

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM COMPUTACIONAL

Raphael Francisco Firmiano Teixeira

**Estudo de técnicas de apoio a definições em contratos de
energia elétrica**

Juiz de Fora

2017

Raphael Francisco Firmiano Teixeira

Estudo de técnicas de apoio a definições em contratos de energia elétrica

Dissertação apresentada ao Programa de Pós-graduação em Modelagem Computacional, da Universidade Federal de Juiz de Fora como requisito parcial a obtenção do grau de Mestre em Modelagem Computacional. Área de concentração: Métodos Numéricos Aplicados

Orientador: Prof. D.Sc. Henrique Steinherz Hippert

Juiz de Fora

2017

Ficha catalográfica elaborada através do programa de geração automática da Biblioteca Universitária da UFJF, com os dados fornecidos pelo(a) autor(a)

Teixeira, Raphael Francisco Firmiano.

Estudo de técnicas de apoio a definições em contratos de energia elétrica / Raphael Francisco Firmiano Teixeira. -- 2017.
57 f.

Orientador: Henrique Steinherz Hippert

Dissertação (mestrado acadêmico) - Universidade Federal de Juiz de Fora, Faculdade de Engenharia. Programa de Pós Graduação em Modelagem Computacional, 2017.

1. previsão de demanda. 2. contratos de fornecimento de energia elétrica. 3. otimização de contratos. I. Hippert, Henrique Steinherz, orient. II. Título.

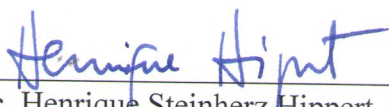
Raphael Francisco Firmiano Teixeira

Estudo de técnicas de apoio a definições em contratos de energia elétrica

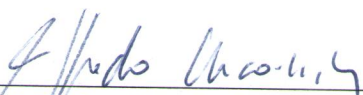
Dissertação apresentada ao Programa de Pós-graduação em Modelagem Computacional, da Universidade Federal de Juiz de Fora como requisito parcial a obtenção do grau de Mestre em Modelagem Computacional. Área de concentração: Métodos Numéricos Aplicados

Aprovada em 30 de agosto de 2017

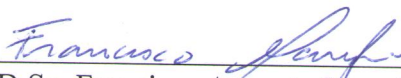
BANCA EXAMINADORA



Prof. D.Sc. Henrique Steinherz Hippert - Orientador
Universidade Federal de Juiz de Fora



Prof. D. Sc. Alfredo Chaoubah
Universidade Federal de Juiz de Fora



Prof. D.Sc. Francisco Augusto Lima Manfrini
Instituto Federal de Educação, Ciência e Tecnologia do Sudeste de Minas Gerais

*Dedico este trabalho a amigos e
familiares que me apoiaram nesse
caminho.*

AGRADECIMENTOS

Agradeço primeiramente a Deus pela proteção;

A minha família por tudo que me proporcionou;

A Livia, pelo cuidado e apoio incondicional;

Ao Professor Henrique, pelo exemplo que é e por toda a atenção que me deu;

Ao nosso coordenador Rafael Bonfim, pela presteza e dedicação;

As meninas da secretaria, Samantha, Renata, Nathália e Adriana pelas várias vezes em que me ajudaram;

Aos professores do Programa pelo aprendizado adquirido e conhecimentos transmitidos;

A grande amiga Cinara, por sempre ter me ajudado;

Ao grande amigo Tiago, pelo companheirismo e parceria.

*“Se não puder voar, corra. Se não
puder correr, ande. Se não puder
andar, rasteje, mas continue em
frente de qualquer jeito.”*

Martin Luther King

RESUMO

Frequentemente os valores dos parâmetros exigidos em um Contrato de Fornecimento de Energia Elétrica para consumidores não industriais são estimados com base na previsão de demanda utilizando o método “Naive”, por vezes, com algum ajuste empírico, o que pode gerar um contrato não-ótimo para o consumidor. Exemplo desse tipo de consumidor são as universidades, principalmente as públicas, por possuírem dimensões físicas consideráveis. Em consumidores com esse tipo de comportamento, a elaboração de um perfil de demanda baseado em estudo do funcionamento das instalações torna-se algo muito complicado. Tendo em vista tratar-se de um consumidor pertencente ao Serviço Público, há a necessidade de Contratos definidos com critérios suficientemente claros, haja vista a pressão dos órgãos de controle. Mais ainda quando se considera o uso responsável e eficaz do dinheiro público. Portanto, métodos com base na previsão de demanda do consumidor, em função do seu histórico e capazes de uma aproximação maior com a realidade, seriam importantes para obter contratos com valores financeiros minimizados. Tendo os dados de Demandas Registradas da Universidade Federal de Juiz de Fora e dados auxiliares de Temperaturas e Calendário de Aulas, desenvolvemos um método que testa previsões realizadas por métodos lineares (Médias Móveis, ARIMA e Holt-Winters), com previsões realizadas por métodos não-lineares (Redes Neurais). Comparamos estas previsões, e a melhor foi levada a um processo de otimização utilizando Algoritmos Genéticos. Essa otimização revelou dados ótimos para o Contrato e os respectivos custos. A previsão com melhor desempenho foi a obtida utilizando-se Redes Neurais, sem os dados auxiliares. A otimização levou a escolha da Tarifa Azul, com previsão de ganhos econômicos para a UFJF.

Palavras-chave: Previsão de Demanda, Contratos de Fornecimento de Energia Elétrica, Otimização de Contratos.

ABSTRACT

The values of the parameters required in a Contract of Electric Power Supply are often estimated with bases on the demand forecasted using the “Naive” method, for non-industrial consumers. Sometimes, the method suffers some empirical adjustment, which can generate a non-optimal contract for the consumer. Universities (in special the public ones) are examples of these type of consumers since they have considerable physical dimensions. The elaboration of a demand profile for these type of consumers, based on a study of the operation of the facilities, is a complicated task. Because the consumer is part of the Public Service, there is a need for Contracts defined with sufficiently clear criteria, given the pressure of the control bodies, particularly when the responsible and effective use of the public money is considered. Therefore, methods based on the consumer demand forecast in function of consumer’s history, and capable of greater approximation with reality, would be important to obtain contracts with minimized financial values. A method was developed based on data of the registered demands of the Federal University of Juiz de Fora (UFJF), and Temperature and Class Calendar adjuvant data. The method tests the predictions made by linear (Moving Averages, ARIMA and Holt-Winters) and by non-linear methods (Neural Networks). The predictions were compared and the best one was taken to an optimization process using Genetic Algorithms. The optimization revealed optimal data for the contract and its costs. The prediction that showed the best performance was the one obtained using Neural Networks without the adjuvant data. The optimization led to the choice of the “Tarifa Azul”, with possible economic gains for UFJF.

Keywords: Demand Forecasting, Contract of Electric Power Supply, Optimization of Contracts

LISTA DE ILUSTRAÇÕES

Figura 01 – Exemplo de Série Temporal.....	20
Figura 02 – Demandas Registradas UFJF.....	21
Figura 03 – Registros de Temperatura em Juiz de Fora.....	22
Figura 04 – Esquema de um neurônio artificial.....	27
Figura 05 – Esquema de uma rede MLP.....	28
Figura 06 – Demanda HFP e Previsão “Naive” para Demanda HFP.....	33
Figura 07 – Demanda HP e Previsão “Naive” para Demanda HP.....	34
Figura 08 – Demanda HFP e Previsão por Média Móveis para Demanda HFP.....	35
Figura 09 – Demanda HP e Previsão por Média Móveis para Demanda HP.....	34
Figura 10 – Demanda HFP e Previsão ARIMA para Demanda HFP.....	36
Figura 11 – Demanda HP e Previsão ARIMA para Demanda HP.....	37
Figura 12 – Demanda HFP e Previsão Holt-Winters para Demanda HFP.....	37
Figura 13 – Demanda HP e Previsão Holt-Winters para Demanda HP.....	38
Figura 14 – Demanda HFP e Previsão com Redes Neurais para Demanda HFP.....	39
Figura 15 – Demanda HP e Previsão com Redes Neurais para Demanda HP.....	40
Figura 16 – Demanda HFP e Previsão com Redes N. c. para Demanda HFP.....	41
Figura 17 – Demanda HP e Previsão com Redes Neurais c. para Demanda HP.....	42
Figura 18 – Demanda HFP e Previsão por diversos métodos para Demanda HFP.....	43
Figura 19 – Demanda HP e Previsão por diversos métodos para Demanda HP.....	44

LISTA DE TABELAS

Tabela 01 – Erros MAPE para Previsões com Redes Neurais.....	39
Tabela 02 – Erros MAPE para Previsões com Redes Neurais completo.....	40
Tabela 03 – Erros MAPE para diversos métodos de previsão.....	42
Tabela 04 – Demandas Registradas da UFJF.....	51
Tabela 05 – Registros de Temperatura em Juiz de Fora.....	52
Tabela 06 – Indicações de mês com ou sem aulas.....	53
Tabela 07 – Resultado das Previsões NAIVE.....	54
Tabela 08 – Resultado das Previsões Médias Móveis.....	54
Tabela 09 – Resultado das Previsões ARIMA.....	55
Tabela 10 – Resultado das Previsões Holt-Winters.....	55
Tabela 11 – Resultado das Previsões Redes Neurais.....	56
Tabela 12 – Resultado das Previsões Redes Neurais Completo.....	56

LISTA DE ABREVIATURAS E SIGLAS

ANEEL	Agência Nacional de Energia Elétrica
AG	Algoritmo Genético
ARIMA	Modelo Auto-Regressivo Integrado de Média Móveis
BDMEP	Banco de Dados Meteorológicos para Ensino e Pesquisa
HFP	Horário Fora de Ponta
HP	Horário de Ponta
HW	Amortecimento Exponencial de Holt-Winters
INMET	Instituto Nacional de Meteorologia
MLP	Perceptron Multi-Camadas
PROCEL	Programa Nacional de Conservação de Energia Elétrica
RN	Redes Neurais
UFJF	Universidade Federal de Juiz de Fora

SUMÁRIO

RESUMO	8
ABSTRACT	9
LISTA DE ILUSTRAÇÕES	10
LISTA DE TABELAS	11
LISTA DE ABREVIATURAS E SIGLAS	12
SUMÁRIO.....	13
1. INTRODUÇÃO	14
1.1 Revisão Bibliográfica	16
2. REVISÃO DE CONCEITOS DE ENGENHARIA ELÉTRICA.....	17
2.1 Estrutura Tarifária	17
2.2 Séries Temporais.....	20
3. MATERIAIS E MÉTODOS	22
3.1 Materiais	22
3.2 Métodos	23
3.2.1 Método "Naive" de Previsão	24
3.2.2 Método de Previsão por Médias Móveis.....	25
3.2.3 Modelos ARIMA.....	26
3.2.4 Método de amortecimento exponencial de Holt-Winters	28
3.2.5 Redes Neurais artificiais.....	28
3.2.6 Avaliação do Desempenho das Previsões	30
3.2.7 Algoritmos Genéticos.....	31
4. DISCUTINDO OS RESULTADOS ALCANÇADOS	34
4.1 Previsões	34
4.2 Otimização	46
4.3 Resultados Financeiros	47
5. CONCLUSÕES	48
REFERÊNCIAS	50
ANEXOS.....	52
A - Tabelas	52

1. INTRODUÇÃO

Na sociedade atual é inegável a necessidade do uso da eletricidade para todas as atividades. Com toda essa demanda, complexos sistemas foram criados para levar energia elétrica a todos os locais. Dado que há custos para manter o sistema ativo, o serviço de fornecimento de energia elétrica é cobrado.

