



UNIVERSIDADE FEDERAL DA BAHIA
ESCOLA POLITÉCNICA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

ARTHUR LÚCIDE COTTA WEYLL

Dissertação de Mestrado

**PREVISÃO DE DEMANDA DE CURTO PRAZO UTILIZANDO
REDES NEURAS ARTIFICIAIS**

Salvador
2020



PREVISÃO DE DEMANDA DE CURTO PRAZO UTILIZANDO REDES NEURAS ARTIFICIAIS

Arthur Lúcido Cotta Weyll

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Engenharia Elétrica da Universidade Federal da Bahia, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia Elétrica.

Orientadores: Eduardo F. de Simas Filho
Kim N. Samejima

Salvador
Dezembro de 2020

W548 Weyll, Arthur Lúcido Cotta.

Previsão de demanda de curto prazo utilizando redes neurais artificiais/ Arthur Lúcido Cotta Weyll. – Salvador, 2020.

144 f.: il. color.

Orientadores: Prof. Dr. Eduardo F. de Simas Filho.

Prof. Dr. Kim N. Samejima.

Dissertação (mestrado) – Universidade Federal da Bahia. Escola Politécnica, 2020.

1. Potência - previsão. 2. Redes neurais. 3. Inteligência artificial. I. Simas Filho, Eduardo F. de. II. Samejima, Kim N. III. Universidade Federal da Bahia. IV. Título.

CDD: 621.31

PREVISÃO DE DEMANDA DE CURTO PRAZO UTILIZANDO REDES
NEURAIS ARTIFICIAIS

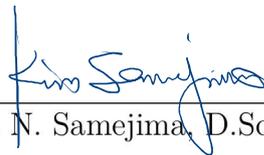
Arthur Lúcido Cotta Weyll

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA DA UNIVERSIDADE FEDERAL DA BAHIA COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE EM ENGENHARIA ELÉTRICA.

Examinada por:



Prof. Eduardo Furtado de Simas Filho, D.Sc. (UFBA)
(Orientador)



Prof. Kim N. Samejima, D.Sc. (IME-UFBA)
(Coorientador)



Prof. Antônio Carlos Lopes Fernandes Júnior, D.Sc.
(UFBA)



Prof. Danton Diego Ferreira, D.Sc. (UFLA)

SALVADOR, BA – BRASIL
DEZEMBRO DE 2020

*Dedico este trabalho a minha avó
Marília Lucide Cota*

Agradecimentos

Agradeço aos meus tios Victor Weyll e Stella Chaves pois sem o apoio deles não seria possível realizar esta pesquisa.

Agradeço aos meus pais Luciana e Augusto por todo apoio.

Ao meu professor Fábio da Conceição Cruz pela idéia do trabalho e todo incentivo e suporte para a pesquisa.

Em especial ao meu orientador Eduardo Simas, pelas conversas, incentivo, suporte, paciência e compreensão nos momentos difíceis no final da pesquisa.

Ao meu coorientador Kim Samejima pelo incentivo, apoio e suporte para o desenvolvimento da pesquisa.

A todos os colegas do LSD da UFBA, em especial ao Edmar e ao Moisés, com a convivência, conversas importantes nos momentos difíceis e troca de conhecimentos durante o andamento do trabalho.

Ao Wild pelo apoio e ajuda na parte da ESN.

A minha namorada Natália Carvalho da Silva por todo apoio.

Aos meus amigos.

Agradeço ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela concessão da bolsa de dedicação exclusiva e apoio financeiro.

Resumo da Dissertação apresentada ao PPGEE/UFBA como parte dos requisitos necessários para a obtenção do grau de Mestre em Engenharia Elétrica

PREVISÃO DE DEMANDA DE CURTO PRAZO UTILIZANDO REDES NEURAIS ARTIFICIAIS

Arthur Lúcido Cotta Weyll

Dezembro/2020

Orientadores: Eduardo F. de Simas Filho

Kim N. Samejima

Programa: Engenharia Elétrica

As edificações industriais, residenciais e comerciais dependem primordialmente de suprimento de energia ininterrupto e de baixo custo. O Brasil é um país rico em recursos naturais e energias renováveis, mas os preços da energia em todo o país são elevados. Apesar dos excelentes níveis de irradiação solar, das características predominantes dos ventos (constantes e unidirecionais) e também da geração de energia através da cana de açúcar (biomassa) a matriz energética brasileira é predominantemente dependente das usinas hidrelétricas. Devido aos altos custos da energia no país, muitas empresas estão buscando fontes alternativas e sistemas que possibilitam gerenciar a demanda e o consumo de energia elétrica. Nesse contexto, um dos mais importantes pré-requisitos para o gerenciamento de energia é a previsão de potência requerida pela instalação. As curvas de demanda de um determinado local são muito influenciadas por fatores como a meteorologia, as atividades humanas e a carga instalada. Deste modo, o aspecto das curvas de carga pode variar muito em um determinado dia, dificultando a tarefa de previsão. Uma previsão adequada combinada a um sistema de gerenciamento levam ao uso eficiente da energia pelo consumidor com o menor custo possível. Neste trabalho, foram utilizados métodos estatísticos e de Inteligência Artificial para realizar previsão de potência de curto prazo no intervalo de 15 e 30 minutos a frente utilizando dados da potência demandada pela instalação elétrica da Universidade Estadual de Santa Cruz (Ilhéus, Bahia, Brasil) no período de março de 2014 a março de 2015. Foram utilizados apenas dados da potência ativa para prever a potência ativa demandada pelo sistema elétrico e três estudos de caso foram propostos para estabelecer como lidar com a informação temporal disponível da série para realizar as previsões com o menor erro possível.

Abstract of Dissertation presented to PPGEE/UFBA as a partial fulfillment of the requirements for the degree of Master of Engenharia Elétrica

SHORT TERM LOAD FORECASTING USING ARTIFICIAL NEURAL NETWORKS

Arthur Lúcido Cotta Weyll

December/2020

Advisors: Eduardo F. de Simas Filho

Kim N. Samejima

Department: Electrical Engineering

Industrial, residential and commercial buildings depend primarily on an uninterrupted and low cost energy supply. Brazil is a country rich in natural resources and renewable energy, but energy prices across the country are high. Despite the excellent levels of solar irradiation, the prevailing wind characteristics (constant and unidirectional) and also the generation of energy through sugarcane (biomass), the Brazilian energy matrix is predominantly dependent on hydroelectric plants. Due to high energy costs in the country, many companies are looking for alternative sources and systems that manage the demand and consumption of electricity. In this context, one of the most important prerequisites for power management is the power forecast required by the facility. The demand curves of a given location are greatly influenced by factors such as weather, human activities, and installed load. In this way, the appearance of load curves may vary greatly on a given day, making the forecasting task difficult. A proper forecast combined with a management system leads to the efficient use of energy by the consumer at the lowest possible cost. In this work, statistical and Artificial Intelligence methods were used to forecast short-term power in the interval of 15 and 30 minutes ahead using data from the power demanded by the electrical installation of the State University of Santa Cruz (Ilhéus, Bahia, Brazil) from March 2014 to March 2015. Only active power data was used to predict the active power demanded by the electrical system and three case studies were proposed to establish how to handle with time information available in the series to make the forecasts with the smallest possible error.

Sumário

Lista de Figuras	x
Lista de Tabelas	xv
Lista de Abreviações e de Símbolos	1
1 Introdução	4
1.1 Objetivo	6
1.2 Impactos e Contribuições	6
1.2.1 Científicos	6
1.2.2 Tecnológicos	7
1.3 Organização do Documento	7
2 Revisão Bibliográfica	8
2.1 Previsão de Potência	8
2.1.1 Tipos de Previsão	8
2.1.2 Fatores Relevantes	9
2.1.3 Métodos de Previsão	9
2.2 Séries Temporais	10
2.3 Métodos Estatísticos	11
2.3.1 Modelo de Previsão <i>Naive</i>	11
2.3.2 Modelo AR (p)	11
2.3.3 Modelo de Médias Móveis - MA (q)	13
2.3.4 Modelo de Previsão ARMA (p,q)	13
2.3.5 Modelo de Previsão ARIMA	14
2.4 Métodos de Inteligência Artificial	17
2.4.1 Redes Neurais Artificiais	17
2.4.2 Redes Neurais de Função de Base Radial	24
2.4.3 Redes Neurais Com Estado de Eco	26
2.4.4 Abordagem Prática Para Produzir um Reservatório	28
2.5 Modelos Combinados de Redes Neurais	29
2.5.1 <i>Ensemble</i> Médio	29

3	Metodologia e Pré-Processamento da Informação	31
3.1	Aquisição dos Dados e Detalhamento das Instalações do Local	31
3.2	Pré-Processamento dos dados	35
3.2.1	Tratamento dos <i>Outliers</i>	36
3.3	Configuração dos Modelos Utilizados no Trabalho	37
3.3.1	Configuração do Modelo <i>Naive</i>	38
3.3.2	Configuração do Modelo SARIMA	38
3.3.3	Configuração do Modelo de Redes Neurais <i>Feedforward</i>	38
3.3.4	Configuração do Modelo de Redes Neurais de Base Radial	39
3.3.5	Configuração do Modelo de Redes Neurais com Estados de Eco	39
3.3.6	Configuração do <i>Ensemble</i> ou Combinação Redes Neurais	39
3.4	Estudo de Caso 1: Previsão Semanal Utilizando Modelos de IA e Estatísticos	40
3.4.1	Divisão dos dados em Conjuntos de Treino e Teste	40
3.5	Estudo de Caso 2: Previsão Mensal, um Comparativo Entre os Melhores Modelos	40
3.6	Estudo de Caso 3: Previsão da Primeira Semana de Cada Mês, um Comparativo Entre os Melhores Métodos	42
3.7	Aplicação Prática para a Previsão	42
3.8	Parâmetros de Avaliação	44
4	Resultados	45
4.1	Resultados de Ajustes de Parâmetros	45
4.1.1	Seleção dos Parâmetros de Entrada das Redes e Identificação do modelo ARIMA	45
4.1.2	Parâmetros do Modelo <i>Naive</i>	48
4.1.3	Parâmetros do Modelo SARIMA	48
4.1.4	Parâmetros do Modelo de Redes <i>Feedforward</i>	49
4.1.5	Parâmetros do Modelo de Redes RBF	51
4.1.6	Parâmetros do Modelo de Redes Neurais com Estado de Eco	55
4.2	Estudo de Caso 1	59
4.2.1	Resultados da Previsão Utilizando o Modelo <i>Naive</i>	59
4.2.2	Resultados da Previsão Utilizando o Modelo SARIMA	64
4.2.3	Resultados da Previsão das RNAs <i>Feedforward</i>	68
4.2.4	Resultados da Previsão das Redes RBF	72
4.2.5	Resultados da Previsão das ESNs	76
4.2.6	Comparação Entre Métodos	80
4.3	Estudo de Caso 2	82
4.3.1	Resultados da Previsão do Modelo SARIMA	82

4.3.2	Resultados da Previsão das RNAs <i>Feedforward</i>	85
4.4	Estudo de Caso 3	89
4.4.1	Resultados da Previsão do Modelo SARIMA	89
4.4.2	Resultados da Previsão das RNAs <i>Feedforward</i>	93
4.5	Escolha da Melhor Forma de Inserir os Dados Temporais nos Modelos	97
4.6	Comparações com Resultados da Literatura	99
4.7	Como Economizar Aplicando um Sistema Preditor de Potência	101
4.7.1	Propondo Redução de Demanda Contratada	102
4.7.2	Cálculo da Economia	111
5	Conclusões	115
	Referências Bibliográficas	118
A	Trabalhos Publicados	123
A.1	Artigos apresentados em Congressos	123
B	Anexos	125

Lista de Figuras

2.1	Previsão <i>Naive</i>	12
2.2	Modelo não linear de um neurônio.	18
2.3	Exemplo de RNA multicamadas típica.	20
2.4	Exemplo de RNA recorrente.	21
2.5	Distância radial e função de base radial.	25
2.6	Arquitetura básica das ESNs.	27
2.7	Esquema de um modelo combinado de Redes Neurais Artificiais.	30
3.1	Mapa da universidade.	32
3.2	Entrada da energia no cubículo de medição da universidade.	34
3.3	Potência ativa da Universidade de março de 2014 a março de 2015.	35
3.4	Histograma da série temporal de potência.	36
3.5	Histograma da série temporal de potência com ênfase na região de interesse.	37
3.6	Potência ativa da Universidade de março de 2014 a março de 2015 após o tratamento dos <i>outliers</i>	38
3.7	Separação dos conjuntos de treino e teste para o Estudo de Caso 1.	41
3.8	Separação dos conjuntos de treino e teste para o Estudo de Caso 2.	41
3.9	Separação dos conjuntos de treino e teste para o Estudo de Caso 3.	42
3.10	Esquema elétrico simples com uso de rede inteligente.	43
4.1	ACF e PACF da série temporal original para 1000 atrasos.	46
4.2	ACF e PACF da série temporal diferenciada para 1000 atrasos.	46
4.3	ACF e PACF para 1000 atrasos da série de diferenças sazonais.	47
4.4	MAPEs médios das 5 redes variando o número de neurônios da camada oculta, horizonte de previsão de 15 minutos.	49
4.5	<i>Box Plot</i> dos MAPEs médios das 5 redes variando o número de neurônios da camada oculta, horizonte de previsão de 15 minutos.	49
4.6	MAPEs médios das 5 redes variando o número de neurônios da camada oculta, horizonte de previsão de 30 minutos.	50

4.7	<i>Box Plot</i> dos MAPEs médios das 5 redes variando o número de neurônios da camada oculta, horizonte de previsão de 30 minutos.	51
4.8	Variação da constante de espalhamento para redes RBF com 27 neurônios na camada oculta, horizonte de 15 minutos.	52
4.9	Variação da constante de espalhamento para redes RBF com 15 neurônios na camada oculta, horizonte de 30 minutos.	53
4.10	Variação do número de neurônios para a constante de espalhamento de 1.0, horizonte de 15 minutos.	53
4.11	Variação do número de neurônios para a constante de espalhamento de 0.8, horizonte de 30 minutos.	54
4.12	Busca 1 para o horizonte de 15 minutos.	56
4.13	Busca 1 para o horizonte de 30 minutos.	56
4.14	MSE versus α no horizonte de previsão de 15 minutos.	58
4.15	MSE versus α no horizonte de previsão de 30 minutos.	58
4.16	<i>Outlier</i> na segunda feira da última semana do mês de fevereiro de 2015. 60	60
4.17	Curva da previsão de potência, mês de março de 2014, horizonte de previsão de 15 minutos.	61
4.18	Curva do erro absoluto, mês de março de 2014, horizonte de previsão de 15 minutos.	61
4.19	Histograma do erro absoluto, mês de março de 2014, horizonte de previsão de 15 minutos.	62
4.20	Curva da previsão de potência, mês de março de 2014, horizonte de previsão de 30 minutos.	62
4.21	Curva do erro absoluto, mês de março de 2014, horizonte de previsão de 30 minutos.	63
4.22	Histograma do erro absoluto, mês de março de 2014, horizonte de previsão de 30 minutos.	63
4.23	Curva da previsão de potência, mês de março de 2014, horizonte de previsão de 15 minutos.	65
4.24	Curva do erro absoluto, mês de março de 2014, horizonte de previsão de 15 minutos.	65
4.25	Histograma do erro absoluto, mês de março de 2014, horizonte de previsão de 15 minutos.	66
4.26	Curva da previsão de potência, mês de março de 2014, horizonte de previsão de 30 minutos.	66
4.27	Curva do erro absoluto, mês de março de 2014, horizonte de previsão de 30 minutos.	67
4.28	Histograma do erro absoluto, mês de março de 2014, horizonte de previsão de 30 minutos.	67

4.29	Curvas da previsão de potência, mês de março de 2014, horizonte de previsão de 15 minutos.	69
4.30	Curva do erro absoluto, mês de março de 2014, horizonte de previsão de 15 minutos.	70
4.31	Histograma do erro absoluto, mês de março de 2014, horizonte de previsão de 15 minutos.	70
4.32	Curva da previsão de potência, mês de março de 2014, horizonte de previsão de 30 minutos.	71
4.33	Curva do erro absoluto, mês de março de 2014, horizonte de previsão de 30 minutos.	71
4.34	Histograma do erro absoluto, mês de março de 2014, horizonte de previsão de 30 minutos.	72
4.35	Curva da previsão de potência, mês de março de 2014, horizonte de previsão de 15 minutos.	74
4.36	Curva do erro absoluto, mês de março de 2014, horizonte de previsão de 15 minutos.	74
4.37	Histograma do erro absoluto, mês de março de 2014, horizonte de previsão de 15 minutos.	74
4.38	Curva da previsão de potência, mês de março de 2014, horizonte de previsão de 30 minutos.	75
4.39	Curva do erro absoluto, mês de março de 2014, horizonte de previsão de 30 minutos.	75
4.40	Histograma do erro absoluto, mês de março de 2014, horizonte de previsão de 30 minutos.	76
4.41	Curva da previsão de potência, mês de março de 2014, horizonte de previsão de 15 minutos.	78
4.42	Curva do erro absoluto, mês de março de 2014, horizonte de previsão de 15 minutos.	78
4.43	Histograma do erro absoluto, mês de março de 2014, horizonte de previsão de 15 minutos.	78
4.44	Curva da previsão de potência, mês de março de 2014, horizonte de previsão de 30 minutos.	79
4.45	Curva do erro absoluto, mês de março de 2014, horizonte de previsão de 30 minutos.	79
4.46	Histograma do erro absoluto, mês de março de 2014, horizonte de previsão de 30 minutos.	80
4.47	<i>Box plot</i> do MAPE dos modelos de previsão aplicados no horizonte de 15 minutos.	81

