AR7	AR4	AR5	AR1	AR2	AR8	AR6	AR3	AR7	AR4	AR5	AR1	AR2	AR8
AR6	AR7	AR1	AR4	AR5	AR2	AR3	AR8	AR6	AR7	AR1	AR4	AR5	AR2	AR3	AR8
AR1	AR6	AR3	AR8	AR5	AR7	AR2	AR4	AR1	AR6	AR3	AR8	AR5	AR7	AR2	AR4
AR6	AR3	AR2	AR8	AR5	AR1	AR7	AR4	AR6	AR1	AR2	AR8	AR5	AR3	AR7	AR4
AR1	AR4	AR5	AR8	AR3	AR2	AR7	AR6	AR1	AR4	AR5	AR8	AR3	AR2	AR7	AR6
AR4	AR1	AR2	AR8	AR3	AR5	AR7	AR6	AR4	AR1	AR2	AR8	AR3	AR5	AR7	AR6
AR3	AR6	AR1	AR7	AR8	AR5	AR4	AR2	AR3	AR4	AR1	AR7	AR8	AR5	AR6	AR2
AR5	AR1	AR6	AR4	AR8	AR2	AR3	AR7	AR5	AR1	AR6	AR4	AR8	AR2	AR3	AR7
AR4	AR5	AR6	AR8	AR2	AR7	AR3	AR1	AR4	AR5	AR6	AR8	AR3	AR7	AR2	AR1
AR1	AR6	AR2	AR5	AR7	AR8	AR4	AR3	AR1	AR6	AR2	AR5	AR7	AR8	AR4	AR3
AR1	AR2	AR6	AR5	AR8	AR7	AR4	AR3	AR1	AR2	AR6	AR5	AR8	AR7	AR4	AR3
AR4	AR1	AR7	AR3	AR8	AR5	AR6	AR2	AR4	AR1	AR7	AR3	AR8	AR5	AR6	AR2
AR6	AR7	AR4	AR3	AR8	AR1	AR5	AR2	AR6	AR7	AR4	AR3	AR8	AR1	AR5	AR2
AR3	AR7	AR6	AR5	AR2	AR8	AR1	AR4	AR3	AR7	AR6	AR5	AR2	AR8	AR1	AR4
AR1	AR5	AR2	AR7	AR8	AR3	AR6	AR4	AR1	AR5	AR2	AR7	AR8	AR3	AR6	AR4

Fonte - Próprio autor.

Percorridos os quatro passos mencionados, de forma eficiente e precisa, obtiveram-se condições favoráveis para a montagem da matriz de confusão. Desse processo, originaram-se duas tabelas, sendo a primeira a matriz de confusão.

A matriz de confusão foi obtida por meio da soma dos acertos e erros de cada uma das cargas. Na diagonal da matriz, visualiza-se os acertos para cada uma das cargas e nas demais células totaliza-se os erros para cada uma das cargas referentes, de acordo com a Tabela 9.

Tabela 9 - Matriz de confusão para cada carga

Cargas	AR1	AR2	AR3	AR4	AR5	AR6	AR7	AR8
AR1	467	11	6	11	6	7	5	7
AR2	8	461	5	9	6	7	7	5
AR3	5	8	457	3	11	6	5	5
AR4	12	9	7	454	7	8	3	4
AR5	5	13	12	7	460	8	6	4
AR6	7	6	7	8	9	463	8	7
AR7	2	4	9	7	9	6	467	5
AR8	7	1	10	14	5	8	9	476
Total	513	513	513	513	513	513	513	513

Fonte - Próprio autor.

Posteriormente, a Tabela 10 mostra acertos e erros da sequência total, com a finalidade de calcular o índice Kappa de forma geral. Foram observados 436 acertos e 77 erros, totalizando 513 dados.

Tabela 10 - Total dos Acertos e Erros para todos os testes

Acertos	Erros	Total
436	77	513

Fonte - Próprio autor.

Empregando os dados da matriz denominada "carga a carga" e aplicando o cálculo do índice Kappa, obteve-se o valor 0,889. Assim, o índice Kappa indicou que houve 89% de concordância não aleatória entre os valores esperados e obtidos do classificador de prioridades.

Na observância do acerto da sequência total, ou seja, se a sequência obtida é a mesma da sequência esperada, utilizou-se o cálculo do coeficiente Kappa novamente. Assim sendo, calcula-se o índice Kappa geral e obtém-se o valor 0,823, ou seja, 82,3% de concordância. Valores que podem ser observados na Tabela 11.