Para consumidores de grande porte, esse serviço se dá através de formalização de Contratos nos quais são pactuadas diversas cláusulas. Dentre várias, algumas dizem respeito aos parâmetros elétricos (Demandas de Potência Elétrica).

No momento da assinatura desses contratos devem ser definidos o tipo de tarifa e os parâmetros elétricos pertinentes à escolha. Os parâmetros definidos deverão ser observados durante toda a vigência do contrato (no caso deste trabalho, um ano), portanto devem ser definidos adequadamente. No caso das indústrias, o controle dos parâmetros ao longo da vigência do contrato é realizado de forma eficaz, justamente porque o processo produtivo utiliza diversos equipamentos que trabalham de forma ordenada, onde o uso de cada um deles é de domínio dos engenheiros da indústria. Ocorre de forma diferente o uso de energia elétrica no serviço público, em particular nas universidades. O dinamismo é grande e as atividades não estão sob o controle centralizado. Portanto é muito difícil tentar implementar um controle de parâmetros. Assim, torna-se interessante e necessário estudar esse caso em particular, buscando criar uma maneira de definir os parâmetros de contrato onde não é possível controlá-los ao longo da vigência. É claro que, para a definição dos parâmetros, é necessário visualizar o comportamento das curvas de demanda elétrica no futuro prazo onde o contrato será vigente.

Um outro aspecto que se observa é a maneira com que alguns engenheiros definem os parâmetros elétricos nos contratos. Geralmente esses parâmetros são escolhidos de forma empírica, e, quando há alguma análise, é feita somente uma inspeção no ano anterior (método “Naive”), procurando ajustar os valores para evitar eliminar multas que possam ter sido geradas. Em casos mais refinados, Engenheiros mais experientes ajustam os parâmetros em função da experiência prática.

Com tudo isso, o problema de definição de parâmetros de contrato de fornecimento de energia elétrica em instituições onde o controle desses parâmetros é complicado, e mais ainda, a utilização da eletricidade é realizada de forma muito

imprevisível, com variações inesperadas, parece ter uma solução baseada em desenvolvimento de um método adequado para previsões com base nas séries históricas dos parâmetros. Para, com isso, criar um cenário onde a escolha dos parâmetros possa ser otimizada.

Diferente do que os profissionais têm feito no passo de definição exposto anteriormente, este trabalho propõe utilizar os conhecimentos de Inteligência Computacional, métodos de previsão, matemática e computação para definir uma forma de previsão dos valores de demanda, baseado na série histórica, para permitir uma melhor avaliação do contexto. Com uma boa previsão, pode-se desenvolver um processo de otimização das demandas, capaz de ser modificado sempre que houver mudanças nas normativas referentes.

Assim, temos então um projeto de uma ferramenta de apoio para os gestores definirem os parâmetros dos contratos de energia elétrica. É necessária a série histórica dos dados elétricos, um bom método de previsão e um método de otimização adequado.

Nas seções a seguir, procurou-se desenvolver esse projeto. Na seção 2, é feita uma introdução, apresentando os conceitos elétricos básicos e as tarifas. Além disso temos uma apresentação rápida de Séries Temporais.

Na seção 3 são apresentados os dados. Os quais são relativos à Universidade Federal de Juiz de Fora. Nessa seção também é apresentada ainda a metodologia aplicada nos diversos métodos de previsão, tanto métodos lineares quanto não-lineares. Há também os conceitos e metodologias do Algoritmo Genético, para otimização.

Na seção 4, os resultados são apresentados. As previsões são comparadas e julgadas quanto ao seu desempenho. É vista a otimização dos parâmetros do contrato e também são apresentados os reflexos financeiros que o trabalho poderia atingir.

Por fim, na seção 5 é feita uma análise do trabalho são sugeridos novos estudos.

1.1 Revisão Bibliográfica

Pesquisando sobre o estudo de contratos de energia elétrica, pouca coisa é encontrada. Há material relativo a técnicas de previsão de demanda de energia elétrica, mas todos voltados às concessionárias fornecedoras de energia; nenhum desses trabalhos é voltado ao consumidor.

O trabalho encontrado sobre o estudo de contratos de energia [8], é semelhante a prática exercida por diversos engenheiros, onde se tenta otimizar uma previsão de demanda do tipo “Naive”. Nesse trabalho, o autor apresenta alguns conceitos da engenharia elétrica, apresenta a estrutura tarifária e mostra seus dados. Após, ele faz a determinação da demanda ótima através da análise dos dados de demanda registrados no passado. Não há nenhum método de previsão, apenas são considerados, para um possível novo contrato, os dados do ano passado.

Observado isso, temos que na academia também é praticada a utilização do método “Naive” para previsão e posterior otimização a fim de se obter embasamento para contratação de energia elétrica. Este trabalho tem por objetivo estudar técnicas mais elaboradas na determinação de tarifas e valores de demanda.

Há outros trabalhos [5], [11], [12] e [13] que não são focados no consumidor, mais sim na produção e fornecimento de energia elétrica. Apesar disso, algumas das técnicas de previsão abordadas por esses, podem ser úteis neste trabalho.

2. REVISÃO DE CONCEITOS DE ENG. ELÉTRICA

Diversos são os conceitos na Engenharia Elétrica. No caso específico de Contratos de Energia, alguns deles são de extrema importância. A seguir, os principais, listados e com o devido esclarecimento.

CONSUMO DE ENERGIA ELÉTRICA: Quantidade de potência elétrica (kW) consumida em um intervalo de tempo, expresso em quilowatt-hora (kWh) ou em pacotes de 1000 unidades (MWh). No caso de um equipamento elétrico o valor é obtido através do produto da potência do equipamento pelo seu período de utilização e, em uma instalação residencial, comercial ou industrial, através da soma do produto da demanda medida pelo período de integração.

DEMANDA: 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.

HORÁRIO DE PONTA (HP): É o período de 3 (três) horas consecutivas exceto sábados, domingos e feriados nacionais, definido pela concessionária, em função das características de seu sistema elétrico. Em algumas modalidades tarifárias, nesse horário a demanda e o consumo de energia elétrica têm preços mais elevados.

HORÁRIO FORA DE PONTA (HFP): Corresponde às demais 21 horas do dia, que não sejam às referentes ao horário de ponta.[16]

2.1 Estrutura Tarifária

Diversas são as modalidades de tarifas de eletricidade. Neste trabalho será considerado o Grupo A de consumidores. Neste grupo, temos os consumidores atendidos em Alta Tensão (no caso, acima de 2300 V), que na maioria dos casos são consumidores comerciais ou industriais. A tarifa é chamada de Binômica, pois a cobrança ocorre em cima da Demanda e do Consumo. Essa estrutura tarifária utilizada para o desenvolvimento do trabalho está apresentada com base nas normas da ANEEL e PROCEL [1], [18].

ESTRUTURA TARIFÁRIA CONVENCIONAL: O valor pago, por mês, nesse tipo de tarifa será definido pela soma da parcela referente ao consumo de energia

elétrica, mais a parcela referente à demanda contratada (parâmetro este que tem de ser definido no contrato, ou seja, é o valor que buscamos otimizar nesse tipo de tarifa) mais a parcela referente a ultrapassagem de demanda, caso ocorra. Portanto:

$$Custo_i = C_{c_i} + C_{d_i} + C_{u_i} \quad (1)$$

Onde:

$$i = \text{mês}$$

$$C_{c_i} = \text{Tarifa Consumo} \times \text{Consumo Registrado}_i$$

$$C_{d_i} = \text{Tarifa Demanda} \times \text{Demanda Contratada}$$

$$C_{u_i} = \begin{cases} 0, & \text{caso } DReg \leq DCon \\ Tar_U \times (DReg - DCon), & \text{caso } DReg > DCon \end{cases}$$

Onde:

$$DReg = \text{Demanda Registrada}$$

$$DCon = \text{Demanda Contratada}$$

$$Tar_U = \text{Tarifa de Ultrapassagem}$$

O custo anual, que desejamos minimizar em função da Demanda Contratada, será:

$$Custo\ anual = \sum_{i=1}^{12} Custo_i$$

Essa estrutura só pode ser aplicada a instalações cuja demanda contratada não seja superior a 300kW.

ESTRUTURA TARIFÁRIA HORO-SAZONAL VERDE: O valor pago, por mês, nesse tipo de tarifa será definido pela soma da parcela referente ao consumo de energia elétrica (consumo no horário de ponta e consumo do horário fora de ponta), mais a parcela referente à demanda contratada (parâmetro este que tem de ser definido no contrato, ou seja, é o valor que buscamos otimizar nesse tipo de tarifa) mais a parcela referente a ultrapassagem de demanda, caso ocorra. Portanto:

$$Custo_i = C_{c_i} + C_{d_i} + C_{u_i} \quad (2)$$

Onde:

$i = \text{mês}$

$$C_{ci} = TCon_{HP} \times CReg_{HPi} + TCon_{HFP} \times CReg_{HFPi}$$

$$C_{di} = \text{Tarifa Demanda} \times \text{Demanda Contratada}$$

$$C_{ui} = \begin{cases} 0, & \text{caso } DReg \leq DCon \\ Tar_U \times (DReg - DCon), & \text{caso } DReg > DCon \end{cases}$$

Onde:

$$TCon = \text{Tarifa Consumo}$$

$$CReg = \text{Consumo Registrado}$$

$$DReg = \text{Demanda Registrada}$$

$$DCon = \text{Demanda Contratada}$$

$$Tar_U = \text{Tarifa de Ultrapassagem}$$

O custo anual, que desejamos minimizar em função da Demanda Contratada, será:

$$\text{Custo anual} = \sum_{i=1}^{12} \text{Custo}_i$$

Cabe observar que do ponto de vista da Demanda Contratada as duas tarifas apresentadas são bem semelhantes. Contudo, os valores de tarifas de consumos são diferentes, portanto, é necessário avaliar as duas. Há de se observar ainda que a Demanda Registrada para as duas tarifas anteriores será o maior valor entre as Demandas Registradas HP e HFP.