4.48	<i>Box plot</i> do MAPE dos modelos de previsão aplicados no horizonte de 30 minutos.	81
4.49	Curvas da previsão de potência, mês de março de 2014, horizonte de previsão de 15 minutos.	82
4.50	Curva do erro absoluto, mês de março de 2014, horizonte de previsão de 15 minutos.	83
4.51	Histograma do erro absoluto, mês de março de 2014, horizonte de previsão de 15 minutos.	83
4.52	Curva da previsão de potência, mês de março de 2014, horizonte de previsão de 30 minutos.	84
4.53	Curva do erro absoluto, mês de março de 2014, horizonte de previsão de 30 minutos.	84
4.54	Histograma do erro absoluto, mês de março de 2014, horizonte de previsão de 30 minutos.	85
4.55	Curvas da previsão de potência, mês de março de 2014, horizonte de previsão de 15 minutos.	86
4.56	Curva do erro absoluto, mês de março de 2014, horizonte de previsão de 15 minutos.	86
4.57	Histograma do erro absoluto, mês de março de 2014, horizonte de previsão de 15 minutos.	87
4.58	Curva da previsão de potência, mês de março de 2014, horizonte de previsão de 30 minutos.	87
4.59	Curva do erro absoluto, mês de março de 2014, horizonte de previsão de 30 minutos.	88
4.60	Histograma do erro absoluto, mês de março de 2014, horizonte de previsão de 30 minutos.	88
4.61	Curvas da previsão de potência, mês de maio de 2014, horizonte de previsão de 15 minutos.	90
4.62	Curva do erro absoluto, mês de maio de 2014, horizonte de previsão de 15 minutos.	90
4.63	Histograma do erro absoluto, mês de maio de 2014, horizonte de previsão de 15 minutos.	91
4.64	Curva da previsão de potência, mês de maio de 2014, horizonte de previsão de 30 minutos.	91
4.65	Curva do erro absoluto, mês de maio de 2014, horizonte de previsão de 30 minutos.	92
4.66	Histograma do erro absoluto, mês de maio de 2014, horizonte de previsão de 30 minutos.	92

4.67	Curvas da previsão de potência, mês de maio de 2014, horizonte de previsão de 15 minutos.	94
4.68	Curva do erro absoluto, mês de maio de 2014, horizonte de previsão de 15 minutos.	94
4.69	Histograma do erro absoluto, mês de maio de 2014, horizonte de previsão de 15 minutos.	95
4.70	Curva da previsão de potência, mês de maio de 2014, horizonte de previsão de 30 minutos.	95
4.71	Curva do erro absoluto, mês de maio de 2014, horizonte de previsão de 30 minutos.	96
4.72	Histograma do erro absoluto, mês de maio de 2014, horizonte de previsão de 30 minutos.	96
4.73	Curva de carga com maior registro de potência no período seco.	102
4.74	Curva de carga com maior registro de potência no período úmido.	102
4.75	Potência ativa e erro absoluto nos intervalos de pico dos meses de março e outubro de 2014.	105
4.76	Potência ativa e erro absoluto nos intervalos de pico dos meses de dezembro de 2014 e fevereiro de 2015.	105
4.77	Potência ativa e erro absoluto nos intervalos de pico dos meses de novembro de 2014 e fevereiro de 2015.	106
4.78	Potência ativa e erro absoluto no horário de ponta dos meses de agosto de 2014 e fevereiro de 2015.	107

Lista de Tabelas

3.1	Legenda do mapa da Figura 3.1.	33
3.2	Lista do Grupos Motor-Gerador da universidade.	34
3.3	Formatação dos dados da memória de massa fornecida pela fornecedora de energia local.	35
3.4	Parâmetros da Potência Ativa Instantânea (março de 2014 a março de 2015)	36
4.1	Exemplo do resultado da previsão de potência utilizando o método de persistência.	48
4.2	Configuração das redes <i>Feedforward</i> para o horizonte de 15 minutos.	51
4.3	Configuração das redes <i>Feedforward</i> para o horizonte de 30 minutos.	51
4.4	Desempenho da rede RBF ao aumentar os neurônios na camada oculta para 250 nos dois horizontes de previsão.	54
4.5	Configuração das Redes RBF	54
4.6	Configuração das Redes RBF	55
4.7	Exemplo dos processos de busca exaustiva.	55
4.8	Melhores configurações das redes em cada processo de busca no horizonte de 15 minutos.	57
4.9	Melhores configurações das redes em cada processo de busca no horizonte de 30 minutos.	57
4.10	Configuração das ESNs de menor MSE.	57
4.11	Configuração das redes ESN.	58
4.12	Erros da Previsão para o horizonte de 15 minutos	59
4.13	Erros da Previsão para o horizonte de 30 minutos	59
4.14	Erros da Previsão para o horizonte de 15 minutos	64
4.15	Erros da Previsão para o horizonte de 30 minutos	64
4.16	Erros da Previsão das redes <i>feedforward</i> para o horizonte de 15 minutos	68
4.17	Erros da Previsão das redes <i>feedforward</i> para o horizonte de 30 minutos	69
4.18	Erros da Previsão das redes de base radial para o horizonte de 15 minutos,	72

4.19 Erros da Previsão das redes de base radial para o horizonte de 30 minutos,	73
4.20 Erros da previsão para as ESNs no horizonte de 15 minutos	76
4.21 Erros da previsão para as ESNs no horizonte de 30 minutos	77
4.22 Erros da Previsão do modelo SARIMA para o horizonte de 15 minutos	82
4.23 Erros da Previsão do modelo SARIMA para o horizonte de 30 minutos	82
4.24 Erros da Previsão das redes <i>Feedforward</i> para o horizonte de 15 minutos	85
4.25 Erros da Previsão das redes <i>Feedforward</i> para o horizonte de 30 minutos	85
4.26 Erros da Previsão do modelo ARIMA para o horizonte de 15 minutos	89
4.27 Erros da Previsão do modelo ARIMA para o horizonte de 30 minutos	89
4.28 Erros da Previsão das redes <i>Feedforward</i> para o horizonte de 15 minutos	93
4.29 Erros da Previsão das redes <i>Feedforward</i> para o horizonte de 30 minutos	93
4.30 Tabela com o MAPE de todos os métodos do Estudo de Caso 1 para o horizonte de 15 e 30 minutos.	97
4.31 Tabela com o MAPE de todos os métodos do Estudo de Caso 2 para o horizonte de 15 e 30 minutos.	97
4.32 Tabela com o MAPE de todos os métodos do Estudo de Caso 3 para o horizonte de 15 e 30 minutos.	98
4.33 Visão geral dos dados e componentes do trabalho	99
4.34 Resultados da previsão no horizonte de 1 hora a frente da fonte [8] . .	99
4.35 Visão geral dos dados e componentes do trabalho	100
4.36 Resultados da previsão no horizonte de 1 hora a frente da fonte [23] .	100
4.37 Maiores registros de demanda nos períodos seco e úmido em horários de ponta e fora de ponta.	103
4.38 Demandas contratadas pela universidade definidas com base na análise dos dados.	104
4.39 Erros absolutos máximos da previsão nos horários fora de ponta onde os picos são registrados.	104
4.40 Erros absolutos máximos da previsão nos horários de ponta.	107
4.41 Cinco maiores registros de potência em todos os conjuntos de teste durante o horário de ponta.	109
4.42 Demandas contradas após o estudo feito com os modelos de previsão de potência.	110
4.43 Resumo dos cálculos econômicos por período do ano e por posto diário.	113

Lista de Abreviações e de Símbolos

Abreviações

ACF *Auto Correlation Function* - Função de Autocorrelação

ANEEL Agência Nacional de Energia Elétrica

AR *Autoregressive* - Auto-Regressivo

ARIMA *Autoregressive Integrated Moving Average* - Auto-regressivo Integrado de Média Móvel

BP *Backpropagation* - Retropropagação

BPTT *Backpropagation Through Time* - Retropropagação através do Tempo

BR *Bayesian Regularization* - Regularização Bayesiana

ESN *Echo State Networks* - Redes Neurais com Estados de Eco

ESP *Echo State Property* - Propriedade de Estados de Eco

FF *Feedforward* - Alimentada para Frente

FNN *Feedforward Neural Network* - Redes Alimentadas Para Frente

GLD Gerenciamento Pelo Lado da Demanda

GM *Grey Model*

GMG Grupo Motor-Gerador

GPSO *Global Best Particle Swarm Optimization* - Melhor Partícula Global de Otimização de Enxame

GW *Gigawatt*

IA Inteligência Artificial

LM *Levenberg-Marquadt*

LTLF *Long-Term Load Forecasting* - Previsão de Potência de Longo Prazo

MAE *Mean Absolute Error* - Erro Médio Absoluto

MAPE *Mean Absolute Percentage Error* - Erro Médio Absoluto Percentual

MLP *Multi Layer Perceptron* - Perceptron Multi-Camadas

MSE *Mean Squared Error* - Erro Médio Quadrático

MTLF *Medium-Term Load Forecasting* - Previsão de Potência de Médio Prazo

MW *Megawatt*

OPLS *Orthonormal Partial Least Squares* - Modelo de Mínimos Quadrados Parciais Ortonormais

PACF *Auto Correlation Partial Function* - Função de Autocorrelação Parcial

PCA *Principal Component Analysis* - Análise de Componentes Principais

PSO *Particle Swarm Optimization* - *Otimização de Enxame de Partículas*

RBF *Radial Basis Function* - Função de Base Radial

RBFINN *Radial Basis Function Neural Network* - Redes Neurais de Função de Base Radial

RF *Random Forest*

RNA Redes Neurais Artificiais

RNCL *Regularized Negative Correlation Learning* - Método de Aprendizagem por Regularização da Correlação Negativa

RNR *Recurrent Neural Network* - Rede Neural Recorrente

RTRL *Real Time Recurrent Learning* - Aprendizado Recorrente em Tempo Real

SARIMA *Seasonal Autoregressive Integrated Moving Average* - Auto-Regressivo Sazonal Integrado de Média Móvel

STLF *Short-Term Load Forecasting* - Previsão de Potência de Curto Prazo

SVM *Support Vector Machine* - Máquinas de Vetor de Suporte

Símbolos

Δx_t Resíduo da Primeira Diferença da Série

Δ^n Operador da n-ésima diferença

Δt Intervalo de Tempo

\mathbb{R} Conjunto dos Números Reais

\mathbf{W} Matriz de Pesos Recorrentes

$\phi(B)$ Operador Autorregressivo

ϕ_{hh} Função de Autocorrelação Parcial

$\Phi_P(B^s)$ Operador Autorregressivo Sazonal

ρ_t Função de Autocorrelação

$\theta(B)$ Operador de Médias Móveis

$\Theta_P(B^s)$ Operador de Média Móvel Sazonal

B Operador de Atraso

w_t Ruído Branco

Capítulo 1

Introdução

O desenvolvimento econômico depende da disponibilidade da energia elétrica, visto que a maioria das indústrias depende diretamente dela [1]. Dispor de uma fonte de energia barata, contínua e confiável é um dos pontos mais importantes na manutenção da atividade industrial.

A previsão de potência possui um papel importante nas tarefas de otimização, gerenciamento, agendamento de paradas, compra e venda de energia e operações de despacho em sistemas de potência. Estas atividades são facilitadas quando está disponível uma estimativa confiável da demanda de energia futura em diferentes intervalos de tempo [2].

A maioria dos trabalhos envolvendo a previsão de demanda de energia elétrica é focada nas áreas de transmissão e distribuição de potência em grande escala (MW e GW) [3], [4], [5].

Devido aos altos preços da energia em todo o país, houve um fomento por parte de muitas empresas nos investimentos em fontes alternativas de energia elétrica. Em empreendimentos que utilizam os diversos sistemas de microgeração, a integração dessas tecnologias ao sistema elétrico é feita através das redes inteligentes, onde o gerenciamento da energia é feito em baixa tensão [6]. Nesses empreendimentos é muito importante que seja feito o gerenciamento da energia gerada disponível.

As técnicas de otimização do consumo de energia mais aplicadas nesse tipo de sistema são: o gerenciamento pelo lado da demanda (GLD) e a previsão de potência. Na primeira, busca-se alterar o perfil da carga em um determinado horário, remanejando as cargas para um período do dia mais favorável à utilização das mesmas [7]. Na segunda, dados de potência ativa são pré-processados e utilizados para realizar previsão em intervalos de tempo definidos [8]. Propor um modelo preditor eficiente é uma tarefa desafiadora, pois fatores como a meteorologia, o impacto humano e eventos sociais ou culturais em um dia podem alterar muito a curva de carga de um determinado local [8].

Muitas são as pesquisas relacionadas à previsão de séries temporais de potência

e inúmeras são as metodologias aplicáveis neste cenário. Nagy et al. [9] sugere um conjunto aditivo de árvore generalizada para prever geração de energia solar e eólica. Yuan et al. [10] utiliza o modelo auto-regressivo integrado de média móvel (ARIMA), modelo cinza (do inglês *Grey Model*) GM(1,1) e modelo híbrido para prever o consumo de energia primário na China. Fumo e Biswas et al. [11] aplicam análise por regressão linear para prever o consumo de energia em casas. Haydari et al [12] apresenta um modelo de previsão de demanda de curta duração usando um sistema adaptativo de inferência neuro-fuzzy. Zhang et al [13] aplica regressão de vetor de suporte para estimar o consumo de energia.

No cenário mais atual, S. Hadri et al. [14] implantaram uma plataforma baseada em *IoT* e *Big Data* para a coleta dos dados de potência em tempo próximo ao real e utilizaram métodos como ARIMA, SARIMA, *XGBoost*, *Random Forest* (RF) e *Long Short-Term Memory* para realizar previsão de potência de curto prazo. Gordillo-Orquera, R. et al. [15] realizaram previsão de potência no horizonte de 1 ano em um hospital e no centro de atenção primária associado utilizando técnicas não supervisionadas combinando a análise de componentes principais (PCA) com um modelo auto-regressivo (AR) e supervisionadas usando o modelo de mínimos quadrados parciais ortonormais (OPLS). Nepal, B. et al. [16] realizaram previsão de picos de carga em construções universitárias utilizando um modelo híbrido de técnicas de agrupamento e ARIMA. Dagdougui, H. et al. [17] realizaram previsão de potência em horizontes de uma hora e um dia a frente usando redes neurais artificiais e avaliaram a performance do modelo proposto com diferentes algoritmos de aprendizagem, *Bayesian Regularization* (BR) e *Levenberg-Marquardt* (LM). Kim, Y., Son, H. e Kim, S. [18] apresentam um estudo de previsão de pico de carga para uma instituição de ensino usando ARIMA, ARIMA-GARCH, suavização exponencial e redes neurais artificiais.

No âmbito das diversas metodologias e modelos, o cenário fica bastante dividido entre as técnicas baseadas em Inteligência Artificial (IA) e técnicas estatísticas. As técnicas estatísticas certamente são a primeira escolha quando trata-se de problemas que envolvem o estudo de séries temporais, por propor modelos que se baseiam no estudo dos padrões e tendências da série. No âmbito da IA, destacam-se as redes neurais, que possuem vasta gama de aplicações tanto em processos de classificação quanto de previsão, além de mostrarem resultados muito bons quando comparados a outras técnicas [19], [20], [21].

Os modelos de redes neurais onde a propagação dos dados ocorre apenas para frente não são capazes de representar a dinâmica de sistemas não lineares com perfil temporal, mas este fato não os exclui como alternativa de solução para o problema, pois as séries temporais podem ser aplicadas com atrasos temporais nas redes para ajudar a modelar a tendência não linear dos dados.

Nessa dissertação são aplicados métodos estatísticos e de inteligência artificial para realizar previsões de demanda de curto prazo, em intervalos de 15 e 30 minutos a frente. Este trabalho tem o intuito de investigar a possibilidade de economia nos contratos de demanda da universidade propondo um sistema preditor de potência que irá atuar durante os dias de semana.