Tabela 11 - Índice Kappa

Kappa/Análise	Kappa	Kappa %
Carga/carga	0,88889	89%
Geral	0,82339	82%

Fonte - Próprio autor.

Equiparando-se os resultados obtidos pelo cálculo do índice Kappa com a Tabela 12 de concordância do mesmo, constata-se que os valores se situam dentro da faixa 0,81 a 1. Portanto, de acordo com o referencial de concordância do índice Kappa, o valor é excelente.

Tabela 12 - Escala de concordância do Kappa

Valor de Kappa	Concordância
0	Pobre
0 - 0,20	Ligeira
0,21 - 0,40	Considerável
0,41 - 0,60	Moderada
0,61 - 0,80	Substancial
0,81 - 1	Excelente

Fonte - Próprio autor.

4 CONCLUSÃO

Com a realização deste trabalho e de acordo com as condições experimentais utilizadas e resultados obtidos em ambiente de simulação, é possível concluir que a utilização de RNA no sistema de previsão é robusta ao que tange a previsão de demanda de energia elétrica. O mesmo afirma-se do sistema de

classificação das prioridades de carga aplicado ao controlador de demanda, no que diz respeito a função de desligamento de cargas do controlador.

Através dos índices de validação utilizados e os resultados obtidos, afirma-se que o sistema pode ser inserido ao setor energético de abastecimento da

Universidade com finalidade fundamental de melhoria do controlador de demanda, possibilitando assim sua melhora no desempenho, e assim buscar a otimização do consumo de energia elétrica na Universidade Federal de Lavras.

REFERÊNCIAS

ALECRIM, E. Redes Neurais Artificiais. **Infowester**, São Paulo, v. 1, n. 1, p. 1, maio 2004. Disponível em: <<http://www.infowester.com/redesneurais.php>>. Acesso em: ago. 2016.

ANDRADE, L. C. M. **Abordagem Neurofuzzy para previsão de demanda de energia no curtíssimo prazo**. São Paulo, 2010. Catálogo – Universidade de São Paulo.

BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDERMIR, T. B. 2007. **Redes neurais artificiais: teoria e aplicações**. 2 ed. Rio de Janeiro: LTC. 226 p.

BRASIL. Agência Nacional de Energia Elétrica. **Capacidade de Geração do Brasil**. Brasília, DF, 2017. Disponível em: <<http://www2.aneel.gov.br/aplicacoes/capacidadebrasil/capacidadebrasil.cfm>>. Acesso em: 11 out. 2017.

BRASIL. Agência Nacional de Energia Elétrica. **Resolução Normativa nº 414**, de 9 de setembro de 2010. Estabelece as Condições Gerais de Fornecimento de Energia Elétrica de forma atualizada e consolidada. Brasília, DF, 2010. Disponível em: <<http://www2.aneel.gov.br/cedoc/bren2010414.pdf>>. Acesso em: 10 mar. 2016.

CEMIG - COMPANHIA ENERGÉTICA DE MINAS GERAIS. **Estrutura Tarifária**: Minas Gerais, 2016. Disponível em: <<http://cemig.com.br/atendimento/paginas/valoresdetarifaservicos>>. Acesso em: 25 ago. 2016.

CONGALTON, R. G.; ODERWALD, R. O.; MEAD, R. A. Assessing land sat classification accuracy using discrete multivariate analysis statistical techniques. **Photogrammetric Engineering and Remote Sensing**, v. 49, n. 12, p. 1671-1678, 1983.

HAYKIN, S. **Redes Neurais princípios e práticas**. Porto Alegre: Bookman, 2001. 898 p.

HUDSON, W. D.; RAMM, C. W. Correct formulation of the Kappa coefficient of agreement. **Photogrammetric Engineering and Remote Sensing**, v. 53, n. 4, p. 421-422, 1987.

OLIVEIRA, E. L. **Previsão de demanda de energia elétrica com redes neurais artificiais e análise por série de Fourier**. 2011. 84 f. Dissertação (Mestrado em Estatística) – Universidade Federal de Minas Gerais, BH, 2016.

PRADO, J. R. **Métodos Estatísticos no Monitoramento da Potencia Elétrica**. 2015. 159 f. Tese (Doutorado em Estatística e Experimentação Agropecuária) – Universidade Federal de Lavras, Lavras, 2015.

VILLAMAGNA, M. R. **Seleção de Modelos de Séries Temporais e Redes Neurais Artificiais na Previsão de Consumo e Demanda de Energia Elétrica**. 2013. 74 f. Dissertação (Mestrado em Estatística e Experimentação Agropecuária). Universidade Federal de Lavras, Lavras, 2013.