ESTRUTURA TARIFÁRIA HORO-SAZONAL AZUL: O valor pago, por mês, nesse tipo de tarifa será definido pela soma da parcela referente ao consumo de energia elétrica (consumo no horário de ponta e consumo do horário fora de ponta), mais a parcela referente à demanda contratada (no horário de ponta e no horário fora de ponta – agora são dois valores de demanda à serem otimizados) mais a parcela referente a ultrapassagem de demanda, caso ocorra. Portanto:

$$\text{Custo}_i = C_{ci} + C_{di} + C_{uiHP} + C_{uiHFP} \quad (3)$$

Onde:

$i = \text{mês}$

$$C_{c i} = TCon HP \times CReg HP_i + TCon HFP \times CReg HFP_i$$

$$C_{d i} = TDem HP \times DCon HP + TDem HFP \times DCon HFP$$

$$C_{u iHP} = \begin{cases} 0, & \text{caso } DRegHP \leq DConHP \\ Tar_{UHP} \times (DRegHP - DConHP), & \text{caso } DRegHP > DConHP \end{cases}$$

$$C_{u iHFP} = \begin{cases} 0, & DRegHFP \leq DConHFP \\ Tar_{UHFP} \times (DRegHFP - DConHFP), & DRegHFP > DConHFP \end{cases}$$

Onde:

$TCon = \text{Tarifa Consumo}$

$TDem = \text{Tarifa Demanda}$

$CReg = \text{Consumo Registrado}$

$DReg = \text{Demanda Registrada}$

$DCon = \text{Demanda Contratada}$

$Tar_U = \text{Tarifa de Ultrapassagem}$

O custo anual, que desejamos minimizar em função da Demanda Contratada HP e Demanda Contratada HFP, será:

$$Custo\ anual = \sum_{i=1}^{12} Custo_i$$

2.2 Séries Temporais

Uma Série Temporal pode ser definida como sendo um conjunto de observações que são ordenadas no tempo. Essas observações possuem a chamada dependência serial, que nada mais é do que uma dependência entre os valores da variável em instantes de tempo [2], [3].

Em uma década, potência instalada de energia solar, eólica e biomassa cresceu no país

Em megawatts




Figura 01 – Exemplo de Série Temporal [4].

A dependência serial dos dados é uma característica muito importante das Séries Temporais, pois permite fazer a previsão de valores futuros dessa série.

Vários são os métodos para realizar previsão de valores futuros de Séries Temporais. Alguns deles são: Previsão “Naive”, Previsão por Médias Móveis, Previsão através de modelos ARIMA ou Holt-Winters e Previsão através de Redes Neurais.

Estes métodos serão discutidos na próxima seção.

3. MATERIAIS E MÉTODOS

3.1 Materiais

Os Contratos de Energia tratam de grandezas elétricas. Na estrutura definida para o estudo, é necessário o histórico de demandas máximas registradas, tanto HP quanto HFP. Como estudo de caso, os dados a serem utilizados serão os da Universidade Federal de Juiz de Fora (dados mensais de maio de 2009 a junho de 2017). Mais especificamente, as medições da sua subestação principal.

As observações de Demanda HFP e HP utilizadas foram obtidas no setor de eletricidade da Pró-Reitoria de Infraestrutura dessa Universidade. A Tabela 04 (no Anexo) apresenta os dados obtidos.

Importante frisar que, conforme observado nas tabelas, a UFJF não poderá contratar a Tarifa Convencional, pois 300 kW não seriam suficientes pelo histórico.

As Séries de Demanda da Universidade podem ser visualizadas na Figura 02.




Figura 02 – Demandas Registradas UFJF.

Para o incremento da previsão por Redes Neurais, foram utilizados os dados de temperatura, calendário escolar e calendário de greves.

Os dados de temperatura foram obtidos no BDMEP [14]. A estação meteorológica considerada foi a de Juiz de Fora, cujo código de identificação do BDMEP é 83692. As temperaturas selecionadas são as compensadas médias por mês e

as médias máximas por mês, de acordo com o mês das demandas registradas.

Nos dados do BDMEP, havia alguns dados faltantes. Esses foram obtidos no INMET através do site do Laboratório de Climatologia e Análise Ambiental da UFJF [22].

Desta forma, os dados são apresentados na Tabela 05 e visualizados na figura 03.




Figura 03 – Registros de Temperatura em Juiz de Fora.

A informação relativa ao período de aulas na UFJF foi obtida analisando os calendários escolares (obtidos no site da Universidade [23]) juntamente com os calendários de greves (esses obtidos junto ao sindicato dos professores, APES). Dessa maneira criou-se uma variável binária que indica se o mês teve ou não pelo menos um dia de aula da graduação. Essa consideração foi baseada no fato de que a Demanda Registrada é a maior demanda ocorrida no mês; portanto, se há aula em um dia apenas, esse pode ser o dia de registro da demanda máxima, dado o maior uso de eletricidade devido às aulas do dia.

No Anexo, na Tabela 06 as informações de meses com algum dia de aula (valor atribuído “1”) e meses sem nenhuma aula (valor atribuído “0”).

3.2 Métodos

Conforme visto na introdução, o objetivo desse trabalho é obter diretrizes “ótimas” para contratação de energia elétrica. O ótimo neste caso é a minimização dos

custos. Dessa forma, o procedimento adotado é o de realizar previsões das demandas para o horizonte do contrato (doze meses) e com essas previsões minimizar os custos através da escolha ótima das demandas do contrato.

Para isso alguns métodos de previsão foram utilizados. O método “Naive” é a referência, dado que é o método adotado na prática. Com o objetivo de superar os resultados do “Naive”, métodos lineares (Médias Móveis, ARIMA e Holt-Winters - que podem ser vistos com mais detalhes em [2], [3], [5], [7] e [16]), e não-lineares (Redes Neurais – vistos com mais detalhes em [6], [10], [11], [12], [13], [17] e [21]) foram testados.

Para comparação entre os métodos, dado a natureza de 12 meses do contrato, as últimas 12 observações foram reservadas para esse fim. Dessa forma há o conjunto de estudos (da 1ª até a 86ª observação, pouco mais de 7 anos) e o de comparação (da 87ª a 98ª observação, 1 ano).

Para otimização, Algoritmos Genéticos foram aplicados. Essa aplicação é justificada pela facilidade de implementar possíveis regras dos contratos que as Resoluções pertinentes possam vir a exigir.

3.2.1 Método “Naive” de previsão

Quando se deseja fazer algum tipo de previsão, um método bastante simples pode ser adotado: Previsão “Naive” ou Método Ingênuo. Ele se baseia na ideia de que a previsão de valores futuros são os observados “hoje”.

$$\hat{Z}_{T+k/T} = Z_T \quad (4)$$

Onde:

$\hat{Z}_{T+k/T}$ Previsão no instante T + k.

Z_T Valor observado no instante T.

Apesar de ser um tipo de previsão banal, é muito utilizado na prática, onde não se dispõe de ferramentas para fazer previsões (caso já comentado na introdução – uso desse processo na definição de parâmetros dos contratos).

A implementação da Previsão “Naive” é bem simples. Ressalta-se apenas que o valor previsto são os 12 meses de horizonte do contrato, ou seja, os últimos 12 meses do conjunto de estudos formam a previsão neste caso.

3.2.2 Método de previsão por Médias Móveis

Outro método de se fazer previsões é a utilização do conceito de médias móveis. Nesse caso, o valor previsto é o resultado da média de um certo número de observações anteriores. Esse número seria fixo. E, conforme vai se avançando na previsão, no sentido de se prever instantes posteriores, essa média se “movimenta”, conforme equação abaixo:

$$\hat{Z}_{T+k/T} = M_T = \frac{Z_T + Z_{T-1} + \dots + Z_{T-N+1}}{N} \quad (5)$$

Onde:

- $\hat{Z}_{T+k/T}$ Previsão no instante T + k.
- Z_T Valor observado no instante T.
- M_T Média no instante T.
- N Tamanho de “janela” utilizado na média.

Antes de realizar a previsão, o conjunto de dados de estudo foi utilizado para uma otimização. Buscou-se a janela de médias ótima para cada conjunto de dados. Essa busca foi realizada separando-se o conjunto de estudos, parte para fazer as médias, parte para comparar a previsão. Foram usadas de janelas contendo 2 a 12 meses na média. O número de janelas ótimo foi definido como o que obteve menor erro nesse processo.

A previsão para confronto com o conjunto de comparação foi feita mês a mês. Dessa maneira, a cada mês previsto, os valores mais recentes da média não seriam valores observados, mas sim valores obtidos pelas previsões dos meses anteriores. Até que, dependendo do tamanho de janela, a previsão seria obtida com valores previstos também. Por exemplo: supondo o tamanho de janela ótimo $N = 2$. Para a previsão do primeiro mês do contrato, julho de 2016, a média seria com os meses de maio e junho

de 2016, sendo estes valores observados. Já para a previsão do segundo mês do contrato, agosto de 2016, a média seria obtida com valores dos meses de junho e julho de 2016. Ora, julho já é um valor previsto. Quando há a previsão de setembro, os dois valores utilizados são valores previstos pelo método.

Apesar de propagar erros, essa é a forma prática e aplicável, dado que no momento da assinatura do contrato não existiram os valores observados dos meses futuros, para que possam ser usados nas médias.

3.2.3 Modelos ARIMA

Os Modelos ARIMA, ou Modelos de Box e Jenkins [3], são métodos de previsão com base estatística, e pressupõem que uma série temporal Z é uma realização de um processo estocástico, sendo remetida à série uma determinada distribuição de probabilidades. A série é uma amostra com apenas um elemento, que é conjunto de observações que a compõe.