1.1 Objetivo

O objetivo deste trabalho consistiu em desenvolver modelos estatísticos e de IA para realizar previsão de potência de curto prazo (em intervalos de 15 e 30 minutos a frente) utilizando dados de potência ativa das instalações de uma universidade propondo diferentes arquiteturas e também avaliou o efeito da combinação de modelos de redes neurais para a qualidade da previsão.

Os objetivos específicos desse trabalho incluem:

- Aplicação de ferramentas de processamento digital de sinais para condicionamento do conjunto de dados, como a normalização e o tratamento dos *outliers*;
- Utilização de técnicas estatísticas através da análise das funções de autocorrelação (ACF) e autocorrelação parcial (PACF) para identificação do modelo de séries temporais e definição dos parâmetros de entrada dos preditores;
- Construção de modelos de previsão baseados em estatística e inteligência artificial usando atrasos temporais em três estudos de caso para constatar a melhor forma de entrar com os registros temporais nos preditores e obter os melhores resultados;
- Avaliar estatisticamente o desempenho dos preditores propostos utilizando o erro médio quadrático, erro médio absoluto percentual, erro médio absoluto e visualização de gráfico *box plot*;
- Propor a melhor forma de entrar com os dados nos preditores e realizar previsões e trazer o melhor caso para avaliar os benefícios da previsão de potência em um cenário de aplicação real.

1.2 Impactos e Contribuições

1.2.1 Científicos

Essa proposta de dissertação buscou proporcionar um estudo comparativo entre técnicas de previsão de séries temporais de potência. Tendo em vista que os dados

utilizados foram de uma universidade que possui as diversas áreas da engenharia, este trabalho serviu de base para a implementação de projetos de gerenciamento da energia elétrica e para os estudos de processamento de sinais envolvendo eficiência energética e previsão de séries temporais de potência.

1.2.2 Tecnológicos

Como aspecto tecnológico a ser abordado está o desenvolvimento de algoritmos próprios em MATLAB, que implementam as rotinas de redes neurais artificiais para previsão de séries temporais de potência, acarretando em contribuição para a comunidade acadêmica que busca otimizar problemas relacionados à eficiência energética utilizando séries temporais de dados com caráter estocástico.

1.3 Organização do Documento

Este documento está organizado conforme descrito a seguir:

No Capítulo 2 é apresentada uma revisão bibliográfica sobre previsão de potência e sobre os métodos de previsão estatísticos e de inteligência artificial que serão aplicados no trabalho. No Capítulo 3, a metodologia do trabalho é descrita, desde a aquisição dos dados, pré-processamento, identificação do modelo de séries temporais até a configuração de cada modelo em cada estudo de caso. No Capítulo 4, são apresentados os resultados obtido da previsão em cada estudo de caso conforme a metodologia proposta. No Capítulo 5 as conclusões e perspectivas futuras do trabalho são apresentadas.

Capítulo 2

Revisão Bibliográfica

Neste capítulo, é feita uma breve introdução sobre previsão de potência, séries temporais e uma revisão mais aprofundada dos métodos estatísticos e de IA aplicados no trabalho.

2.1 Previsão de Potência

A previsão de potência em sistemas elétricos pode ser feita em fração de uma hora, para propósitos operacionais ou até dez anos no futuro, para fins de planejamento [1].

2.1.1 Tipos de Previsão

A previsão de potência é usualmente classificada em três categorias, são elas [22]:

- Previsão de potência de curto prazo (STLF, do inglês *Short-Term Load Forecasting*): na qual o horizonte de previsão é menor do que um dia;
- Previsão de potência de médio prazo (MTLF, do inglês *Medium-Term Load Forecasting*): na qual o horizonte de previsão é entre um dia e um ano;
- Previsão de potência de longo prazo (LTLF, do inglês *Long-Term Load Forecasting*): com horizonte de previsão entre um ano e dez anos.

A previsão de potência de curto prazo é utilizada no planejamento e funcionamento diário dos sistemas elétricos, visando segurança, continuidade, otimização e economia. A de médio prazo é utilizada na programação das manutenções e coordenação das geradoras, hidráulicas e térmicas. E por fim, a de longo prazo é utilizada quando o objetivo é expandir o sistema elétrico [2].

2.1.2 Fatores Relevantes

As cargas elétricas são influenciadas por diversos fatores, dentre eles [2]:

- Fatores Climáticos: determinados pela temperatura média, umidade, velocidade do vento, entre outros;
- Fatores Socioeconômicos: determinados pela renda, índices de empregabilidade e padrão econômico das residências;
- Fatores Temporais: determinados pela hora do dia, dia da semana, finais de semana, estações do ano e feriados;
- Fatores Demográficos: determinados pela quantidade de habitantes por quilômetro quadrado e distribuição por faixas etárias;
- Fatores Aleatórios: determinados por eventos não previstos, tais como a qualidade do fornecimento da energia, manutenções não programadas, greves, etc. Eventos que provoquem a evasão das pessoas de determinado local em um período ou dia.

Os fatores socioeconômicos e demográficos influenciam de forma direta a carga.

Fatores temporais e climáticos tem forte influência nas previsões de curto prazo, pois podem alterar muito a curva de carga de um local em um intervalo curto de tempo. Dependendo do local de estudo, o aumento da temperatura pode aumentar a carga devido ao uso aos aparelhos de ar condicionados ou diminuir a carga devido a redução do uso de aparelhos aquecedores.

A previsão de potência de curto prazo é muito influenciada pelos fatores aleatórios, pois são fatores imprevisíveis que podem mudar totalmente o perfil da carga de um local por tempo indeterminado.

2.1.3 Métodos de Previsão

A maior parte dos métodos de previsão utiliza aproximações estatísticas ou algoritmos de inteligência artificial [23]. Os métodos estatísticos necessitam estabelecer um conhecimento prévio de algumas características do sistema para serem aplicados, já os modelos de inteligência artificial não necessitam de uma modelagem prévia pois possuem a fase de treinamento por aprendizado.

Dentre os métodos mais utilizados, estão a suavização exponencial e métodos *Holt Winters*, Redes Neurais Artificiais e mais recentemente Máquinas de Vetor de Suporte (SVM) [24], [23].

Uma boa introdução a aplicação de séries temporais pode ser encontrada em *Brockwell and Davis* [25] e informações sobre técnicas diversas de previsão podem ser encontradas em *Feinberg and Genethliou* [26].

As Redes Neurais possuem aplicações nas diversas áreas das Ciências, muitas vezes em casos com dados reais. São também utilizadas para previsão nos diversos campos das Engenharias [23]. As Redes Neurais, quando treinadas para uma determinada tarefa, apresentam habilidade de extrair conhecimento e aprender a relação entre as variáveis observadas, podendo mostrar resultados expressivos na previsão de potência de curto período [27].

2.2 Séries Temporais

Uma Série Temporal é definida como um conjunto de observações quantitativas ou qualitativas arranjadas em ordem cronológica [28]. Nas análises dos dados de uma série, adota-se o tempo como uma variável discreta.

Considerando a natureza sequencial das observações, as séries temporais podem ser agrupadas nos seguintes tipos:

- **Contínuas:** Possuem infinitos valores entre dois limites de um intervalo qualquer;
- **Discretas:** Com registros apenas em tempos específicos, igualmente espaçados, podem ser geradas a partir de um processo de amostragem de uma série temporal contínua em intervalos de tempo iguais a Δt . Processo essencial para a possibilidade de modelagem e predição da série.

Dado o conjunto $T = \{t : t_1 < t < t_2\}$ uma série temporal contínua pode ser descrita por: $\{X(t) : t \in T\}$

Uma série temporal discreta pode ser representada pela forma genérica de uma sequência finita de valores de uma certa variável:

$$\mathbf{x} \in \mathbb{R}, \{x(1), x(2), \dots, x(N)\} \quad (2.1)$$

sendo N a quantidade de amostras observadas.

As séries temporais podem ser decompostas nas seguintes componentes [29]:

1. **Tendência:** mudança do nível médio da série temporal a longo prazo;
2. **Sazonal:** alteração periódica que ocorre em períodos de tempo determinados, como exemplo, fenômenos naturais decorrentes de características meteorológicas;

3. **Cíclica:** oscilações recorrentes, mas sem periodicidade determinada ou regular, deterministicamente previsíveis;
4. **Aleatória:** modificação de natureza imprevisível.

As séries temporais podem ser classificadas como [30]:

1. **Determinísticas:** valores futuros podem ser determinados com precisão e absoluta certeza, sem a existência de componente aleatória;
2. **Estocásticas:** comportamento irregular gerado por um ou mais componentes aleatórios existentes no sistema.

Ao se analisar uma determinada série temporal, deve-se atentar para suas propriedades, classificação e determinação das relações de dependência existentes, apontando para a escolha de um modelo satisfatório que realize a previsão de valores futuros com base nos valores passados observados.

2.3 Métodos Estatísticos

2.3.1 Modelo de Previsão *Naive*

O preditor *Naive* é um preditor trivial que realiza previsão utilizando o valor mais atual da série. É um método que aumenta o erro da previsão a medida em que o horizonte é aumentado. Em publicações na área de previsão de séries temporais, é um método utilizado para quantificar a melhora dada por técnicas mais complexas [23].

O modelo *Naive* pode ser definido da seguinte forma:

$$x_{t-S} = x_t \quad (2.2)$$

Este modelo entrega como previsão no tempo t , o valor observado exatamente no período de S passos anteriores.

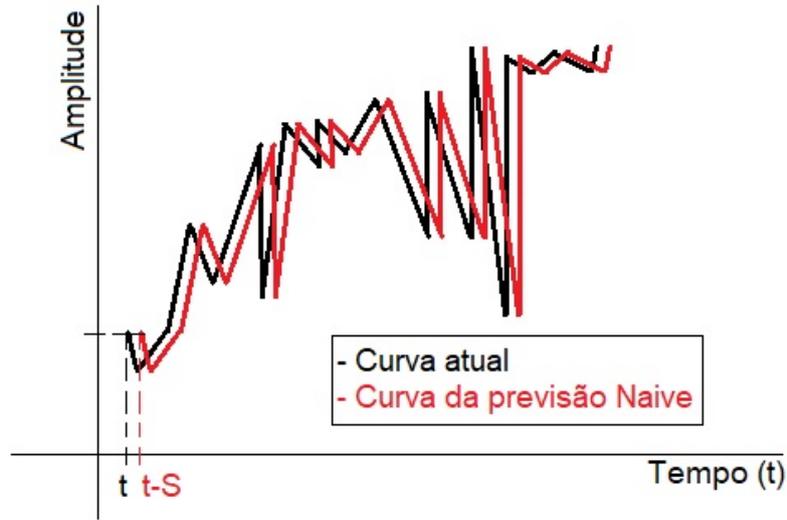
A Figura 2.1 ilustra graficamente o processo, percebe-se que a curva de previsão *Naive* nada mais é do que a própria série deslocada de S passos a frente.

2.3.2 Modelo AR (p)

No modelo auto-regressivo, a série temporal $x(t)$ é composta por seus valores passados e pelo ruído aleatório w_t . Dessa forma, um modelo AR(p) pode ser descrito por:

$$x_t = \phi_1 x_{t-1} + \phi_2 x_{t-2} + \dots + \phi_p x_{t-p} + w_t \quad (2.3)$$

Figura 2.1: Previsão *Naive*.



Fonte: Própria.

onde x_t é estacionário, e $\phi_1, \phi_2, \dots, \phi_p$ são constantes (ϕ_p). Caso a média de x_t na equação 2.3 seja representada por μ e não seja zero, x_t pode ser substituído por $x_t - \mu$ em 2.3,

$$x_t - \mu = \phi_1(x_{t-1} - \mu) + \phi_2(x_{t-2} - \mu) + \dots + \phi_p(x_{t-p} - \mu) + w_t,$$

ou

$$x_t = \alpha + \phi_1 x_{t-1} + \phi_2 x_{t-2} + \dots + \phi_p x_{t-p} + w_t, \quad (2.4)$$

sendo $\alpha = \mu(1 - \phi_1 - \dots - \phi_p)$.

Neste ponto, com o objetivo de simplificar ainda mais a Equação 2.3, pode-se definir o operador de atraso como:

$$Bx_t = x_{t-1}$$

e isso pode ser estendido para potências de B , sendo: $B^2 x_t = B(Bx_t) = Bx_{t-1} = x_{t-2}$ e assim por diante. Então:

$$B^k x_t = x_{t-k} \quad (2.5)$$

O modelo AR(p) pode ser reescrito adicionando-se o operador de atraso $B = x_t - x_{t-1}$, da seguinte forma:

$$1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p = \phi(B) \times B_t = a_t \quad (2.6)$$

Uma forma útil de escrever o modelo AR(p) usando o operador de atraso é:

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)x_t = w_t \quad (2.7)$$

ou ainda

$$\phi(B)x_t = w_t \quad (2.8)$$

O operador autorregressivo pode ser definido com a seguinte equação:

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p \quad (2.9)$$

2.3.3 Modelo de Médias Móveis - MA (q)

O nome médias móveis vem do fato de que $x(t)$ é uma função soma algébrica ponderada dos w_t (um processo aleatório com média μ e variância σ_a^2) que se movem no tempo.

$$x_t = w_t + \theta_1 w_{t-1} + \theta_2 w_{t-2} + \dots + \theta_q w_{t-q}, \quad (2.10)$$

em que existem q atrasos na média móvel e $\theta_1, \theta_2, \dots, \theta_q (\theta_q \neq 0)$ são os parâmetros.

De forma alternativa, pode-se escrever o processo MA(q) da seguinte forma:

$$x_t = \theta(B)w_t \quad (2.11)$$

O operador de médias móveis pode então ser definido:

$$\theta(B) = 1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q \quad (2.12)$$

2.3.4 Modelo de Previsão ARMA (p,q)

Uma série temporal é dita ARMA(p,q) se for estacionária e se:

$$x_t = \phi_1 x_{t-1} + \dots + \phi_p x_{t-p} + w_t + \theta_1 w_{t-1} + \dots + \theta_q w_{t-q}, \quad (2.13)$$

$\phi \neq 0$, $\theta_q \neq 0$ e $\sigma_w^2 > 0$. Os parâmetros p e q são chamados de ordens autorregressivas e de médias móveis, respectivamente. Caso x_t tenha uma média $\mu \neq 0$, faz-se $\alpha = \mu(1 - \phi_1 - \dots - \phi_p)$ e o modelo pode ser escrito da seguinte forma:

$$x_t = \alpha + \phi_1 x_{t-1} + \dots + \phi_p x_{t-p} + w_t + \theta_1 w_{t-1} + \dots + \theta_q w_{t-q} \quad (2.14)$$

Relembrando os modelos anteriores, quando $q = 0$, o modelo é chamado de autorregressivo de ordem p , AR(p), e quando $p = 0$, o modelo é chamado de modelo

de média móvel de ordem q , $MA(q)$. O modelo ARMA pode ser equacionado usando o operador autorregressivo 2.9 e o operador de médias móveis 2.12, da seguinte forma:

$$\phi(B)x_t = \theta(B)w_t \quad (2.15)$$

2.3.5 Modelo de Previsão ARIMA

Um modelo de séries temporais é certamente a primeira escolha quando se trata de algum problema de previsão. O modelo ARIMA (auto-regressivo integrado de médias móveis, do inglês *autoregressive integrated moving average*) considera a não estacionariedade dos dados e foi apresentado no trabalho de *Box e Jenkins* [31]. Nesse modelo, valores futuros de um determinado conjunto de dados são representados como uma função linear das observações passadas mais um erro (com média zero e variância finita) relacionado. O modelo $ARIMA(p, d, q)$ é uma ampliação do modelo ARMA, incluindo nele diferenciação. Neste ponto, dá-se uma pausa no modelo ARIMA para esclarecer o conceito de diferenciação de uma série temporal.

Diferenciação de Séries Temporais

A diferenciação é uma técnica aplicada nos dados das séries temporais a fim de torná-la estacionária [31]. Sendo uma série temporal estacionária, suas propriedades não dependem do tempo em que a mesma está sendo observada [32]. De forma simples, a primeira diferenciação de uma série pode ser equacionada da seguinte forma:

$$\Delta x_t = (1 - B)x_t = x_t - x_{t-1} \quad (2.16)$$

onde Δx_t representa o resíduo da primeira diferença da série, x_t representa a série temporal e x_{t-1} o primeiro atraso da série.

O processo de diferenciação elimina mudanças no nível da série temporal, removendo tendências e sazonalidade e como consequência, estabiliza a média da mesma [31]. Dentro deste processo, a diferenciação sazonal também é realizada, tomando a diferença entre uma observação e a observação onde o caráter sazonal se repete. A diferenciação sazonal pode ser equacionada da seguinte forma:

$$\Delta x_t = (1 - B^s)x_t = x_t - x_{t-s} \quad (2.17)$$

onde s é a observação em que o caráter sazonal se repete.

Os dados da série diferenciada são utilizados para a estimar um modelo ARIMA.