Um processo estocástico, de modo formal, é um conjunto de variáveis aleatórias $Z = Z_t$ com $t \in T$. Os valores Z_t são denominados estados do processo, e o conjunto dessas observações é denominado como espaço de estados. Se T for finito ou numerável, o processo estocástico é dito ser a tempo discreto; se $T \in \mathbb{R}$, é chamado tempo contínuo.

Já de modo informal, dizemos que um processo estocástico é estacionário se ele varia em torno de seu nível médio, sem alteração de suas propriedades estatísticas. Caso o processo seja estacionário e gaussiano, é chamado estritamente estacionário. Modelos de determinação deste tipo são denominados Modelos ARMA, com bases em filtros lineares. Caso o processo seja não estacionário, os modelos ARIMA, também baseados em filtros lineares, podem ser utilizados. Desse modo, o processo necessita ser diferenciado para só então haver o ajuste do modelo a ser utilizado.

Um filtro linear é uma função de transferência definida por uma combinação linear infinita dos valores da série temporal. Ou seja, esse filtro recebe uma série de choques aleatórios a_t , transformando-os na série Z_t .

$$a_t \rightarrow [FT] \rightarrow Z_t$$

De forma invertida, retira-se a autocorrelação da série.

$$a_t \leftarrow [FT'] \leftarrow Z_t$$

Há três casos particulares de filtros lineares: os modelos de médias móveis (MA, ‘moving average’), os modelos autorregressivos (AR), e os modelos autoregressivos/médias móveis (ARMA).

Considerando um operador de retardo B, que aplicado à série produz um valor de anterior ($B^k Z_t = Z_{t-k}$) e um operador de diferenciação baseado nesse B ($\nabla = 1 - B$) temos o modelo ARIMA (p,d,q) de forma geral básica.

$$\Phi_p(B)\nabla^d Z_t = \Theta_q(B)a_t \quad (6)$$

Onde:

- p Ordem do modelo autorregressivo.
- d Grau de diferenciação.
- q Ordem do modelo de média móvel.

Podemos modelar pela teoria dos Modelos ARIMA, quando o processo é não estacionário e sazonal, de duas formas: por processos puramente sazonais (SAR, SARI, MA sazonal) ou por modelos mistos SARIMA. Ao considerarmos uma série sazonal não estacionária, de sazonalidade S, definimos o operador de diferenciação de ordem D para modelos sazonais como:

$$\nabla_S^D = (1 - B^S)^D$$

De modo geral, temos um modelo SARIMA (P, D, Q)_s, com forma geral:

$$\Phi(B^S)\nabla_S^D Z_t = \Theta(B^S)b_t \quad (7)$$

A previsão ARIMA foi realizada utilizando a rotina já existente no R (pacote base [19]). O conjunto de dados de teste foi fornecido a essa rotina, que calculou todos os parâmetros necessários e retornou a previsão para ser confrontada com o conjunto de dados de comparação.

3.2.4 Método de amortecimento exponencial de Holt-Winters

O método de Holt-Winters é um método de previsão do tipo amortecimento exponencial linear multiplicativo.

A equação de previsão desse modelo é:

$$\hat{Z}_{T+k} = (\hat{a}_T + \hat{b}_T k) \hat{\rho}_T^{m(T+k)} \quad (7)$$

Onde:

- \hat{Z}_{T+k} Previsão no instante T + k.
- \hat{a}_T Estimativa do nível local da série.
- \hat{b}_T Estimativa da declividade.
- $\hat{\rho}_T$ Fator sazonal.

A previsão Holt-Winters foi realizada, assim como a ARIMA, utilizando a rotina já existente no R (pacote base [19]). O conjunto de dados de teste foi fornecido a essa rotina, que calculou todos os parâmetros necessários e retornou a previsão para ser confrontada com o conjunto de dados de comparação.

3.2.5 Redes Neurais artificiais

As redes neurais artificiais são sistemas de neurônios artificiais interconectados trocando informações. Esse sistema é inspirado no cérebro humano. O neurônio, que é a base da rede, é uma simplificação do conceito biológico de neurônio.

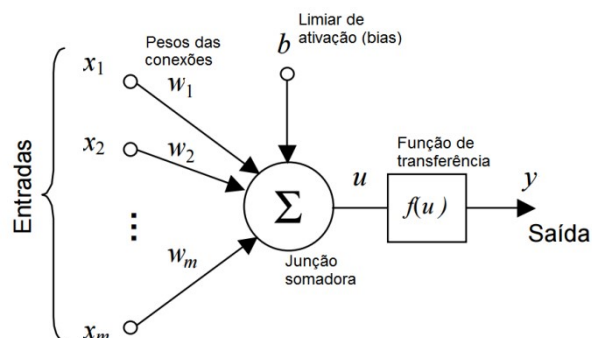


Figura 04 – Esquema de um neurônio artificial. Fonte: [20].

Basicamente, as redes são sistemas de computação massivamente paralelos, podendo ser implementados em hardware ou software. Os neurônios, como unidade dessa rede, possuem características tais, que quando conectados entre si, podem “aprender” o comportamento de algum processo através de treinamento. Para haver esse treinamento um conjunto de dados do processo é passado à rede em questão. Após isso, a rede poderia reproduzir o comportamento desse processo.

Um tipo de arquitetura de rede neural muito utilizado é o perceptron de múltiplas camadas (MLP) [10].




Figura 05 – Esquema de uma rede MLP . Fonte: [20].

Esse tipo de rede pode ser utilizado para previsões de séries temporais e para aproximação de funções em que há alto grau não-linearidade. Seu treinamento é do tipo supervisionado e utiliza um algoritmo popular chamado retro-propagação do erro (“error backpropagation”). Esse algoritmo é baseado numa regra de aprendizagem que atualiza os pesos (pesos das conexões – Figura 04) de forma a minimizar o erro durante o treinamento [10].

Algumas das diferentes funções de treinamento disponíveis:

trainlm : Essa função de treinamento de rede atualiza os valores de peso e de bias de acordo com a otimização de Levenberg- Marquardt [10].

traingdx: Essa função de treinamento de rede atualiza os valores de peso e de bias de acordo com a dinâmica de gradiente descendente e uma taxa de aprendizagem adaptativa [10].

trainrp: Essa função de treinamento de rede atualiza os valores de peso e bias de acordo com o algoritmo de retropropagação resiliente (Rprop) [10].

A previsão baseada em Redes Neurais utiliza a função *feedforwardnet*, que cria uma rede MLP com uma camada escondida implementado no Matlab (Licença número 334543). Os parâmetros dessa função foram ajustados nos valores “default”. Associada a essa função, foi aplicada a técnica de janelamento. Nessa técnica, um certo número de meses anteriores serão utilizados como entrada na rede, objetivando implantar uma memória na previsão. Foi também uma busca para a definição de um número ideal de meses no janelamento (de um a doze) e um número ótimo de neurônios na camada escondida (de um a vinte quatro).

O procedimento anterior foi repetido para três tipos de função de treinamento (*trainlm*, *traingdx* e *trainrp*). Em cada caso temos uma configuração.

Como já citado nas previsões anteriores, ao realizar a previsão das demandas para o contrato não serão utilizados na entrada dos modelos os dados observados a cada mês, e sim as previsões feitas pelo modelo para estes meses. Este é o caso real, pois a definição do contrato é feita no início do período.

Como as Redes Neurais possuem uma inicialização de pesos aleatórios, foram rodadas 30 repetições de cada configuração, e selecionados os melhores resultados. Isso, no intuito de se evitar utilizar um resultado no qual os pesos foram inicializados com valores ruins.

Dois tipos de previsão com redes foram realizadas. Uma delas utilizando-se somente as demandas como dados de entrada. A outra utiliza dados de temperatura média e máxima mensal e a variável binária que indica se houve aula ou não no mês, além das demandas, como entradas. Esse último modelo foi chamado de redes neurais “completo”.

3.2.6 Avaliação do Desempenho das Previsões

Conforme abordado no início do item 3.2, há um conjunto de dados reservados para as comparações. Esse equivale a 12 meses de dados, simulando exatamente a situação real de contratação de energia. Dessa forma, cada método fez a previsão para esse período e foi avaliado de acordo com o erro obtido em relação aos valores reais. A

medida de erro utilizada é o MAPE. Abaixo a definição do seu cálculo.

$$MAPE = \frac{1}{12} \times \sum_{t=1}^{12} 100 \times \left| \frac{Z_t - \hat{Z}_t}{Z_t} \right| \quad (8)$$

Onde:

Z_t Valor observado no instante t.

\hat{Z}_t Valor previsto no instante t.

3.2.7 Algoritmos Genéticos

Os Algoritmos Genéticos (AGs) são algoritmos inspirados na evolução natural das espécies. Charles Darwin desenvolveu diversos conceitos sobre seleção e evolução de espécies na natureza. Os AGs se baseiam nessas teorias para solucionar problemas, principalmente, problemas de otimização (mais detalhes em [9] e [15]).

Basicamente o algoritmo tem os seguintes passos:

- Há uma população inicial gerada aleatoriamente, onde cada indivíduo é representado por um “cromossomo” que contém as informações do indivíduo;
- A população é avaliada, e seu desempenho é medido, pontuando todos e permitindo definir quem são os melhores (mais aptos);
- Os melhores têm maior acesso a recombinação, isto é, se “reproduzem”;
- Os indivíduos gerados podem passar por um processo de mutação;
- Essa nova geração novamente é avaliada, os melhores são recombinados e mutados (se for o caso);
- As gerações vão se sucedendo, até que seja atingido um critério de parada.

As etapas podem ser mais detalhadas e algumas características podem ser adicionadas aos algoritmos.

Após as previsões, os melhores resultados de Demanda HP prevista e Demanda HFP prevista em um período de 12 meses seguem para serem usados na escolha de um contrato com o menor custo possível. Essa escolha foi feita utilizando um algoritmo genético com as configurações explicadas na sequência.


A população de valores válidos para esse problema pertence ao conjunto dos números naturais, que são os valores de demanda válidos para o contrato. Foram

utilizados valores que vão até a capacidade máxima da subestação, uma vez que valores maiores não poderão ser implementados por questões elétricas. Assim, no caso da Subestação Principal da UFJF, cuja potência instalada é de 3300 kW, o conjunto de valores possíveis serão os números naturais de 0 a 3300.

Os indivíduos foram representados através dos números binários.

O tamanho do cromossomo foi definido para trazer as informações do tipo de tarifa (convencional, verde ou azul – ver seção 2.1) e as demandas HFP e HP. Para as tarifas são necessários 2 bits e para cada demanda 12 bits (4096 possibilidades) totalizando 26 bits. As tarifas foram mapeadas por 00 e 11 sendo convencional, 01 sendo verde e 10 sendo azul. Já os valores de demanda foram mapeados pela equação da reta abaixo (para ajustar os 3300 valores as 4096 possibilidades).

$$\text{Binário} = 1,2412 \times \text{Demanda}$$



O desempenho da população foi avaliado pela função específica desenvolvida neste trabalho. Essa simplesmente calcula o custo anual exatamente como apresentado na seção 2.2.

A seleção de pais para reprodução acontece através de uma roleta, com área definida em função do desempenho da população.

O crossover ocorre com um único corte, misturando o material genético dos pais para compor os filhos.

A mutação pode ocorrer de acordo com a probabilidade definida, em cada bit do cromossomo. No intuito de otimizar o algoritmo, a mutação possui valores dinâmicos. No início a taxa é mais alta, buscando maior variedade. Com o passar do tempo, pela pressão de seleção, a população vai se aproximando do ótimo, sendo então importante não ocorrerem tantas mutações, para evitar indivíduos que fujam dessa região.

As gerações foram sendo criadas até que toda a população tenha um desempenho semelhante, ou seja, esteja bem uniforme. Temos o parâmetro ‘erro de parada’, que indica a diferença máxima de desempenho do melhor para o pior indivíduo da população. Esse, juntamente com a taxa de mutação dinâmica, leva a obtenção de

uma população com desempenho próximo do ótimo. Nas primeiras gerações há uma grande diversidade, mas com o passar do tempo essa diversidade diminui, indo na direção do melhor desempenho.

Quanto à sobrevivência, a política de substituição é plena, com os filhos substituindo os pais. Porém, adotou-se o Elitismo para preservar o melhor de cada geração. Nesse caso o melhor pai substitui o pior filho. Após isso, os filhos se tornam os pais na próxima geração.

Após a rotina estar desenvolvida, foram feitas algumas rodadas para definição dos parâmetros, tais como taxa de mutação, taxa de crossover, tamanho inicial da população e erro máximo de parada do processo.

A questão de possíveis restrições também foi também avaliada nesse trabalho. Na prática, temos uma limitação relativa a equipamentos de proteção usados na Subestação. Com os novos relés habilitados, os valores registrados de demanda só podem ultrapassar em 5% os valores contratados, sob pena de acionamento dos disjuntores e conseqüente desligamento geral da Universidade. Para isso uma simples mudança foi realizada: ao invés de utilizar uma escala com valores possíveis de 0 a 3300 kW, foram criadas duas escalas (HFP e HP). Estas escalas tem agora os valores permitidos iniciando do valor que faz com que o maior valor registrado não o ultrapasse por mais de 5%, a 3300 kW para HFP. Para HP, temos que a escala vai do valor que faz com que o maior valor registrado não o ultrapasse por mais de 5%, a 3300 kW. Por fim, foi feito o mapeamento para conversão em binário.

4.DISCUTINDO OS RESULTADOS ALCANÇADOS

4.1 Previsões

A previsão “Naive” é a referência. É então o primeiro resultado deste trabalho.

Do ponto de vista computacional ela é bastante simples. Apenas há uma leitura dos dados, e a rotina separa os últimos 12 meses do conjunto de estudos. Portanto pouco esforço computacional é necessário.

O Erro MAPE tanto da Previsão de Demandas HFP quanto de Demandas HP é apresentado na Tabela 03. Foram obtidos erros acima de 24% em relação aos valores Reais nos dois casos.

As Figuras 06 e 07 mostram as Previsões plotadas juntamente com os dados reais. Nota-se que os momentos de aumento e diminuição das demandas ficaram invertidos com relação aos reais. Essa característica não é interessante, pois poderiam induzir conclusões incorretas pelas observações dos gráficos. Esperar uma queda de demanda nos meses de agosto e setembro sendo que na verdade há um aumento.




Figura 06 – Demanda HFP e Previsão “Naive” para Demanda HFP.




Figura 07 – Demanda HP e Previsão “Naive” para Demanda HP.

A previsão por Médias Móveis foi a primeira das previsões lineares utilizadas.

Do ponto de vista computacional, assim com a “Naive”, ela é simples. O algoritmo varre os dados de maneira a ir calculando as médias, sendo essas o resultado das previsões. Nesse caso, porém, antes de prever há uma busca do número de janelas (meses utilizados na média) ótimo. Tanto na previsão de Demandas HFP quanto HP o número ótimo de janelas é 2.

Nas Figuras 08 e 09 temos as Previsões plotadas juntamente com os dados reais. Nota-se que o método tornou as curvas planas nos dois casos (HP e HFP). Isso acontece porque o número de janelas igual a 2 e a utilização das próprias previsões para o andamento do método durante toda a previsão faz com que a média se torne quase constante. Certamente já foi dito que devido a necessidade de definição de 1 ano de previsões no momento do contrato, essa era a estratégia correta a ser adotada no algoritmo. O resultado nas curvas seria melhor, se fosse possível ir utilizando os valores reais mês a mês.

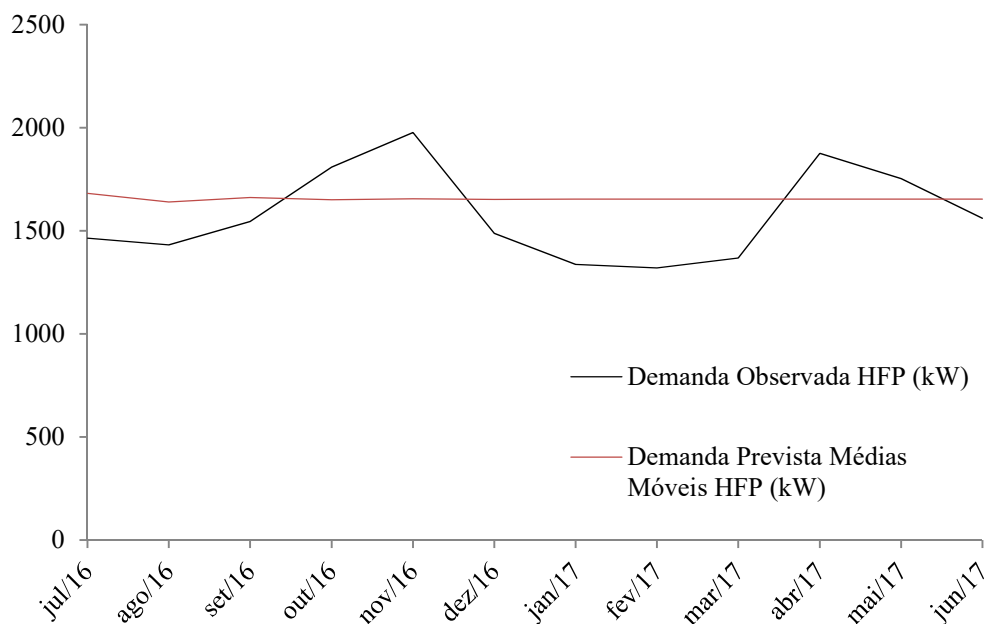


Figura 08 – Demanda HFP e Previsão por Média Móveis para Demanda HFP.




Figura 09 – Demanda HP e Previsão por Média Móveis para Demanda HP.

As previsões por ARIMA e Holt-Winters são os últimos dois tipos de previsão por métodos lineares utilizados.

Do ponto de vista computacional, esses dois tipos de previsão são bem mais complexos do que a previsão “Naive” e a previsão por Média Móveis. Nesse caso não foi desenvolvido nenhum algoritmo novo. Foram utilizadas as rotinas existentes no

software R (pacote base) [19]. Apenas para cálculo dos erros MAPE e elaboração dos gráficos foram escritas rotinas próprias.

Os coeficientes do ARIMA calculado pelo R para previsão de demanda HFP são: $AR(1) = 0,5724237$, $MA(1) = -0,9962440$, $SAR(1) = -0,2398620$ e $SMA(1) = -0,5524744$. Para previsão de demanda HP são: $AR(1) = -0,8493719$, $MA(1) = 0,9999877$, $SAR(1) = -0,1881576$ e $SMA(1) = -0,6439063$.

Nas Figuras 10 e 11 temos as previsões ARIMA plotadas juntamente com os dados reais. Já nas Figuras 12 e 13 temos as previsões Holt-Winters plotadas juntamente com os dados reais. Nota-se em ambos os tipos de previsões que não encontramos os problemas citados nas previsões “Naive” e Médias Móveis. Não houve um efeito das curvas se tornarem planas e as previsões acompanharam os valores reais nos momentos de aumento e diminuição da demanda. Os Erros são apresentados na Tabela 03.

Métodos lineares mais elaborados conseguiram melhores resultados que os métodos lineares mais simples.




Figura 10 – Demanda HFP e Previsão ARIMA para Demanda HFP.




Figura 11 – Demanda HP e Previsão ARIMA para Demanda HP.




Figura 12 – Demanda HFP e Previsão Holt-Winters para Demanda HFP.




Figura 13 – Demanda HP e Previsão Holt-Winters para Demanda HP.

A previsão por Redes Neurais foi uma previsão não-linear utilizada neste trabalho.

São dois os tipos de previsão com Redes Neurais, uma com somente os dados de demanda na entrada e a chamada “completo” que utiliza também na entrada dados de temperatura e períodos de aula.

Do ponto de vista computacional, as previsões utilizando redes são extremamente mais custosas que as previsões anteriores. Para se ter uma ideia, no mesmo computador utilizado, a rotina que fez a previsão com as redes utilizou algumas horas para rodar e entregar todos os resultados. Nas previsões anteriores, o computador necessitou de segundos para entregar os resultados.

Cada uma das 3 funções de treinamento, teve 30 rodadas. Na tabela 01 temos os melhores resultados de cada função, para o caso de somente demandas utilizadas como entradas nas redes.

Tabela 01 – Erros MAPE para Previsões com Redes Neurais.