Um processo x_t é dito $ARIMA(p, d, q)$ se:

$$\Delta^d x_t = (1 - B)^d x_t$$

é ARMA(p, q). O modelo ARIMA(p, d, q) pode ser expresso como:

$$\phi(B)(1 - B)^d x_t = \theta(B)w_t \quad (2.18)$$

Vistos todos estes conceitos, é importante ter o conhecimento que a variabilidade de muitos processos físicos, biológicos e econômicos possuem componentes sazonais [32]. Logo, são introduzidos polinômios autorregressivos e de médias móveis que identificam atrasos sazonais. Com isso o modelo ARMA(p, q) assume a seguinte forma:

$$\Phi_P(B^s)x_t = \Theta_Q(B^s)w_t \quad (2.19)$$

com o equacionamento dos seguintes operadores:

$$\Phi_P(B^s) = 1 - \Phi_1(B^s) - \Phi_2(B^{2s}) - \dots - \Phi_P(B^{Ps}) \quad (2.20)$$

e

$$\Theta_Q(B^s) = 1 + \Theta_1(B^s) - \Theta_2(B^{2s}) - \dots - \Theta_Q(B^{Qs}) \quad (2.21)$$

são o operador autorregressivo sazonal e o operador de média móvel sazonal de ordens P e Q , respectivamente, com período sazonal s .

Pode-se então introduzir o conceito de diferenciação sazonal. Uma diferenciação sazonal de ordem D é definida como:

$$\nabla_s^D x_t = (1 - B^s)^D x_t \quad (2.22)$$

onde $D = 1, 2, \dots$, pode assumir valores inteiros positivos. Tipicamente com $D = 1$ é suficiente para obter estacionariedade sazonal [32]. Incorporando essas idéias a um modelo geral nos leva à seguinte definição:

O modelo multiplicativo sazonal autorregressivo integrado de médias móveis ou **SARIMA** é dado por:

$$\Phi_P(B^s)\phi(B)\nabla_s^D \nabla^d x_t = \delta + \Theta_Q(B^s)\theta(B)w_t \quad (2.23)$$

onde w_t é o ruído branco gaussiano. O modelo geral é denotado como **ARIMA**(p, d, q) \times (P, D, Q) $_s$. Os componentes autorregressivos e de médias móveis são representados por $\phi(B)$ e $\theta(B)$ de ordens p e q respectivamente, e os componentes sazonais autorregressivos e de médias móveis por $\Phi_P(B^s)$ e $\Theta_Q(B^s)$ de ordens P e Q e os

componentes de diferenças sazonais $\nabla^d = (1 - B)^d$ e $\nabla_s^D = (q - B^s)^D$.

Identificação do Modelo

Uma forma comum de se identificar o modelo é analisar as funções de autocorrelação (*Autocorrelation Function - ACF*) e autocorrelação parcial (*Partial Autocorrelation Function - PACF*) da série, elas são ferramentas usadas para verificar o desempenho e a especificação dos modelos de séries temporais. A ACF descreve a correlação entre dois termos da série que ocorrem em tempos diferentes e pode ser equacionada da seguinte forma:

$$\rho_h = \text{corr}(X_t, X_{t+h}) \quad (2.24)$$

onde h é inteiro, tal que $-\infty \leq h \leq \infty$.

A PACF descreve a correlação entre dois valores da série desconsiderando a influência dos termos intermediários e pode ser equacionada da seguinte forma:

$$\phi_{hh} = \text{corr}(X_t - \hat{x}_t, X_{t+h} - \widehat{x_{t+h}}) \quad (2.25)$$

onde \hat{x}_t é o efeito linear de $x_{t+1}, \dots, x_{t+h-1}$ em X_t e $\widehat{x_{t+h}}$ é o efeito linear de $x_{t+1}, \dots, x_{t+h-1}$ em X_{t+h} .

Para identificar o modelo, relacionam-se os seguintes padrões das funções de ACF e PACF que classificam o comportamento das séries temporais [32]:

- Não estacionariedade: a ACF decai de forma lenta e a PACF exibe valor significativo (positivo ou negativo) no atraso 1;
- Não estacionariedade sazonal: a ACF é próxima de zero, exceto nos atrasos $s, 2s, \dots$ e também decai de forma lenta. A série pode se tornar estacionária através da diferenciação sazonal;
- Comportamento autorregressivo: a PACF é diferente de zero para os atrasos $1, 2, \dots, p$ e zero para os demais;
- Comportamento autorregressivo sazonal: a PACF é diferente de zero para os atrasos $s, 2s, \dots$ e zero para os demais;
- Comportamento média móvel: a ACF é diferente de zero para os atrasos $1, 2, \dots, q$ e zero para os demais;
- Comportamento média móvel sazonal: a ACF é diferente de zero para os atrasos $s, 2s, \dots$ e zero para os demais.

2.4 Métodos de Inteligência Artificial

2.4.1 Redes Neurais Artificiais

O cérebro humano é uma estrutura biológica complexa que inspira estudos em áreas como a biologia e a engenharia. Na engenharia, a busca pela construção de máquinas inteligentes leva naturalmente ao modelo do cérebro. Responsável pelo processamento de diversas informações e geração de respostas a elas, o cérebro humano motivou o desenvolvimento das redes neurais artificiais (RNAs). Elas foram inspiradas na estrutura e no funcionamento do sistema nervoso com o principal objetivo de entender o fenômeno da capacidade de aprendizado do cérebro na aquisição do conhecimento [33].

A procura por modelos computacionais matemáticos do sistema nervoso teve início em 1940. No ano de 1943, *McCulloch e Pitts* propuseram um modelo matemático de neurônio artificial em que os neurônios executavam funções lógicas simples, e cada um podia executar uma função diferente. Os dois mostraram que qualquer função que pudesse ser representada por uma combinação de funções lógicas poderia ser modelada por uma rede formada por esses neurônios [33]. As redes iniciais não possuíam capacidade de aprendizado.

O primeiro trabalho que tem ligação direta com o aprendizado foi apresentado por *Donald Hebb* em 1949. No trabalho, o aprendizado dos neurônios é feito através da variação dos pesos de entrada dos nós. A regra de *Hebb* foi posteriormente adaptada e hoje é utilizada em vários algoritmos de aprendizado [34].

Em 1958, *Frank Rosenblatt* mostrou através de sua teoria sobre os *perceptrons* que se fossem acrescentadas sinapses ajustáveis, as RNAs poderiam ser treinadas para classificar certos tipos de padrões. *Rosenblatt* descreveu uma topologia de RNA, as estruturas de ligação entre os nós e propôs um algoritmo para treinar a rede para executar determinados tipos de funções. O *perceptron* descrito por *Rosenblatt* possui três etapas de processamento [34]:

- Primeira: Etapa que recebe as entradas do exterior e possui conexões fixas (camada de entrada);
- Segunda: Etapa que recebe os impulsos da primeira através de conexões cuja eficiência de transmissão é ajustável (peso);
- Terceira: Etapa que recebe as saídas da anterior (saída).

Esse tipo elementar de *perceptron* comporta-se como um classificador de padrões, dividindo o espaço de entrada em regiões distintas para cada uma das classes existentes, sendo capaz de separar apenas dados linearmente separáveis.

As pesquisas na área das RNAs foram interrompidas em 1970 por diversos fatores. O principal fator foi a publicação do livro de *Minsky e Papert*, em 1969, no qual os autores apontaram limitação da rede *perceptron* a problemas linearmente separáveis [33]. O interesse pela área ressurgiu em 1980 com os computadores mais sofisticados, as novas propostas de arquiteturas de RNAs e os algoritmos de aprendizado mais sofisticados.

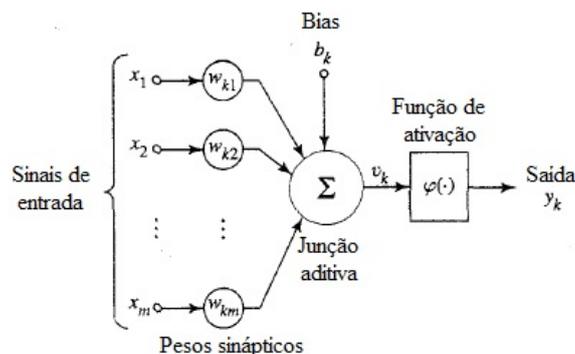
Componentes Básicos das RNAs

As RNAs possuem unidades de processamento simples, interconectadas que são chamadas de neurônios artificiais. Os neurônios computam funções matemáticas e são dispostos em uma ou mais camadas interligadas. Na maioria das estruturas, as conexões entre os neurônios possuem pesos associados que ponderam a entrada recebida por cada neurônio da rede [34]. Esses pesos podem assumir valores positivos ou negativos dependendo do comportamento da conexão. Em um processo de aprendizado, os pesos tem seus valores ajustados e codificam o conhecimento adquirido pela rede [34].

Os neurônios são unidades de processamento fundamentais para a operação das RNAs. A Figura 2.2 mostra o modelo de um neurônio artificial. Na imagem, pode-se identificar três elementos básicos de um modelo neuronal [35]:

1. Série de sinapses ou elos de conexão. Em uma iteração sináptica j , um sinal x_j conectado ao neurônio k é multiplicado pelo peso sináptico w_{kj} ;
2. Somador. Realiza o somatório dos sinais de entrada ponderados pelos pesos sinápticos;
3. Função de ativação. No modelo, é responsável por limitar a amplitude dos sinais de saída e dar o comportamento não linear do sistema preditor.

Figura 2.2: Modelo não linear de um neurônio.



Fonte: Adaptado de [36].

Na Figura 2.2, além dos elementos principais do modelo, nota-se o elemento *bias* (ou tendência), denotado por b_k . Este elemento é responsável por aumentar ou diminuir a entrada da função de ativação da rede.

Equacionando com base na Figura 2.2, o potencial de ativação de um neurônio k pode ser descrito da seguinte forma:

$$v_k = \sum_{j=1}^m w_{kj} x_j \quad (2.26)$$

e sua saída

$$y_k = \varphi(v_k + b_k) \quad (2.27)$$

onde x_1, x_2, \dots, x_m representam os sinais de entrada; $w_{k1}, w_{k2}, \dots, w_{km}$ representam os pesos sinápticos do neurônio k ; v_k é a combinação linear das entradas; b_k é o valor do termo *bias*; $\varphi(\cdot)$ é a função de ativação e y_k é o sinal de saída do neurônio artificial.

O modelo de neurônio foi proposto por *McCulloch e Pitts* e é uma simplificação do que se sabia sobre o neurônio biológico. Quando os neurônios são organizados em conjuntos e dispostos em uma ou mais camadas, cria-se uma Rede Neural Artificial. O número de camadas e de neurônios em cada camada, tipo de conexão entre os neurônios, e a topologia da rede classificam os tipos de arquiteturas das redes neurais [34].

Arquitetura

Uma Rede Neural Artificial é classificada por três características básicas, são elas [36]:

1. Modelo do neurônio que utilizam;
2. Arquitetura da RNA;
3. Algoritmo de treinamento ou aprendizado;

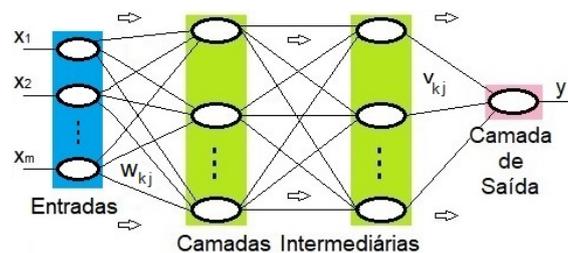
A arquitetura da RNA descreve as conexões internas entre neurônios e o algoritmo de aprendizado elabora a estratégia para ajustar os pesos sinápticos. Diversas são as arquiteturas de Redes Neurais Artificiais, citando algumas: Redes de Função de Base radial (RBF - *Radial Basis Function*), Redes Perceptron Multi-Camadas (MLP, do inglês *Multilayer Perceptron*), Redes de Hopfield [37] etc. Seguindo o conceito de Arquitetura, pode-se dividir as RNAs em duas vertentes: Redes Neurais Alimentadas para Frente (FNN - *Feedforward Neural Networks*), onde a dinâmica de transferência de informações ocorre apenas em um sentido e Redes Neurais Recorrentes (RNR),

onde a informação pode também retornar para camadas anteriores através dos laços de realimentação.

Redes Neurais Alimentadas para Frente Estas redes são compostas de três componentes básicos: uma camada de entrada, onde a rede recebe os dados; uma ou mais camadas ocultas, onde as características dos dados são extraídas e o mapeamento não linear dos sinais de entrada é feito através de conexões que são ponderadas pela matriz de pesos da camada; e uma camada de saída onde é apresentado o resultado é apresentado.

A Figura 2.3 representa uma rede multicamada alimentada para frente onde os círculos representam os neurônios, x_j as entradas, w_{kj} representam os pesos entre as entradas e as camadas ocultas e v_{kj} os pesos entre a última camada oculta e a camada de saída, os índices k e j representam a unidade de processamento e a camada onde estão. A camada de neurônios que gera os valores de saída é chamada de camada de saída e as demais camadas são denominadas camadas intermediárias, escondidas ou ocultas.

Figura 2.3: Exemplo de RNA multicamadas típica.



Fonte: Própria.

O processo de treinamento de uma Rede Neural Alimentada para Frente visa encontrar a melhor relação entrada/saída através do ajuste dos pesos sinápticos das camadas oculta e de saída. Quando o treinamento é finalizado, a rede entregará valores próximos aos desejados.

Com o ajuste dos pesos realizados, mapeiam-se os padrões de entrada em um único conjunto de sinais de saída. Este processo capacita essas redes a lidar com tarefas de classificação de padrões e aproximação de funções [35].

Em muitos problemas reais, existe a necessidade de que modelo seja capaz de memorizar os acessos históricos dos sinais de entradas e saídas e também dos estados internos da rede. Para tratar problemas que demandam memória é comum fornecer ao sistema propriedades dinâmicas que respondam a perturbações temporais, como por exemplo inserir laços de realimentação entre camadas e/ou neurônios [36].

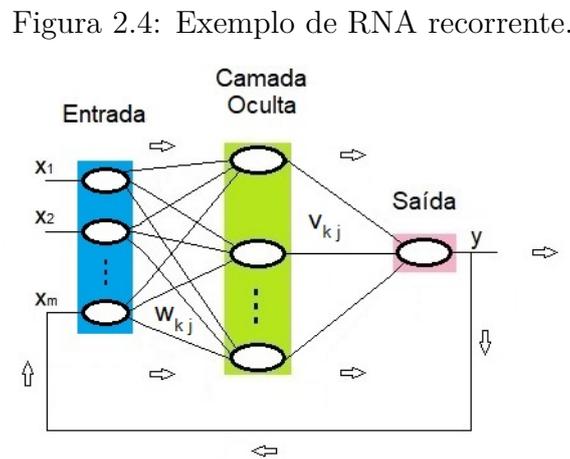
Redes Neurais Recorrentes Esse tipo de redes se diferencia das redes alimentadas para frente pois possuem pelo menos um laço de realimentação, e isso torna possível a transferência de informações entre neurônios na mesma camada, na camada anterior ou até ao próprio neurônio. A presença de laço ou laços de realimentação tem influência direta na capacidade de aprendizagem e no desempenho da rede pois concede a ela o comportamento de memorização e acesso a histórico dos sinais presentes.

As redes recorrentes, em sua grande maioria, compartilham as seguintes características [35]:

- Incorporam um perceptron de múltiplas camadas estático ou parte dele;
- Possuem a capacidade de mapeamento não linear do perceptron de múltiplas camadas.

Na Matemática, as redes neurais alimentadas para frente são funções e as redes neurais recorrentes são sistemas dinâmicos. O comportamento dinâmico não linear nas redes recorrentes é complexo e por isso, torna-se necessário ajustar delicadamente seus parâmetros para conseguir êxito na tarefa que está sendo realizada. Devido aos laços de recorrência, pequenas mudanças nos hiperparâmetros podem resultar numa dinâmica indesejada, desestabilizada e com rápido aumento do erro [36].

A Figura 2.4 representa uma rede recorrente.



Fonte: Própria.

No que diz respeito a aprendizado com supervisão, as redes recorrentes utilizam métodos que visam minimizar o erro entre as saídas e os valores desejados de forma iterativa. Alguns desses algoritmos são:

- Retropropagação através do Tempo (BPTT - *Backpropagation Through Time*) [38];
- Aprendizado Recorrente em Tempo Real (RTRL - *Real Time Recurrent Learning*) [39];

- Algoritmos de segunda ordem [40].

Ao executar algoritmos padrões de gradiente descendente em redes recorrentes é necessário calcular o gradiente da função de erro através das camadas intermediárias e também considerar a influência dos sinais de realimentação, o que os tornam complexos e de alto custo computacional [41]. A convergência lenta na etapa de aprendizado do algoritmo e a dificuldade na escolha dos parâmetros também são duas desvantagens relatadas [42].