	Erro MAPE	
	HFP	HP
Redes Neurais - trainlm	10,4333	13,9626
Redes Neurais - traingdx	9,3531	12,2618
Redes Neurais - trainrp	10,7269	11,4129

Para a previsão de Demandas HFP, a rede com função de treinamento “traingdx” teve o menor erro, conseguindo ficar abaixo de 10%. Já na previsão de Demandas HP, a rede com função de treinamento “trainrp” obteve o menor erro.

Nas Figuras 14 e 15 temos os resultados das melhores previsões plotados juntamente com os valores reais. Observa-se que as curvas previstas acompanham de forma razoável os valores reais. As tendências de aumento e diminuição das demandas estão coerentes, e os valores previstos não estão muito discrepantes.




Figura 14 – Demanda HFP e Previsão com Redes Neurais para Demanda HFP.




Figura 15 – Demanda HP e Previsão com Redes Neurais para Demanda HP.

Da mesma forma que a previsão anterior, a previsão com Redes Neurais completo, foram feitas 30 rodadas com cada um dos 3 tipos de funções de treinamento. Esperava-se que com mais informações na entrada, as previsões tivessem menor erro do que as realizadas com somente as demandas na entrada. Na tabela 02 os erros apresentados.

Tabela 02 – Erros MAPE para Previsões com Redes Neurais completo.

	Erro MAPE	
	HFP	HP
Redes Neurais Completo - trainlm	11,5011	11,5775
Redes Neurais Completo - traingdx	10,4432	16,7952
Redes Neurais Completo - trainrp	11,1989	17,1617

O fato dos erros apresentados neste caso não serem menores do que o anterior pode ser creditado a diversos fatores. Um deles são os dados de aula binários. A junção do calendário escolar com as informações de greve pode não estar adequada, dado que as informações de greve obtidas são pouco confiáveis. A consideração binária também pode ser um pouco drástica, dado que um mês com apenas um dia de aula, pode não influenciar tanto na demanda máxima quanto um mês completo de aulas. Apesar de que

apenas um registro de demanda máxima é o suficiente no mês, o mês com apenas um dia de aula não mobiliza tanto a Universidade quanto um mês completo de aulas.

Outro fato que pode ter ajudado no resultado é o de que essas informações adicionais na entrada da rede não são as maiores influências na demanda da UFJF.

De qualquer forma, nas Figuras 16 e 17 estão plotadas as previsões junto aos valores reais.

No caso das previsões para Demanda HP, temos, da mesma maneira que as previsões feitas somente com a demanda na entrada da rede, uma curva prevista que acompanha os dados reais de maneira razoável. Diferente disso, nas previsões de Demanda HFP, a curva prevista teve um aspecto mais parecido com o obtido nas previsões por Médias Móveis.




Figura 16 – Demanda HFP e Previsão com Redes Neurais completo para Demanda HFP.




Figura 17 – Demanda HP e Previsão com Redes Neurais completo para Demanda HP.

Com base em todos os resultados a Tabela 03 e as Figuras 18 e 19 são apresentados. Por obterem os menores erros MAPE e apresentarem curvas de previsão mais adequadas, as previsões feitas com Redes Neurais (sem o uso de temperaturas e aulas na entrada) são as previsões que serão utilizadas no Algoritmo Genético, a fim de obter o Contrato de Fornecimento de Energia ótimo.

	Erro MAPE	
	HFP	HP
NAIVE	24,6222	24,0361
Médias Móveis	13,8588	17,7642
ARIMA	13,4341	14,1718
Holt-Winters	14,7329	16,5421
Redes Neurais	9,3531	11,4129
Redes Neurais Completo	10,4432	11,5775

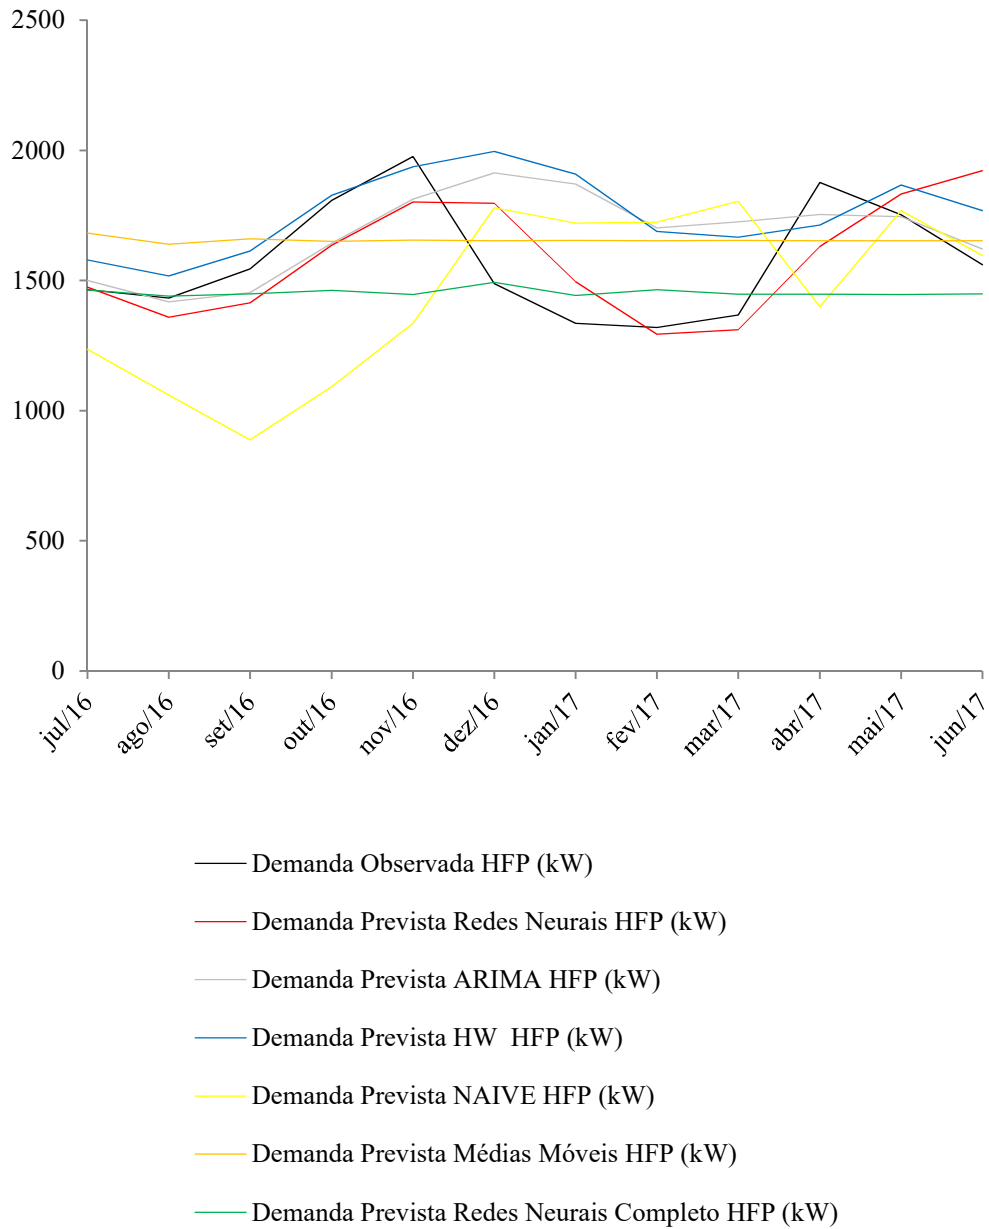


Figura 18 – Demanda HFP e Previsão por diversos métodos para Demanda HFP.




Figura 19 – Demanda HP e Previsão por diversos métodos para Demanda HP.

4.2 Otimização

Uma vez obtidas as previsões, tanto para a Demanda HFP quanto para a Demanda HP, é possível aplicar o processo de otimização.

A rotina desenvolvida para esse processo necessita de alguns parâmetros iniciais. São: tamanho inicial da população, taxa de mutação, taxa de crossover e erro de parada. Após diversas rodadas do algoritmo, esses parâmetros foram acertados. A população inicial ficou em 70, a taxa de mutação ficou em 15%, a taxa de crossover ficou em 85% e o erro de parada ficou em 5%. Usualmente esses parâmetros são definidos com tentativas e erros.

Com todos os parâmetros definidos, a rotina retornou os parâmetros de contrato ótimos. Com eles podem-se calcular os custos ótimos e verificar se há economia ou não com o uso deste trabalho.

A modalidade tarifaria definida pelo AG como ótima foi a Azul, sendo a Demanda HFP contrata no valor de 1546 kW e a Demanda HP contratada no valor de 1234 kW. O custo final anual da UFJF com esse contrato seria de R\$ 3.031.168,90. A UFJF não poderia contratar a Tarifa Convencional, pois não atende o quesito de demanda contratada máxima.

Conforme comentado no item 3.2.7, o algoritmo genético permite fácil implantação de regras para otimizar. A questão do novo relé na Subestação impõe a condição de a maior demanda registrada não ultrapassar em 5% a demanda contratada. Com essa condição implementada, o AG entrega como resultado a modalidade tarifaria ótima sendo novamente a Azul, com a Demanda HFP contrata no valor de 1830 kW e a Demanda HP contratada no valor de 1426 kW. O custo final do contrato neste caso para a UFJF seria de R\$ 3.072.763,90.

Por fim, um resultado extremamente importante para dar respaldo a este trabalho, é o teste feito com os dados reais de demanda no AG (com a questão do relé inclusa). Feito isso, o AG indicou como ótimo a mesma modalidade tarifaria (Azul) com um valor de Demanda HFP contrata no valor de 1882 kW e a Demanda HP contratada no valor de 1539 kW, que é muito coerente com o valor obtido através das previsões. O custo anual seria de R\$ 3.137.952,94.

4.3 Resultados Financeiros

A comparação básica deve ser feita com a situação contratual real da UFJF para o período em questão, os meses de dados do conjunto de comparação. Nesse período a modalidade tarifaria contratada pela Universidade é a Verde, com o valor de Demanda Única sendo 1400 kW. A condição do relé não está habilitada nesse período. Dessa forma o valor anual do Contrato foi de R\$ 3.182.131,03.

Comparando o valor real pago pela UFJF a Cemig, com o obtido por este Trabalho, seria possível uma economia de **R\$ 150.962,13**, ou **4,7 %** no período. Apenas como comparação, com essa economia a Universidade poderia ofertar 100 bolsas de estudo no valor de R\$ 1500,00. Seria possível assim, atender a 4 alunos de mestrado durante os dois anos de duração do curso.