Em meio a essas dificuldades, as Redes Neurais com Estados de Eco (ESN - *Echo State Networks*) possuem características que superam os detalhes no treino das Redes Neurais Recorrentes e foram apresentadas por [43]. A ESN possui a camada oculta denominada de *reservatório de dinâmicas*. Na ESN, os pesos das conexões sinápticas são inicializados de forma aleatória e os pesos da camada de saída são definidos pela combinação linear resultante das ativações desse reservatório. O segredo do processo de treino é manter fixo os pesos das conexões recorrentes do reservatório e ajustar apenas os pesos da camada de saída (utilizando métodos de mínimos quadrados). Essas redes possuem estrutura recorrente e são conhecidas por ter a etapa de treino muito rápida.

Aprendizado

A associação dos valores dos pesos que fazem o modelo obter melhor desempenho chama-se de ajuste dos parâmetros. Vários algoritmos tem sido propostos na literatura para este processo que, para problemas de predição de séries temporais, tem sua eficiência medida pela acurácia preditiva [34]. O ajuste dos parâmetros indica quando e como o valor de cada peso deve ser alterado. Esses algoritmos podem ser divididos em quatro grupos [33]:

1. Correção de erro: utilizados em aprendizado supervisionados, procura ajustar os pesos da rede de forma a minimizar os erros cometidos pela RNA.
2. Hebbiano: usados em aprendizado não supervisionado, seguem a regra de Hebb que diz que se dois neurônios estão simultaneamente ativos, a conexão entre eles deve ser reforçada.
3. Competitivo: utilizados em aprendizado não supervisionado, onde uma competição é estabelecida entre os neurônios para definir qual ou quais devem ter seus pesos ajustados, de forma que os neurônios vencedores são os que respondem mais fortemente ao objetivo apresentado aos seus terminais de entrada.
4. Termodinâmico (Boltzmann): são algoritmos estocásticos baseados em princípios observados na metalurgia.

Rede Perceptron Multicamadas

Uma alternativa para problemas não linearmente separáveis utilizando RNAs é adicionar uma ou mais camadas intermediárias de neurônios artificiais. É possível mostrar que uma rede com pelo menos uma camada intermediária pode implementar qualquer função contínua (é um aproximador universal) [44].

As redes MLP são redes com uma ou mais camadas intermediárias e uma camada de saída.

Algoritmo *Back-propagation*

O algoritmo compreende duas fases, uma fase para frente (*forward*) e uma fase para trás (*backward*), as quais são descritas abaixo [33]:

1. Fase para frente: a informação ponderada por suas conexões de entrada é recebida por cada um dos neurônios da primeira camada intermediária. Cada neurônio desta camada aplica função de ativação a sua entrada e produz um valor de saída que servirá de entrada para o neurônio da camada seguinte. Esse processo segue até o neurônio de saída produzir um valor, que é então comparado ao valor desejado para a saída do mesmo. A diferença entre o valor obtido e o valor desejado indica o erro cometido pela rede.
2. Fase para trás: o valor do erro do neurônio de saída do final da fase para frente é utilizado para ajustar os pesos da rede na fase para trás. O ajuste prossegue da camada de saída até a primeira camada intermediária. A Equação 2.28 ilustra como é feito o processo do ajuste dos pesos pelo algoritmo.

$$w_{kj}(t+1) = w_{kj}(t) + \eta x^j \delta_k \quad (2.28)$$

Na Equação 2.28, w_{kj} representa o peso entre um neurônio k e o j -ésimo atributo de entrada, δ_k indica o erro associado ao k -ésimo neurônio, x^j indica a entrada recebida por esse neurônio e η é a taxa de aprendizado.

Neste ponto, os valores de erro dos neurônios das camadas intermediárias precisam ser estimados, visto que apenas o erro do neurônio da camada de saída é conhecido. O algoritmo propõe estimar esses valores utilizando os erros observados nos neurônios da camada posterior. No equacionamento, a forma de calcular o erro depende da camada em que se encontra o neurônio, como pode ser visto na Equação 2.29.

$$\delta_k = \begin{cases} f'_a e_j, & \text{se } \eta_k \in c_{sai} \\ f'_a \sum w_{kj} \delta_j, & \text{se } \eta_k \in c_{int} \end{cases} \quad (2.29)$$

Na Equação 2.29, o erro de um neurônio de uma camada intermediária é estimado como a soma dos erros dos neurônios da camada seguinte, cujos terminais de entrada estão conectados a ele, ponderados pelo valor do peso associado a essas conexões. Sendo η_k o k -ésimo neurônio, c_{sai} a camada de saída, c_{int} a camada de intermediária, f'_a a derivada parcial da função de ativação do neurônio e e_k é o erro quadrático cometido pelo neurônio de saída, mostrado pela Equação 2.30.

$$e_l = \frac{1}{k} \sum_{q=1}^k (y_q - \hat{f}_q)^2 \quad (2.30)$$

Ainda na Equação 2.30, a derivada parcial define o ajuste dos pesos, utilizando o gradiente descendente da função de ativação. A derivada mede a contribuição de cada peso no erro da rede para a previsão de uma entrada x . Assim sendo, para um dado peso:

- Se a derivada for positiva: o peso está provocando um aumento da diferença entre a saída da rede e a saída desejada e sua magnitude deve ser reduzida para abaixar o erro.
- Se a derivada for negativa: o peso está contribuindo para que a saída do neurônio se aproxime da saída desejada e seu valor deve ser aumentado.

2.4.2 Redes Neurais de Função de Base Radial

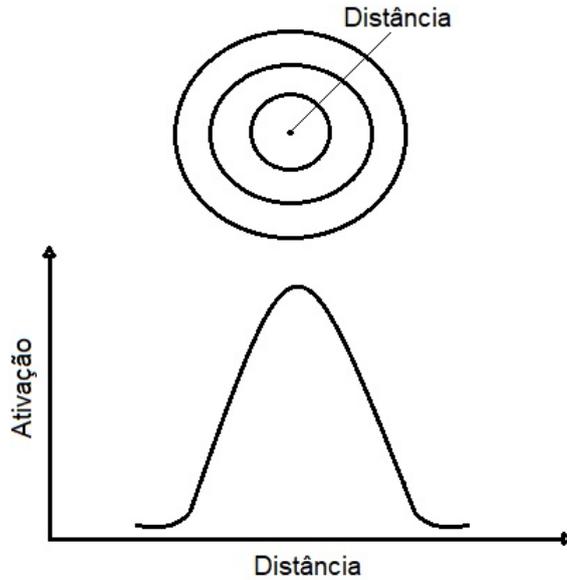
As Redes Neurais de Função de Base Radial (RBFNN, do inglês *Radial Basis Function Neural Network*) possuem estrutura parecida com a estrutura das redes alimentadas para frente (*feedforward*), são compostas de três camadas de neurônios. A primeira camada é a camada de entrada, que alimenta as entradas da camada intermediária ou oculta. Na segunda camada ou camada intermediária, os neurônios realizam mapeamentos não lineares através das funções de ativação que são centradas em um determinado ponto, com padrão circular e valor de raio definido. Nessa camada as Redes de Base Radial se diferem muito das demais redes [45].

A Figura 2.5 mostra a função de base radial centrada em um ponto e o padrão circular mapeado à medida em que se distancia do ponto centrado.

Nas RBFNNs os neurônios na camada intermediária são ativados por uma função de base radial e guardam um vetor centrado em um valor c que possui a mesma dimensão do vetor de entrada x [45].

Quando um vetor de entrada alimenta os neurônios da camada intermediária, cada nó de entrada calcula a distância euclidiana entre o dado de entrada e seu próprio centro. Essa distância d (Equação 2.31) é transformada e o neurônio produz seu valor de saída. O valor de saída é então ponderado e alimenta a terceira camada,

Figura 2.5: Distância radial e função de base radial.



Fonte: Própria.

a qual soma as entradas ponderadas. Por fim, a terceira camada de neurônios gera sua saída.

A distância Euclidiana entre o centro e o vetor de entrada \mathbf{x} é definida na Equação 2.31.

$$d = \|\mathbf{x}(t) - \mathbf{c}_j(t)\| \quad (2.31)$$

onde \mathbf{x} representa o vetor da entrada e \mathbf{c}_j o vetor do neurônio da camada intermediária.

A saída dos neurônios da camada intermediária pode ser gerada a partir de uma função de ativação não linear $h_j(t)$ como a da Equação 2.32.

$$h_j(t) = \exp\left(-\frac{\|\mathbf{x}(t) - \mathbf{c}_j(t)\|^2}{2b_j^2}\right), \quad j = 1, \dots, m \quad (2.32)$$

onde b_j representa a constante de espalhamento ou largura da função de base radial de ativação e m representa o número de neurônios na camada oculta.

A camada de saída é uma combinação linear ponderada representada pela Equação 2.33.

$$y_i(t) = \sum_{j=1}^m w_{ji} h_j(t), \quad i = 1, \dots, n \quad (2.33)$$

onde w são os pesos da camada de saída, n representa o número de saídas e y representa a saída da rede.

Um problema das Redes Neurais de Base Radial aparece quando um vetor de

entrada aplicado na rede se difere muito dos dados do conjunto de treino. No caso de funções gaussianas, quando os valores do vetor de entrada ficam muito distantes dos centros de um conjunto, o resultado da saída da função gaussiana torna-se exponencialmente pequena e cai rapidamente para zero. As RBFs, que utilizam funções gaussianas são boas apenas quando os dados de entrada estão próximos ou abaixo dos centros das funções de base radial, em outras palavras, caso os valores do conjunto de teste estejam muito distantes dos valores do conjunto de treino, a RBF não irá entregar bons resultados [45].

2.4.3 Redes Neurais Com Estado de Eco

A arquitetura básica de uma ESN é composta por uma camada de unidades de processamento não lineares (camada recorrente), uma camada de leitura, responsável pela combinação dos sinais gerados pelo reservatório e uma camada de saída [46].

Os sinais de entrada, que compõem o vetor $\mathbf{u}(n) = [u_1(n) \dots u_K(n)]^T$, após serem combinados de acordo com os coeficientes da matriz $\mathbf{W}^{in} \in \mathbb{R}^{N \times K}$ são inseridos no reservatório de dinâmica. O reservatório é composto por N neurônios não lineares conectados, os quais as ativações são representadas por $\mathbf{x}(n) = [x_1(n) \dots x_N(n)]^T$, compõem os estados da rede e são atualizadas com a seguinte Equação:

$$\mathbf{x}(n+1) = \mathbf{f}(\mathbf{W}^{in} \mathbf{u}(n+1) + \mathbf{W} \mathbf{x}(n)), \quad (2.34)$$

onde $\mathbf{W} \in \mathbb{R}^{N \times N}$ contém os pesos das conexões recorrentes do reservatório e $\mathbf{f}(\cdot) = (f_1(\cdot), \dots, f_N(\cdot))$ representa as funções de ativação dos componentes internos.

Por fim, as saídas da rede, compostas pelo vetor $\mathbf{y}(n+1) = \mathbf{W}^{out} \mathbf{x}(n+1)$, são calculadas de acordo com a seguinte expressão:

$$\mathbf{y}(n+1) = \mathbf{W}^{out} \mathbf{x}(n+1) \quad (2.35)$$

onde $\mathbf{W}^{out} \in \mathbb{R}^{L \times N}$ é a matriz dos pesos de saída.

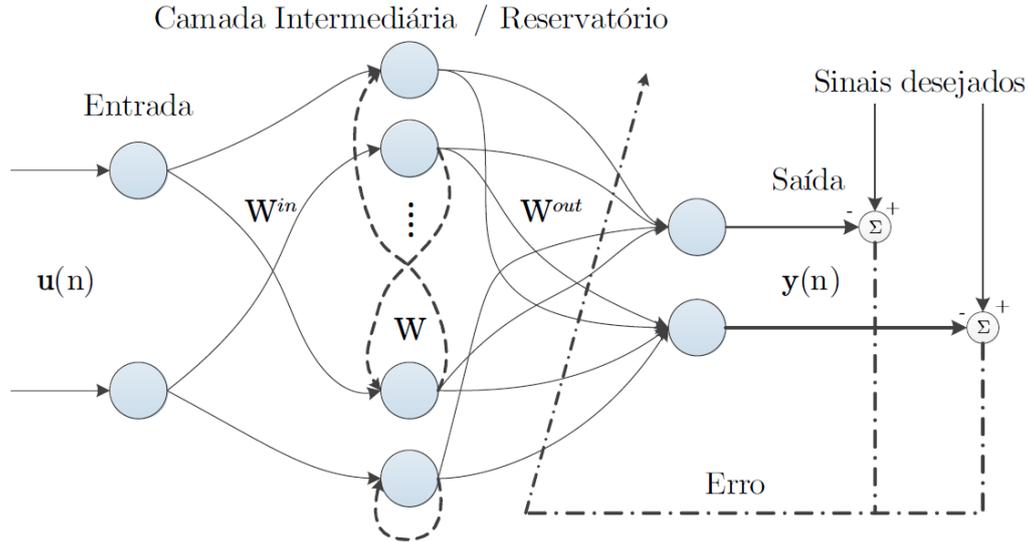
Aprofundando um pouco mais na idéia das ESNs, o ajuste antecipado dos parâmetros da camada recorrente não depende do processo de adaptação da mesma, isso quer dizer que somente os coeficientes da camada de saída sofrem ajuste com base em um sinal de referência [46]. Uma outra reflexão a ser feita é que devido ao padrão linear da camada de saída, os coeficientes ótimos podem ser determinados por mínimos quadrados [43].

A etapa de treinamento desta estrutura recorrente torna-se simples devido à propriedade de estados de eco (do inglês, *echo state property*, ESP) [43], que torna ativação de cada neurônio do reservatório uma transformação não linear do histórico recente do sinal de entrada (dessa idéia se origina o *eco*) quando a matriz \mathbf{W} de

pesos recorrentes corresponda a certos requisitos.

A arquitetura básica de uma ESN pode ser vista na Figura 2.6, perceba que apenas os pesos de saída são adaptados com base no erro.

Figura 2.6: Arquitetura básica das ESNs.



Fonte: Retirado de [48].

Propriedade de Estados de Eco (ESP)

Foi mostrado por [43] que, sob certas circunstâncias, os estados da rede tenham comportamento assintoticamente independentes da condição inicial. Isso significa dizer que numa situação onde a rede foi inicializada a partir de $\mathbf{x}(0)$ e $\hat{\mathbf{x}}(0)$, dois estados diferentes, e os sinais de entrada sejam recebidos na mesma sequência, então as sequências de estados resultantes $\mathbf{x}(n)$ e $\hat{\mathbf{x}}(n)$ vão convergir para valores próximos [46]. Portanto, quando esta sentença é satisfeita, diz-se que os efeitos dos estados iniciais são mitigados e a dinâmica do reservatório vai depender apenas do histórico de entradas, e a rede então possui estados de eco [43].

Treinamento de uma ESN

Assim que a presença do histórico dos sinais de entrada pode ser garantida quando a rede possui os estados de eco (que surgem a partir da escolha da matriz de pesos recorrentes \mathbf{W}) é possível realizar o projeto do reservatório, i.e., sem a influência do processo de adaptação da rede [43].

Neste ponto, é importante salientar que a função do reservatório de dinâmicas é gerar um comportamento de dinâmicas o mais diversificado possível [46]. Contudo, o reservatório não possui a informação do sinal no qual se quer aproximar e isso

acaba gerando uma perda na capacidade de representação. Logo, é essencial que os parâmetros da camada recorrente sejam escolhidos previamente e de maneira correta.

Em [43], Jaeger estabeleceu que: criando aleatoriamente uma matriz de pesos \mathbf{W} que apresente um certo grau de esparsidade, é uma forma simples de propor um reservatório rico em dinâmicas. A idéia por trás da afirmação anterior é que garantindo um padrão de conexões esparsas, o desacoplamento de grupos de neurônios do reservatório é favorecido, o que auxilia o desenvolvimento de dinâmicas individuais, pouco correlacionadas.

O treino da ESN se restringe em definir os coeficientes do combinador linear que vão minimizar o erro quadrático médio entre a saída da rede e a saída desejada desde que os três passos abaixo tenham sido seguidos:

- Defina uma matriz de pesos \mathbf{W} que garanta a existência dos estados de eco;
- Defina a matriz dos pesos de entrada \mathbf{W}^{in} de maneira arbitrária;
- Proponha \mathbf{W}^{in} de forma que não exerça qualquer influência sobre a ESP.

Os coeficientes do combinador linear que minimizam o erro médio entre a saída da rede e a saída desejada podem ser definidos calculando-se a pseudoinversa de Moore-Penrose da matriz de estados $\mathbf{X} \in \mathbb{R}^{N \times T_s}$, onde T_s indica o número de amostras da etapa de treino, da seguinte forma:

$$\mathbf{W}^{out} = \mathbf{d}\mathbf{X}^\dagger = \mathbf{d}\mathbf{X}^T(\mathbf{X}\mathbf{X}^T)^{-1} \quad (2.36)$$

onde a matriz $\mathbf{d} \in \mathbb{R}^{N \times T_s}$ contém todas as saídas desejadas para a sequência de treinamento.