Outros comparativos são possíveis. Se o relé estivesse habilitado nesse período, seria possível uma economia de R\$ 109.367,13, ou 3,4% no período. Se a UFJF pudesse optar pela Tarifa Convencional, com valores de Demanda Contratada otimizados, sem o relé a economia seria de R\$215.485,06, ou 6,8%. Com o relé a economia seria de R\$ 188.627,18, ou 5,9%. Uma ultima situação, sem usar as previsões, apenas otimizando o contrato com os valores reais de demanda, a economia seria de R\$ 44.178,09, ou 1,4%.

O método proposto neste trabalho conseguiria economizar dinheiro mesmo em outros cenários.

5.CONCLUSÃO

Após a apresentação de todos os resultados pode-se concluir que o método proposto neste trabalho pode ser utilizado pelos gestores como ferramenta auxiliar no processo de contratação de energia elétrica.

Diversos são os estudos que procuram realizar previsões ou mesmo otimização do ponto de vista do fornecedor. Este trabalho trouxe a aplicação de diversas técnicas estudadas na previsão de demandas de energia elétrica das unidades geradoras nas condições de um consumidor, proporcionando a ele a otimização de seus custos com energia.

Importante ressaltar que a economia proporcionada pelo trabalho é obtida sem investimentos financeiros. O computador para rodar as rotinas pode ser o de uso comum do gestor. Bastam algumas horas de trabalho computacional e algum tempo de análise dos resultados para obter a economia.

Os procedimentos desenvolvidos no trabalho podem ser utilizados também nas indústrias. Claro que, conforme comentado na introdução, há neste caso condições de se obter os parâmetros de forma precisa. Mas essa pode ser mais uma ferramenta de apoio aos engenheiros nesse caso.

Os valores apresentados nos resultados deixam claro o sucesso do trabalho ao conseguir economia para a UFJF.

Fato que deve ser ressaltado aqui é o teste feito com parâmetros do contrato utilizando os valores reais. O Algoritmo Genético selecionou o mesmo tipo de tarifa (Azul), apenas os valores de Demanda foram um pouco mais altos, porém coerentes. Esse resultado leva a certeza de que as previsões realizadas têm qualidade e que o método indica sim parâmetros adequados de contrato.

Esse trabalho pode ser útil ainda no caso de auditorias, seja por órgãos externos ou internos à UFJF. Ele pode demonstrar o interesse da instituição em minimizar custos.

Para trabalhos futuros alguns aspectos podem ser explorados. Um deles é a tentativa de identificar outros fatores que influenciem na demanda da Universidade; Se identificados, aplicá-los nas Redes Neurais visando melhorar a qualidade das previsões. Outro aspecto é o calendário escolar: Estudar maneiras mais eficazes de quantificá-lo para posterior utilização nas Redes Neurais artificiais.

Por fim, uma sugestão para trabalhos futuros é a de utilizar outras técnicas na

previsão de Demanda: Verificar o desempenho delas, e caso supere os obtidos pelas técnicas testadas neste trabalho, utilizar os valores previstos na otimização e comparar a economia alcançada.

REFERÊNCIAS

- [1] AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. *Estrutura Tarifária das Concessionárias de Distribuição: Procedimentos Gerais*. 2017.
- [2] BARROS, Mônica. *Processos Estocásticos*. Rio de Janeiro: Papel Virtual Editora, 2009.
- [3] BOX, G. E. P., JENKINS, G. M., REINSEL, G. C., *Time series analysis: forecasting and control*. Prentice-Hall, 4a ed., 2008.
- [4] CALIXTO, Bruno. Energia Eólica decola no Brasil. Disponível em: <<http://epoca.globo.com/colunas-e-blogs/blog-do-planeta/noticia/2016/04/energia-eolica-decola-no-brasil-solar-continua-engatinhando.html>>. Acesso em: 31 jul. 2017.
- [5] CARNEIRO, Anna Cláudia Mancini da Silva. *Previsão do consumo de energia elétrica a curto prazo, usando combinações de métodos univariados*. 2014. 60 f. Dissertação (Mestrado) - Curso de Modelagem Computacional, Universidade Federal de Juiz de Fora, Juiz de Fora, 2014.
- [6] CASTRO, L. N.; VON ZUBEN, F. J. *Redes Neurais Artificiais*. (Notas de aula). Disponível em <ftp://ftp.dca.fee.unicamp.br/pub/docs/vonzuben/ia006_03_/topico5_03.pdf>. Acesso em Maio. 2017
- [7] CORREA, Marcelo França; LACHTERMACHER, Gerson; MACHADO, Maria Augusta Soares. *Introdução das Redes Neurais em Modelos de Médias Móveis na Previsão de Preços*. Resenha Econômica, v.4, p.70-78. 2006. Disponível em: <http://www2.bmf.com.br/cimConteudo/W_ArtigosPeriodicos/redesneurais167.pdf>. Acesso em: 10 Nov. 2015.
- [8] DE CARVALHO, Thiago Perilli. *Um estudo sobre Tarifação de Energia Elétrica visando sua utilização racional no Centro de Tecnologia da UFRJ*. 2012. 50 f. Projeto de graduação (Graduação) – Curso de Engenharia Elétrica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2012.
- [9] EIBEN, A. E.; SMITH, J. E. *Introduction to Evolutionary Computing. Natural Computing Series*. Springer, 2003.
- [10] HAYKIN, Simon. *Neural Networks: a comprehensive foundation*. 2nd ed. New Jersey: Prentice Hall, 1999.
- [11] HIPPERT, H. S., *Previsão de cargas a curto prazo - Uma avaliação da viabilidade do uso de redes neurais artificiais*, Ph.D. Thesis, Departamento de Engenharia Elétrica da PUC, Rio de Janeiro, RJ, Brasil, 2001.
- [12] 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, pp. 44–55, 2001.
- [13] HIPPERT, H. S., BUNN, D. W., SOUZA, R. C., Large neural networks for electricity load forecasting: Are they overfitted? *International Journal of*

- Forecasting*, v. 21, pp. 425–434, 2005.
- [14] INMET - Banco de Dados Meteorológicos Para Ensino e Pesquisa. *Séries históricas das várias estações meteorológicas convencionais da rede de estações do INMET*. Disponível em: <<http://www.inmet.gov.br/projetos/rede/pesquisa/>>. Acesso em: 25 ago. 2017.
- [15] LINDEN, Ricardo. *Algoritmos Genéticos*. 3. ed. Rio de Janeiro: Ciência Moderna, 2012.
- [16] MORETTIN, Pedro Alberto; CASTRO, Clélia Maria de. *Previsão de Séries Temporais*. Rio de Janeiro: Atual, 1985.
- [17] PRINCIPE, J. C.; EULIANO, N. R.; LEFEBVRE, W. C. *Neural and adaptive systems: fundamentals through simulations with CD-ROM*. John Wiley & Sons, Inc., 1999.
- [18] PROCEL - PROGRAMA NACIONAL DE CONSERVAÇÃO DE ENERGIA ELÉTRICA. *Manual de Tarifação da energia elétrica*. Brasil: 2011. Disponível em: <http://www.mme.gov.br/documents/10584/1985241/Manual%20de%20Tarif%20En%20EI%20-%20Procel_EPP%20-%20Agosto-2011.pdf>. Acesso em: 09 Nov. 2015
- [19] R PROJECT. Disponível em: <<https://www.r-project.org/>>. Acesso: 25 ago. 2017.
- [20] SANTOS, Cinara de Jesus. *Avaliação do uso de classificadores para verificação de atendimento a critérios de seleção em programas sociais*. 2017. 61 f. Dissertação (Mestrado) - Curso de Modelagem Computacional, Universidade Federal de Juiz de Fora, Juiz de Fora, 2017.
- [21] TORRES JR., Rubião G., MACHADO, Maria Augusta S., SOUZA, Reinaldo C.. Previsão de séries temporais de falhas em manutenção industrial usando redes neurais. *Engevista*, América do Norte, 7, fev. 2010. Disponível em <<http://www.uff.br/engevista/seer/index.php/engevista/article/view/163/66>>. Acesso em: 09 Nov. 2015.
- [22] UFJF. *Laboratório de Climatologia e Análise Ambiental*. Disponível em: <<http://www.ufjf.br/labcaa/>>. Acesso em: 25 ago. 2017.
- [23] UNIVERSIDADE FEDERAL DE JUIZ DE FORA. Disponível em: <<http://www.ufjf.br/ufjf/>>. Acesso em: 25 ago. 2017.

ANEXOS

A - Tabelas

Tabela 04 – Demandas Registradas da UFJF

Mês/ Ano	Dem. HFP (kW)	Dem. HP (kW)	Mês/ Ano	Dem. HFP (kW)	Dem. HP (kW)	Mês/ Ano	Dem. HFP (kW)	Dem. HP (kW)
mai/09	1104	788	fev/12	1020	680	nov/14	1936	1556
jun/09	1052	836	mar/12	1164	764	dez/14	1884	1424
jul/09	992	792	abr/12	1556	1180	jan/15	1708	1244
ago/09	920	736	mai/12	1456	1164	fev/15	1392	848
set/09	992	768	jun/12	1336	1064	mar/15	1332	972
out/09	1204	892	jul/12	1112	876	abr/15	1716	1432
nov/09	1196	860	ago/12	828	732	mai/15	1612	1452
dez/09	1324	800	set/12	900	712	jun/15	1456	1436
jan/10	1324	736	out/12	1572	1124	jul/15	1236	1204
fev/10	888	496	nov/12	1504	1112	ago/15	1060	1096
mar/10	1044	524	dez/12	1420	972	set/15	888	896
abr/10	1424	1060	jan/13	1724	1056	out/15	1092	900
mai/10	1436	964	fev/13	1572	1044	nov/15	1336	1160
jun/10	1268	1024	mar/13	1752	1264	dez/15	1780	1344
jul/10	1272	1072	abr/13	1780	1212	jan/16	1720	1336
ago/10	1148	904	mai/13	1312	1044	fev/16	1724	1304
set/10	1336	1036	jun/13	1352	1064	mar/16	1804	1476
out/10	1320	1044	jul/13	1384	1148	abr/16	1400	1400
nov/10	1308	1028	ago/13	1380	1224	mai/16	1768	1572
dez/10	1376	932	set/13	1408	1196	jun/16	1596	1532
jan/11	1380	908	out/13	1228	1100	jul/16	1464	1500
fev/11	1024	592	nov/13	1684	1348	ago/16	1432	1468
mar/11	1184	656	dez/13	1828	1284	set/16	1544	1468
abr/11	1504	1044	jan/14	1844	1388	out/16	1808	1596
mai/11	1520	1076	fev/14	1868	1388	nov/16	1976	1556
jun/11	1280	1060	mar/14	1816	1272	dez/16	1488	1232
jul/11	1224	1012	abr/14	1440	1220	jan/17	1336	1044
ago/11	1016	836	mai/14	1492	1312	fev/17	1320	960
set/11	1400	1076	jun/14	1404	1300	mar/17	1368	1020
out/11	1340	1076	jul/14	1380	1332	abr/17	1876	1604
nov/11	1336	1120	ago/14	1428	1376	mai/17	1752	1616
dez/11	1400	1048	set/14	1516	1368	jun/17	1560	1568
jan/12	1336	720	out/14	1828	1548			

Tabela 05 – Registros de Temperatura em Juiz de Fora.