2.4.4 Abordagem Prática Para Produzir um Reservatório

De forma introdutória a esta subseção, serão expostas duas equações de atualização típicas de RNRs que a ESN aplica para atualizar a matriz de pesos [41]:

$$\tilde{\mathbf{x}}(n) = \tanh(\mathbf{W}^{in}[1; \mathbf{u}(n)] + \mathbf{W}\mathbf{x}(n-1)) \quad (2.37)$$

$$\mathbf{x}(n) = (1 - \alpha)\mathbf{x}(n-1) + \alpha\tilde{\mathbf{x}}(n) \quad (2.38)$$

onde $\mathbf{x}(n) \in \mathbb{R}^{N_x}$ é o vetor de ativação dos neurônios do reservatório e $\tilde{\mathbf{x}}(n) \in \mathbb{R}^{N_x}$ é sua atualização em cada instante de tempo n , $\tanh(\cdot)$ é aplicado elemento por elemento, $[.;.]$ é uma notação que representa a concatenação vertical de um vetor (ou matriz), e $\mathbf{W}^{in} \in \mathbb{R}^{N_x \times (1+N_u)}$ e $\mathbf{W} \in \mathbb{R}^{N_x \times N_x}$ são as matrizes de entrada e de pesos respectivamente, e $\alpha \in (0, 1]$ é a taxa de vazamento.

Seleção Manual dos Parâmetros Quando o ajuste dos parâmetros de uma ESN é feito de forma manual, deve-se ter o cuidado de não alterar mais de um parâmetro por vez [41]. Uma abordagem razoável é setar valores para um parâmetro até conseguir melhoria na performance e depois partir para outro parâmetro e repetir isso até que se chegue em uma performance satisfatória [41]. Também é uma boa prática anotar os valores dos parâmetros utilizados ou gerar um *log*, registro para que um valor dado a um parâmetro não seja repetido.

2.5 Modelos Combinados de Redes Neurais

Os métodos de combinação de Redes Neurais são usualmente implementados para extrair resultados melhores do que uma única RNA. A ideia desse método é treinar uma maior quantidade de redes e combinar suas saídas, objetivando melhorar a previsão. Dois fatores fundamentais podem contribuir para melhorar os resultados [47]:

1. O efeito combinado das rede neurais compensa as diferentes inicializações aleatórias. Os erros entre redes neurais não são correlacionados.
2. Cada MLP pode empregar números diferentes de neurônios na camada oculta.

2.5.1 *Ensemble* Médio

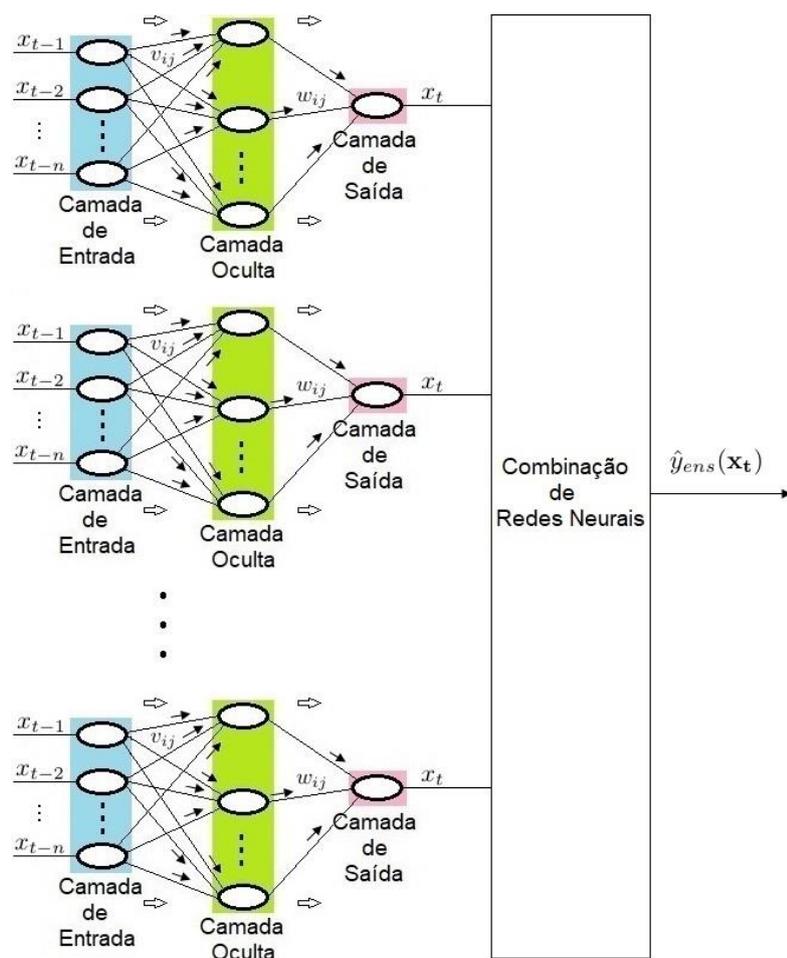
Existem muitas formas de se combinar Redes Neurais, o método mais simples é fazer uma média ponderada das saídas das redes, como na Equação 2.39.

$$\hat{y}_{ens}(x_k) = \frac{1}{M} \sum_{i=1}^M \hat{y}_i(x_k) \quad (2.39)$$

onde M é o número total de redes neurais e $\hat{y}_i(x_k)$, com $i = 1, \dots, M$ são as saídas de cada RNA definidas em cada instante de tempo k .

A Figura 2.7 representa um diagrama de um *ensemble* de redes neurais.

Figura 2.7: Esquema de um modelo combinado de Redes Neurais Artificiais.



Fonte: Própria.

Capítulo 3

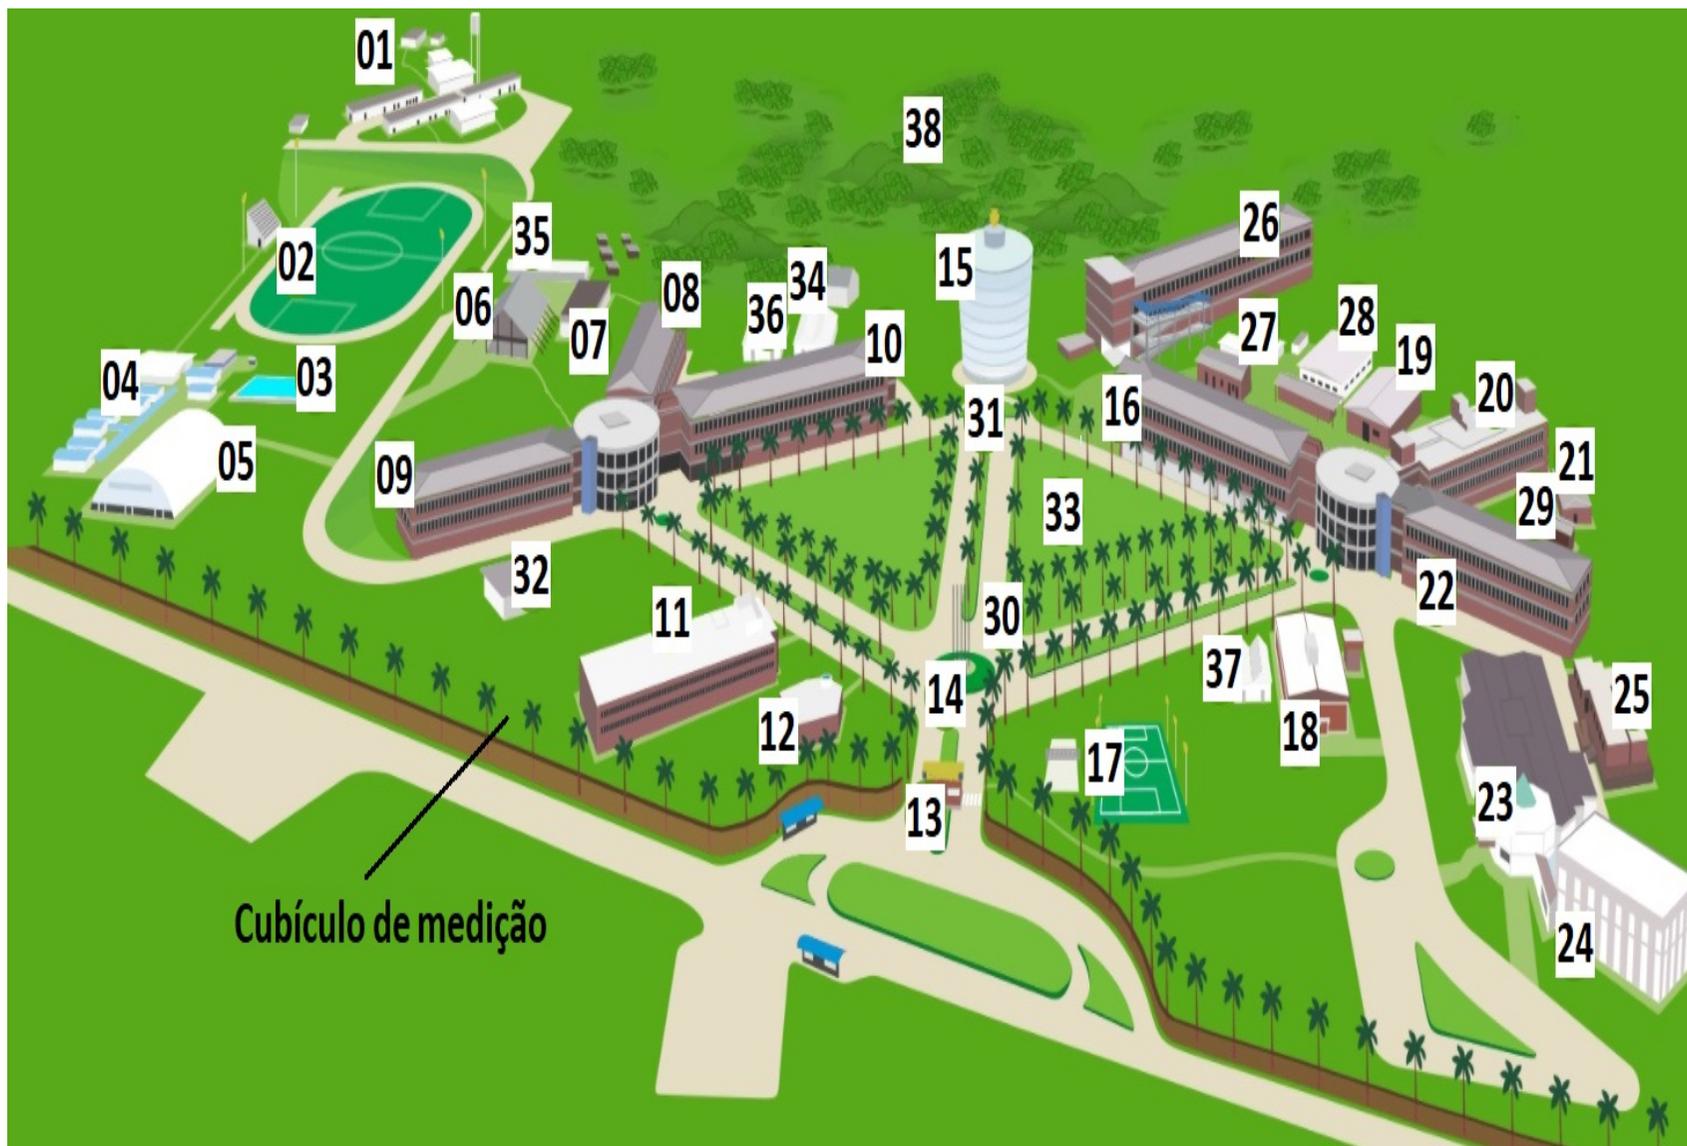
Metodologia e Pré-Processamento da Informação

Neste capítulo, são mostrados todos os pavilhões e demais construções da universidade com o intuito de dar uma noção geral do tamanho da instalação elétrica do local e também como e onde a medição dos parâmetros elétricos é feita pela concessionária. Em seguida, é exibida a etapa de pré-processamento dos dados com o objetivo de retirar *outliers*, fins de semana e feriados. Será exposto também como a seleção dos parâmetros de entrada dos preditores foi realizada e como os modelos foram propostos nos três estudos de caso. Por fim, foram detalhados os materiais, os métodos de avaliação de desempenho dos modelos aplicados e a infraestrutura disponível para a realização deste trabalho.

3.1 Aquisição dos Dados e Detalhamento das Instalações do Local

Os parâmetros elétricos utilizados neste trabalho são auferidos no cubículo de medição e proteção de energia da Universidade Estadual de Santa Cruz, em média tensão (13,8/15 kV). A rede elétrica que atende a universidade fica do lado contrário da pista, a rede atravessa a pista, passa por um poste dentro da universidade, segue em mufla para a caixa de inspeção no chão logo abaixo do poste e segue até o cubículo de medição por baixo da terra. As Figuras 3.1 e 3.2 mostram o mapa do local situando a entrada de energia e a entrada da energia.

Figura 3.1: Mapa da universidade.



A Tabela 3.1 identifica os locais enumerados na Figura 3.1.

Tabela 3.1: Legenda do mapa da Figura 3.1.

Número	Local
01	Hospital Veterinário
02	Campo de Futebol
03	Piscina Semi-Olímpica
04	Pavilhão de Educação Física
05	Quadra Poliesportiva
06	Restaurante Universitário (RU)
07	Centro de Microscopia Eletrônica (CME)
08	Pavilhão Juizado Modelo
09	Pavilhão Pedro Calmon
10	Pavilhão Adonias Filho
11	Pavilhão Professor Max de Menezes
12	Núcleo de Biologia Computacional e Gestão de Informações Biotecnológicas (NBCGIB)
13	Guarita (Entrada da Universidade)
14	Brasão UESC e Praça das Bandeiras
15	Torre Administrativa (Edifício José Haroldo Castro Vieira)
16	Pavilhão Jorge Amado
17	Quadra Poliesportiva
18	Centro de Biotecnologia e Genética (CBG)
19	Pavilhão Agroindústria
20	Instituto de Pesquisas e Análise Físico
21	Centro de Pesquisas em Ciências e Tecnologias das Radiações (CPqCTR)
22	Pavilhão Manoel Fontes Nabuco
23	Biblioteca Central
24	Auditório Paulo Souto
25	Pavilhão Júlio Cezar de Mattos Cascardo
26	Pavilhão de Ciências Exatas e Tecnológicas
27	Oficina de Manutenção e Estacionamento de Veículos Oficiais e Prefeitura do campus
28	Núcleo de Educação a Distância e Laboratórios (EaD)
29	Estação de Manutenção e Recriação de Animais de Laboratório
30	Placa comemorativa pelos Direitos Humanos
31	Placa em homenagem a José Haroldo Castro Vieira
32	Base Ambiental
33	Bosque
34	Horto de Plantas Medicinais
35	Casa de Vegetação
36	Casa de Vegetação
37	Casa de Vegetação
38	Fazenda Santa Cruz

As subestações de cada pavilhão da universidade ficam no térreo e os pavilhões alimentam alguns anexos que ficam próximos. No total, a universidade possui 38 espaços alimentados por energia elétrica.

A universidade possui laboratórios e salas de aula em todos os pavilhões que contemplam ar condicionado, tomadas e iluminação. Todos os pavilhões da universidade possuem 3 pisos e entre 10 a 15 salas por piso, número que varia por pavilhão. A universidade possui oito Grupos Motor-Gerador instalados para operação em situação emergencial, os dados e locais dos grupos foram listados na Tabela 3.2.

Tabela 3.2: Lista do Grupos Motor-Gerador da universidade.

Local	Motor	Marca	Potência em KVA	Potência em KW
Hospital Veterinário	IVECO	Leon Heimer	160	128
Centro de Biotecnologia e Genética	MWM	Leon Heimer	180	144
Gerência de Laboratórios	PERKINS	Leon Heimer	55	44
Pavilhão Max de Menezes	MWM	Gramaco	81	64.8
Unidade de Desenvolvimento Organizacional	CUMMINS	Stanford	85	68
Centro de Microscopia Eletrônica	CUMMINS	Stanford	85	68
Instituto de Pesquisa e Análise Físico-Químicas	SCANIA	WEG	460	368
NBCGIB	IVECO	Leon Heimer	85	68

Figura 3.2: Entrada da energia no cubículo de medição da universidade.



Fonte: Própria.

3.2 Pré-Processamento dos dados

Os dados deste trabalho são registros da memória de massa da Universidade Estadual de Santa Cruz no período de março de 2014 a março de 2015.

Os dados foram fornecidos pela Companhia de Eletricidade do Estado da Bahia (COELBA) por meio de uma planilha, e a Tabela 3.3 mostra o modelo da memória de massa fornecida.

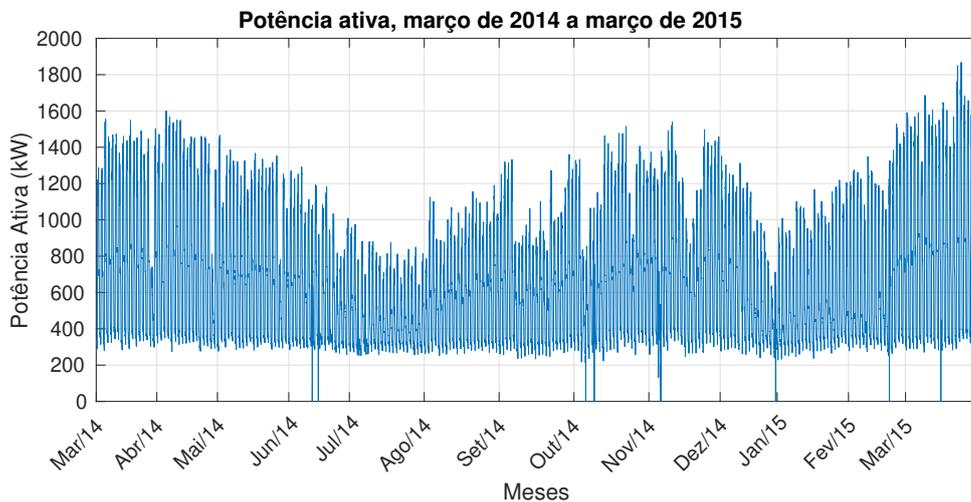
Tabela 3.3: Formatação dos dados da memória de massa fornecida pela fornecedora de energia local.

Data	Dia	Postos Horários	kW Fornecido	kVAr Indutivo	kVAr Capacitivo	UFER	DMCR
06/03/2014 00:00	Quinta	Fora Ponta	333,76	296,68	0	70,12	404,72
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
31/03/2015 23:45	Terça	Fora Ponta	384,16	269,92	0	-	-

Na Tabela 3.3, a coluna UFER corresponde a energia reativa excedente, que é a diferença entre o fator de potência medido e o mínimo de 0,92 para que não seja cobrado multa. A coluna DMCR corresponde a Demanda Máxima Corrigida Registrada, que é registrada por hora e utilizada no cálculo da UFER (os dados de UFER e DMCR do dia 31/03 não aparecem devido ao registro horário dessas informações).

A Figura 3.3 mostra o conjunto de dados utilizado.

Figura 3.3: Potência ativa da Universidade de março de 2014 a março de 2015.



Fonte: Própria.

Da Figura 3.3, nota-se que nos meses mais frios (junho, julho e agosto) a potência ativa mostrou valores mais baixos, com destaque para o mês de julho, que além de frio é um período de férias, e a potência durante todo o mês não ultrapassou 1.000 kW. A potência média consumida diária nos meses mais quentes é de 724 kW e nos meses mais frios é de 444 kW. O valor mínimo de toda a série histórica foi encontrado em Agosto. Os parâmetros da potência ativa estão representados na Tabela 3.4.

Tabela 3.4: Parâmetros da Potência Ativa Instantânea (março de 2014 a março de 2015)

Parâmetros	Mês	Dados da Potência Ativa (kW)
Máximo	Março/2015	1.868,2
Mínimo	Agosto/2014	240,8
Número de Amostras		23.808

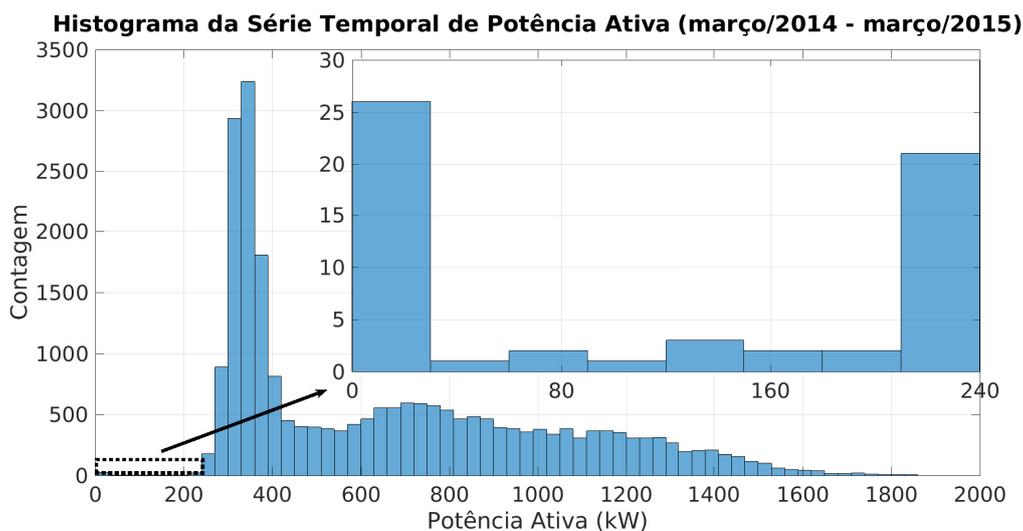
O conjunto de dados possui integralização (intervalo de registro) de medidas de quinze minutos, sendo um total de 96 amostras por dia. Foram utilizados os dados do dia 06/03/2014 às 00:00h ao dia 31/03/2015 às 23:45h.

Neste trabalho, as previsões são focadas nos horizontes de 15 e 30 minutos a frente (1 e 2 passos), visando alocar de forma dinâmica e otimizada a parcela gerada disponível (neste ponto vale salientar que a universidade possui apenas geradores a diesel que funcionam em regime emergencial). Sendo 15 minutos o menor intervalo entre medidas de potência, é possível realizar previsões de curto prazo para preparar um sistema de geração para injetar energia gerada disponível em um sistema elétrico (em horários específicos) oferecendo a ele a parcela necessária para que não haja ultrapassagem de demanda.

3.2.1 Tratamento dos *Outliers*

Na Figura 3.3, nota-se que existem várias quedas da magnitude da potência ativa para zero. Para estimar a quantidade destes registros, foi traçado um histograma da série temporal. A Figura 3.4 mostra o histograma da série temporal.

Figura 3.4: Histograma da série temporal de potência.

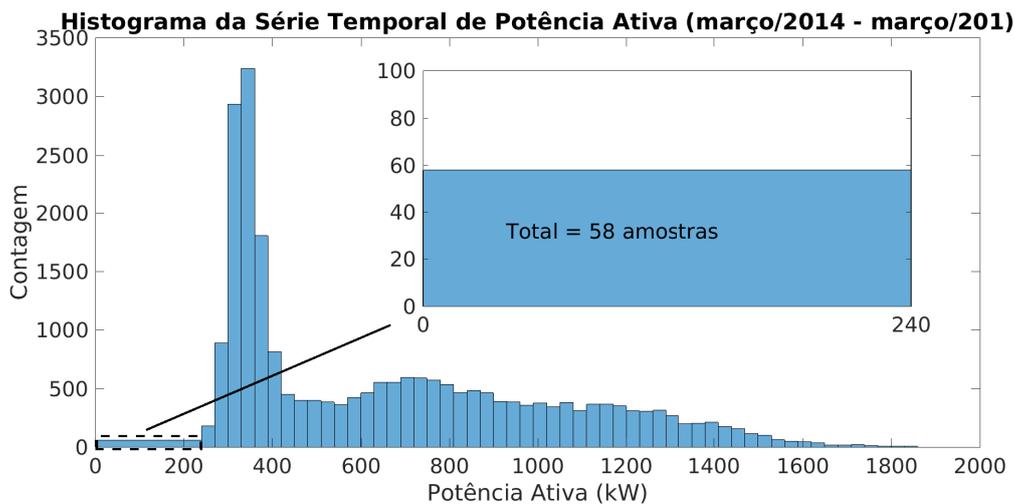


Fonte: Própria.

Da Figura 3.4, observa-se que uma pequena quantidade de dados onde a potência

ativa registrada foi abaixo de 240 kW. Esses valores baixos registrados possivelmente representam distúrbios na rede elétrica que ocorreram durante o processo de medição. Os distúrbios acontecem poucas vezes na série de potência e são caracterizados por quedas abruptas para zero com baixo tempo de duração. Para estimar a quantidade dos dados que situam-se abaixo do limiar de 240 kW, um outro histograma foi traçado, forçando a contagem de dados no intervalo de 0 a 240 kW. A Figura 3.5 mostra a quantidade de observações que foram registradas abaixo de 240 kW.

Figura 3.5: Histograma da série temporal de potência com ênfase na região de interesse.



Fonte: Própria.

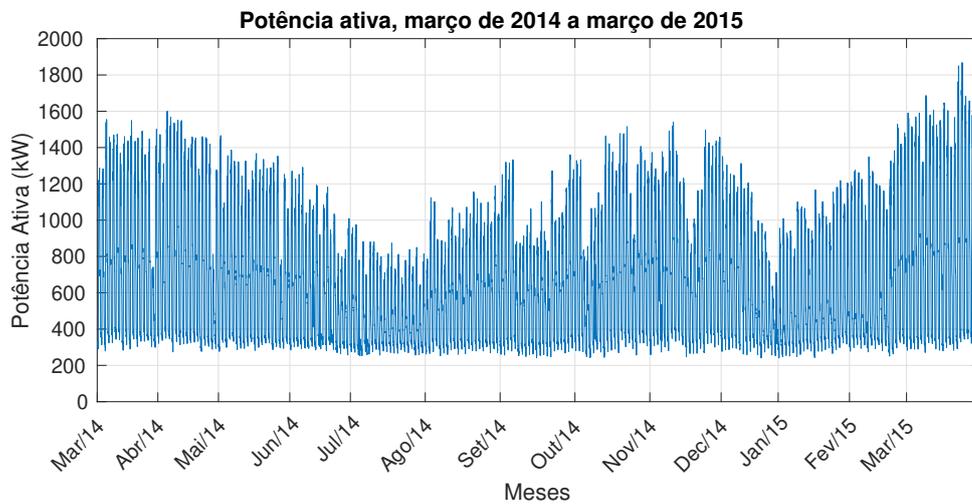
Da Figura 3.5, nota-se que apenas 58 amostras, que representam 0,24% do total de amostras da série temporal situam-se abaixo dos 240 kW. A série de potência após o tratamento inicial possui um total de 23.808 amostras. Para eliminar os *outliers*, foi aplicada uma suavização por médias móveis e os dados foram substituídos pela média dos sete termos anteriores. Os fins de semana e feriados também foram removidos, com base no calendário da instituição. Dias atípicos, nos quais a curva de potência ativa muda muito em relação ao padrão esperado foram mantidos. A Figura 3.6 mostra o *Dataset* após a remoção dos *outliers*.

3.3 Configuração dos Modelos Utilizados no Trabalho

Neste trabalho foram feitos três estudos de caso, e a configuração dos modelos estatísticos e de IA usados nos três serão mostradas antes do capítulo dos Resultados. A seleção das entradas e dos parâmetros configurados para cada modelo foi realizada através de uma análise da série temporal modelando um processo ARIMA sazonal

ou SARIMA. Essa parte se encontra na seção 4.1 do capítulo dos Resultados.

Figura 3.6: Potência ativa da Universidade de março de 2014 a março de 2015 após o tratamento dos *outliers*.



Fonte: Própria.

3.3.1 Configuração do Modelo *Naive*

O modelo de persistência ou *Naive* usa apenas informações da série temporal para realizar as previsões. O modelo recebe a informação de potência e a replica, dando como previsão a última informação de potência que chega. Isso é feito para ambos horizontes de previsão.

3.3.2 Configuração do Modelo SARIMA

O modelo utilizado foi um SARIMA $(4, 1, 0) \times (0, 1, 2)_{96}$ definido anteriormente.

3.3.3 Configuração do Modelo de Redes Neurais *Feedforward*

Foram utilizadas MLPs com uma camada intermediária, usando seis entradas que correspondem aos atrasos temporais da série definidos na seção 4.1, utilizou-se a função de ativação *Log-sigmoid* e o algoritmo de treinamento *Levenberg-Marquadt*. O número de neurônios na camada oculta foram variados de três em três até 45 e as melhores configurações encontradas foram com nove neurônios na camada oculta para a previsão no horizonte de 15 minutos a frente e quinze neurônios na camada oculta para o horizonte de 30 minutos a frente. A combinação em todos os modelos de IA foi feita usando a saída de 5 redes (valor que foi escolhido devido a falta de recurso computacional).

Antes de iniciar as configurações dos modelos baseados em IA (as redes neurais utilizadas), é importante salientar que o caráter deles é estocástico, portanto, é recomendável que sejam projetados vários modelos e fazer a média da saída deles. Em outras palavras, é a combinação das saídas das redes. A combinação das saídas das redes foi feita utilizando a saída de 5 redes neurais devido a falta de recurso computacional. Isso será feito em todos os modelos de IA.

3.3.4 Configuração do Modelo de Redes Neurais de Base Radial

Foram utilizadas MLPs com uma camada intermediária, usando seis entradas que correspondem aos atrasos temporais da série definidos na seção 4.1, utilizou-se 27 neurônios na camada oculta para o horizonte de previsão de 15 minutos e 15 neurônios na camada oculta para o horizonte de previsão de 30 minutos. A escolha das constantes de espalhamento para as cinco redes foi feita através de uma busca exaustiva, adotando erro médio quadrático de treinamento igual a 0.0001. O detalhamento da busca pelos parâmetros foi feito em 4.1.5.

3.3.5 Configuração do Modelo de Redes Neurais com Estados de Eco

Foram utilizadas redes recorrentes com uma camada intermediária, usando seis entradas que correspondem aos atrasos temporais da série definidos na seção 4.1, para o horizonte de 15 minutos, foram utilizados os seguintes parâmetros: taxa de vazamento igual a 0,865, tamanho do reservatório igual a 16 e raio espectral igual a 1,135. Para o horizonte de 30 minutos, foram utilizados os seguintes parâmetros: taxa de vazamento igual a 0,481, tamanho do reservatório igual a 51 e raio espectral igual a 2,181. A escolha dos hiperparâmetros foi feita de forma manual e o processo para determinar cada um deles foi descrito na seção 4.1.6.

3.3.6 Configuração do *Ensemble* ou Combinação Redes Neurais

A combinação de redes neurais artificiais será feita apenas com redes do mesmo tipo, não foram combinadas redes de tipos diferentes. Como exemplo, a combinação de redes neurais *feedforward* é composta pela saída de 5 redes neurais *feedforward* e isso vale para a RBFs e para as ESNs.

3.4 Estudo de Caso 1: Previsão Semanal Utilizando Modelos de IA e Estatísticos

A idéia do primeiro estudo foi propor modelos anuais genéricos de previsão semanal para qualquer semana em qualquer mês do ano. No primeiro estudo de caso, foram aplicadas as seguintes técnicas:

1. Técnicas Estatísticas:
 - Modelo de persistência ou *Naive*;
 - Modelo ARIMA sazonal (SARIMA).
2. Técnicas de Inteligência artificial:
 - Redes *Feedforward*;
 - Redes de base radial (RBF);
 - Redes neurais com estado de eco (ESNs).

3.4.1 Divisão dos dados em Conjuntos de Treino e Teste

Para o treino do Estudo de Caso 1, concatenou-se os dados das três primeiras semanas dos meses de março de 2014 a março de 2015. Diferentemente da concatenação em um só conjunto, para o teste, foram organizados 13 conjuntos, cada um contendo os dados da última semana de cada mês. O conjunto de teste foi utilizado para teste e para validação. A Figura 3.7 ilustra o processo de separação dos conjuntos.

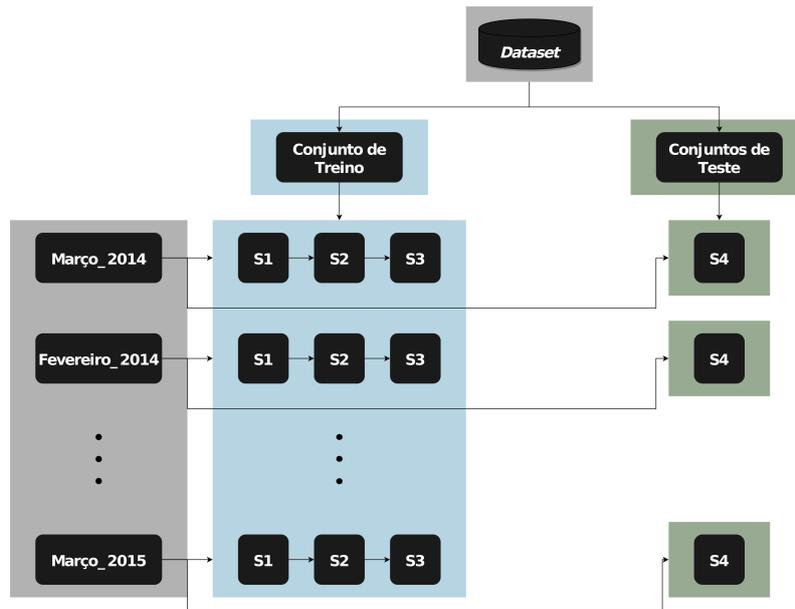
3.5 Estudo de Caso 2: Previsão Mensal, um Comparativo Entre os Melhores Modelos

A idéia do segundo estudo foi propor um modelo anual de previsão mensal.