Mês/ Ano	Temp. Máxima (°C)	Temp. Média (°C)	Mês/ Ano	Temp. Máxima (°C)	Temp. Média (°C)	Mês/ Ano	Temp. Máxima (°C)	Temp. Média (°C)
mai/09	23,7774	18,0510	fev/12	28,2690	22,3979	nov/14	26,8367	20,3236
jun/09	21,9833	15,8327	mar/12	27,4484	21,3819	dez/14	28,3903	22,3858
jul/09	22,8323	16,9723	abr/12	25,7069	20,2520	jan/15	31,1567	24,2580
ago/09	23,0452	17,2490	mai/12	20,6412	16,3271	fev/15	28,7321	22,5800
set/09	26,6067	20,1700	jun/12	21,8574	16,8291	mar/15	27,5032	21,7245
out/09	25,4710	19,8542	jul/12	23,0737	17,3311	abr/15	25,4333	19,8233
nov/09	28,7733	22,7100	ago/12	22,3548	16,6761	mai/15	22,1806	17,5413
dez/09	26,7226	21,0186	set/12	25,5967	18,7707	jun/15	22,1767	17,1033
jan/10	29,3742	23,0543	out/12	27,9323	21,0845	jul/15	23,1355	17,7484
fev/10	29,2214	23,2936	nov/12	24,5621	19,3720	ago/15	23,6935	17,8794
mar/10	27,2000	21,2629	dez/12	29,9548	23,3232	set/15	25,5967	20,0221
abr/10	24,6931	19,5840	jan/13	26,2968	21,0535	out/15	27,7742	21,2953
mai/10	23,1500	17,7626	fev/13	28,8500	23,0293	nov/15	28,1667	22,2400
jun/10	21,1633	15,6467	mar/13	26,4613	20,7740	dez/15	29,0161	22,8869
jul/10	22,2742	17,1181	abr/13	23,5067	18,6333	jan/16	27,0097	22,0174
ago/10	23,5000	17,1013	mai/13	22,8677	17,5353	fev/16	30,4379	23,4964
set/10	24,8633	18,6500	jun/13	22,5567	17,6852	mar/16	27,7828	22,2521
out/10	24,7581	18,4542	jul/13	21,5935	16,1219	abr/16	28,2733	22,2667
nov/10	24,6633	19,6180	ago/13	23,8581	17,5394	mai/16	23,4097	18,1645
dez/10	27,8323	21,8832	set/13	24,2067	18,3333	jun/16	21,1267	15,8697
jan/11	28,0067	22,5093	out/13	24,1871	18,8232	jul/16	22,7903	17,0355
fev/11	30,1071	23,5969	nov/13	25,0567	19,8460	ago/16	25,0897	18,2766
mar/11	25,6581	20,7703	dez/13	26,9032	21,2135	set/16	25,5833	19,0820
abr/11	25,6467	20,2253	jan/14	30,1419	23,5942	out/16	24,9613	19,5535
mai/11	21,6655	16,7180	fev/14	29,3429	23,2636	nov/16	28,8000	19,4916
jun/11	21,0552	15,7433	mar/14	27,5821	21,6693	dez/16	31,6000	21,4163
jul/11	22,9000	16,5493	abr/14	25,4200	19,7500	jan/17	30,9000	22,5466
ago/11	25,4419	18,3807	mai/14	24,5652	18,7243	fev/17	30,3000	21,6844
set/11	25,1000	17,7507	jun/14	25,1288	18,8910	mar/17	30,5000	20,8896
out/11	24,7767	19,5373	jul/14	26,1327	19,5019	abr/17	29,0000	18,9430
nov/11	23,9207	18,2607	ago/14	23,3968	17,3213	mai/17	27,1000	17,1506
dez/11	25,0258	20,2052	set/14	27,1333	19,7683	jun/17	27,8000	17,1348
jan/12	25,7258	20,4903	out/14	27,7032	20,6239			

Tabela 06 – Indicações de mês com ou sem aulas.

Mês/ Ano	Aula	Mês /Ano	Aula	Mês/ Ano	Aula	Mês/ Ano	Aula	Mês/ Ano	Aula
mai/09	1	jan/11	0	set/12	1	mai/14	1	jan/16	0
jun/09	1	fev/11	0	out/12	1	jun/14	1	fev/16	0
jul/09	0	mar/11	1	nov/12	1	jul/14	1	mar/16	1
ago/09	1	abr/11	1	dez/12	1	ago/14	1	abr/16	1
set/09	1	mai/11	1	jan/13	0	set/14	1	mai/16	1
out/09	1	jun/11	1	fev/13	0	out/14	1	jun/16	1
nov/09	1	jul/11	1	mar/13	0	nov/14	1	jul/16	1
dez/09	1	ago/11	1	abr/13	1	dez/14	1	ago/16	1
jan/10	0	set/11	1	mai/13	1	jan/15	0	set/16	1
fev/10	0	out/11	1	jun/13	1	fev/15	0	out/16	1
mar/10	1	nov/11	1	jul/13	1	mar/15	1	nov/16	1
abr/10	1	dez/11	1	ago/13	1	abr/15	1	dez/16	1
mai/10	1	jan/12	0	set/13	1	mai/15	1	jan/17	0
jun/10	1	fev/12	0	out/13	1	jun/15	1	fev/17	0
jul/10	1	mar/12	1	nov/13	1	jul/15	0	mar/17	1
ago/10	1	abr/12	1	dez/13	1	ago/15	1	abr/17	1
set/10	1	mai/12	1	jan/14	1	set/15	1	mai/17	1
out/10	1	jun/12	1	fev/14	1	out/15	1	jun/17	1
nov/10	1	jul/12	1	mar/14	1	nov/15	1		
dez/10	1	ago/12	1	abr/14	1	dez/15	0		

Tabela 07 – Resultado das Previsões NAIVE.

	Demanda Prevista NAIVE HFP (kW)	Demanda Prevista NAIVE HP (kW)
jul/16	1236,000	1204,000
ago/16	1060,000	1096,000
set/16	888,000	896,000
out/16	1092,000	900,000
nov/16	1336,000	1160,000
dez/16	1780,000	1344,000
jan/17	1720,000	1336,000
fev/17	1724,000	1304,000
mar/17	1804,000	1476,000
abr/17	1400,000	1400,000
mai/17	1768,000	1572,000
jun/17	1596,000	1532,000

Tabela 08 – Resultado das Previsões Médias Móveis.

	Demanda Prevista Médias Móveis HFP (kW)	Demanda Prevista Médias Móveis HP (kW)
jul/16	1682,000	1552,000
ago/16	1639,000	1542,000
set/16	1660,500	1547,000
out/16	1649,750	1544,500
nov/16	1655,125	1545,750
dez/16	1652,438	1545,125
jan/17	1653,781	1545,438
fev/17	1653,109	1545,281
mar/17	1653,445	1545,359
abr/17	1653,277	1545,320
mai/17	1653,361	1545,340
jun/17	1653,319	1545,330

Tabela 09 – Resultado das Previsões ARIMA.

	Demanda Prevista	Demanda Prevista ARIMA
--	------------------	------------------------

	ARIMA HFP (kW)	HP (kW)
jul/16	1499,797	1448,356
ago/16	1417,421	1445,669
set/16	1454,085	1402,451
out/16	1643,489	1524,045
nov/16	1812,096	1597,301
dez/16	1913,956	1560,947
jan/17	1870,950	1487,511
fev/17	1701,515	1338,258
mar/17	1725,379	1413,222
abr/17	1753,254	1618,845
mai/17	1744,831	1639,545
jun/17	1620,568	1629,969

Tabela 10 – Resultado das Previsões Holt-Winters.

	Demanda Prevista HW HFP (kW)	Demanda Prevista HW HP (kW)
jul/16	1578,928	1535,701
ago/16	1517,777	1517,922
set/16	1613,564	1517,743
out/16	1827,890	1653,941
nov/16	1936,316	1752,102
dez/16	1995,930	1650,105
jan/17	1908,902	1529,995
fev/17	1688,570	1348,513
mar/17	1666,304	1386,740
abr/17	1713,261	1565,524
mai/17	1866,820	1697,703
jun/17	1768,523	1704,958

Tabela 11 – Resultado das Previsões Redes Neurais.

	Demanda Prevista Redes Neurais HFP (kW)	Demanda Prevista Redes Neurais HP (kW)
jul/16	1474,231	1496,926

ago/16	1359,185	1422,046
set/16	1413,920	1389,951
out/16	1635,408	1266,977
nov/16	1801,010	1192,584
dez/16	1796,262	1097,016
jan/17	1494,857	993,550
fev/17	1293,842	944,912
mar/17	1311,384	1018,635
abr/17	1630,185	1127,738
mai/17	1832,494	1268,107
jun/17	1921,951	1323,118

Tabela 12 – Resultado das Previsões Redes Neurais Completo.

	Demanda Prevista Redes Neurais Completo HFP (kW)	Demanda Prevista Redes Neurais Completo HP (kW)
jul/16	1463,150	1499,307
ago/16	1440,433	1155,010
set/16	1447,983	1132,456
out/16	1461,631	1503,372
nov/16	1446,015	1627,670
dez/16	1492,696	1355,959
jan/17	1441,964	1003,924
fev/17	1464,995	932,151
mar/17	1446,763	1158,821
abr/17	1446,801	1401,511
mai/17	1446,017	1478,863
jun/17	1448,581	1091,734