Para este estudo, foi escolhido o melhor modelo baseado em IA e o melhor modelo estatístico do Estudo de Caso 1 para realizar previsão de todo o mês de março de 2015.

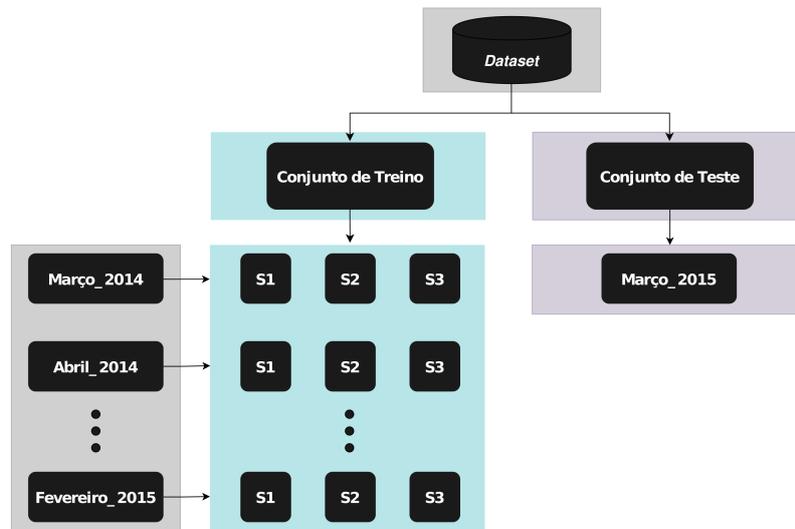
O conjunto de treino foi organizado com as três primeiras semanas dos meses de março de 2014 a fevereiro de 2015. O conjunto de teste e validação foi composto pelas 4 semanas do mês de março de 2015. A Figura 3.8 ilustra a separação dos conjuntos.

Figura 3.7: Separação dos conjuntos de treino e teste para o Estudo de Caso 1.



Fonte: Própria.

Figura 3.8: Separação dos conjuntos de treino e teste para o Estudo de Caso 2.



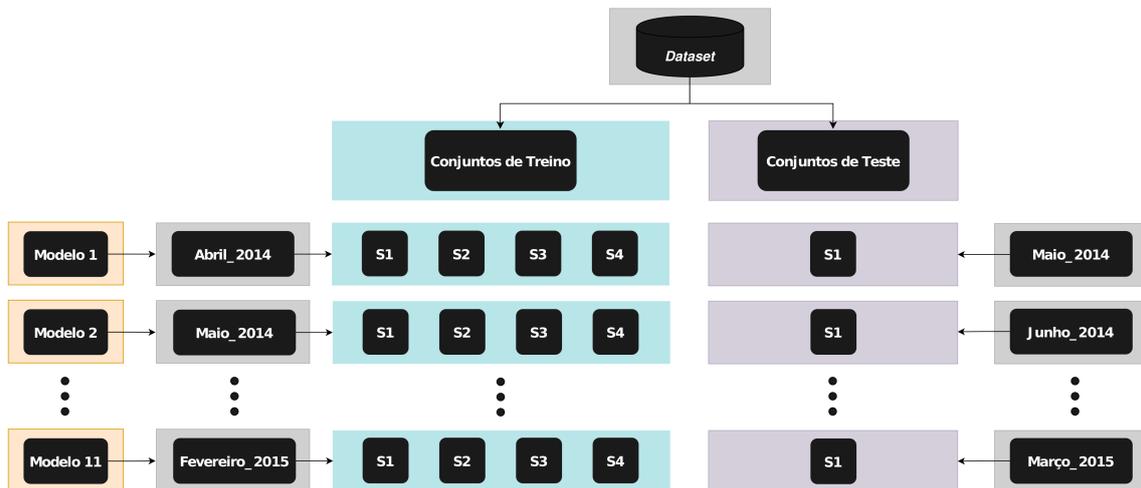
Fonte: Própria.

3.6 Estudo de Caso 3: Previsão da Primeira Semana de Cada Mês, um Comparativo Entre os Melhores Métodos

Nesse estudo de caso, o objetivo foi criar modelos de previsão semanais com conjuntos de treino mensais, compostos por apenas um dos meses do *dataset*.

Os conjuntos de treino de cada modelo foram organizados com as quatro semanas de cada mês, começando pelo mês de abril de 2014 e finalizando no mês de fevereiro de 2015. Os conjuntos de teste/validação foram compostos pela primeira semana do mês seguinte ao conjunto de treino correspondente, começando pelo mês de maio de 2014 e finalizando no mês de março de 2015. A Figura 3.9 ilustra a separação dos conjuntos.

Figura 3.9: Separação dos conjuntos de treino e teste para o Estudo de Caso 3.

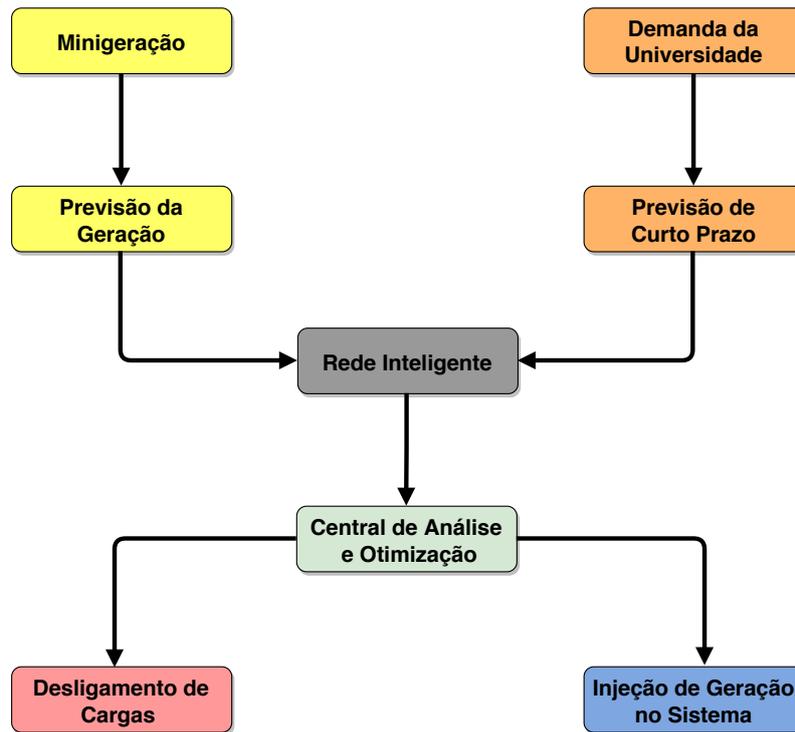


Fonte: Própria.

3.7 Aplicação Prática para a Previsão

A Figura 3.10 mostra o esquema de um sistema elétrico simples com a utilização de rede inteligente e aplicação de previsão de potência de curto prazo.

Figura 3.10: Esquema elétrico simples com uso de rede inteligente.



Fonte: Própria.

A previsão da potência seria realizada dentro de um sistema embarcado conectado à rede inteligente. O sistema embarcado receberia os dados da potência ativa da instalação direto de um sistema medidor em tempo real e forneceria a previsão de potência de curto prazo. Dispondo de uma estimativa confiável da demanda da energia futura em diferentes intervalos de tempo, é possível atuar no sistema elétrico do local para utilizar as diversas fontes de geração disponíveis ou realizar o desligamento de algumas cargas expressivas com o intuito de evitar a ultrapassagem de demanda ou reduzir parte da energia que a instalação irá demandar durante um intervalo de tempo específico (nos instantes de picos de demanda). Com informações sobre a demanda futura, mediante a uma possível ultrapassagem, as seguintes decisões poderiam ser tomadas na universidade:

- Acionamento de Grupos Motor-Gerador para atender parte da demanda da universidade em instantes de tempo específicos;
- Desligamento de cargas significativas.

Além dos itens anteriores, se a universidade possuísse alguma outra fonte de geração auxiliar ela também poderia estar sendo usada para reduzir a potência demandada pelo sistema durante um período específico do dia.

3.8 Parâmetros de Avaliação

O desempenho dos modelos aplicados serão avaliados em função de métricas consolidadas aplicadas na literatura, através do cálculo dos erros MAPE (*Mean Absolute Percentage Error*), MAE (*Mean Absolute Error*) e MSE (*Mean Squared Error*), representados respectivamente pelas equações 4.1, 4.2 e 4.3.

Erro Médio Absoluto Percentual (MAPE)

$$MAPE(y) = \frac{100}{N} \sum_{t=1}^N \left| \frac{y_t - \hat{y}_t}{y_t} \right| \quad (3.1)$$

Erro Médio Absoluto (MAE)

$$MAE(y) = \frac{1}{N} \sum_{t=1}^N |y_t - \hat{y}_t| \quad (3.2)$$

Erro Médio Quadrático (MSE)

$$MSE(y) = \frac{1}{N} \sum_{t=1}^N (y_t - \hat{y}_t)^2 \quad (3.3)$$

onde, y_t representa o valor real da medição, \hat{y}_t o valor predito e N a quantidade de amostras.

Capítulo 4

Resultados

Neste capítulo, são expostos os resultados de ajuste de parâmetros de cada modelo, bem como o resultado da previsão dos modelos ajustados, a comparação entre os modelos ajustados, a apresentação de como seria uma aplicação prática do melhor preditor proposto nesse trabalho e um cálculo simples de quanto a universidade economizaria utilizando previsão de potência com o a geração interna disponível.

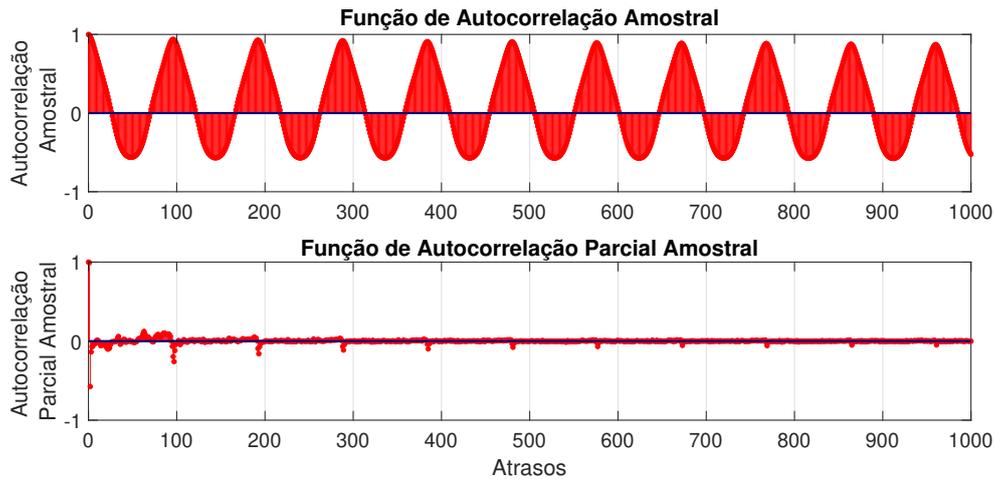
Antes de entrar na seleção das entradas que serão aplicadas no modelo, vale a pena ressaltar que no início do trabalho foram utilizados os 15 primeiros atrasos da série e mais oito atrasos da série referentes ao dia anterior. Com 23 atrasos escolhidos de forma arbitrária o treinamento dos modelos estava muito demorado e os resultados ruins. Dessa forma, houve a necessidade de buscar um critério de seleção dos atrasos que serão utilizados na etapa do treinamento.

4.1 Resultados de Ajustes de Parâmetros

4.1.1 Seleção dos Parâmetros de Entrada das Redes e Identificação do modelo ARIMA

Os parâmetros de entrada dos preditores foram definidos após a identificação do modelo ARIMA, através da análise das sequências de autocorrelação (*Autocorrelation Function - ACF*) e autocorrelação parcial (*Partial Autocorrelation Function - PACF*) da série. A Figura 4.1 mostra as sequências de autocorrelação e autocorrelação parcial da série para 1000 atrasos.

Figura 4.1: ACF e PACF da série temporal original para 1000 atrasos.



Fonte: Própria.

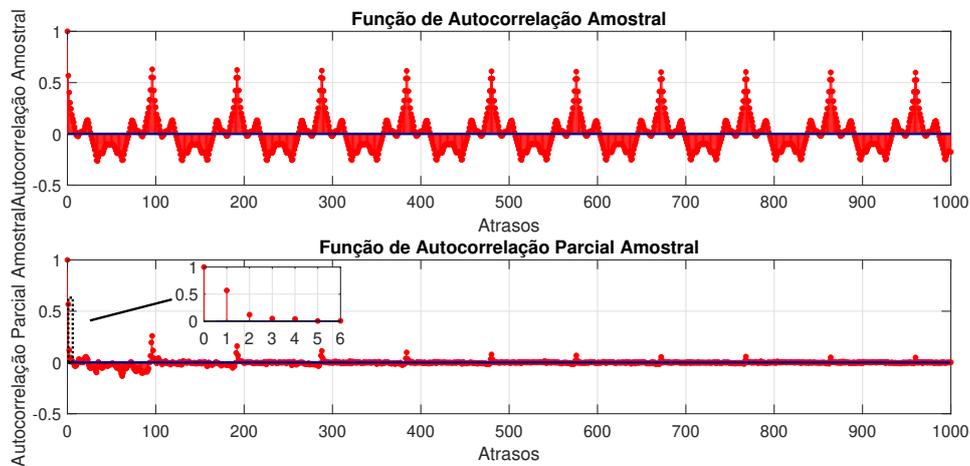
Da Figura 4.1, observa-se que a amplitude da ACF decai lentamente e a PACF mostra valor significativo no primeiro atraso, o que é comportamento típico de uma série não estacionária. Na tentativa de tornar a série estacionária, tomou-se a primeira diferença, da seguinte forma:

$$\Delta x_t = x_t - x_{t-1} \quad (4.1)$$

onde, x_t representa a série temporal, x_{t-1} o primeiro atraso da série e Δx_t a série diferenciada.

A Figura 4.2 mostra as funções de ACF e PACF da série temporal diferenciada para 1000 atrasos.

Figura 4.2: ACF e PACF da série temporal diferenciada para 1000 atrasos.

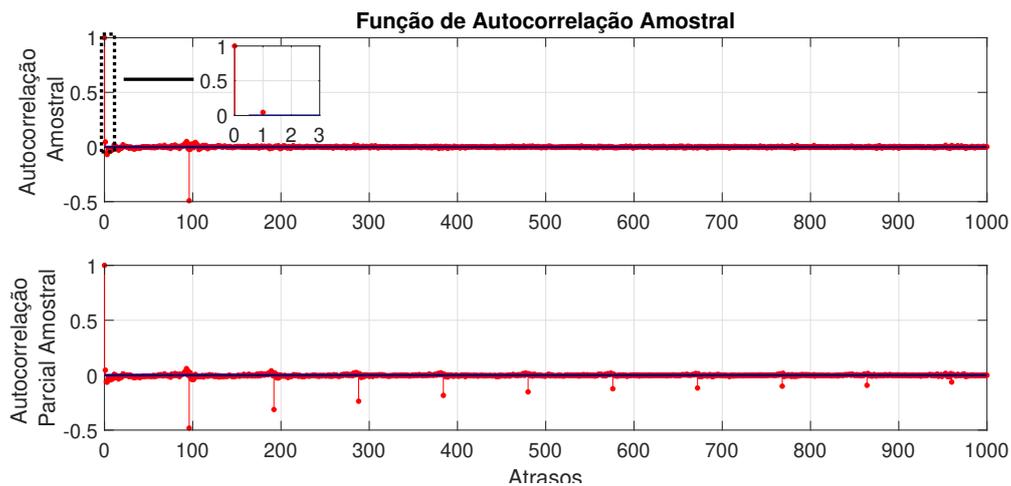


Fonte: Própria.

Da Figura 4.2, observou-se os quatro primeiros atrasos com magnitudes diferentes

de zero e a série se acomodando com alguns picos sazonais, dessa forma identificou-se um modelo autorregressivo AR(4) na PACF. Na ACF da Figura 4.2, nota-se que a série diferenciada possui atrasos sazonais que não decaem para zero, e que a cada 96 atrasos a magnitude mostra picos, portanto, existe também uma diferença sazonal. Na tentativa de tirar a sazonalidade da série e identificar o modelo, tomou-se a diferença sazonal de atraso 96. A Figura 4.3 mostra as funções de ACF e PACF da série de diferenças sazonais para 1000 atrasos.

Figura 4.3: ACF e PACF para 1000 atrasos da série de diferenças sazonais.



Fonte: Própria.

Analisando a Figura 4.3, a série de diferenças sazonais possui um comportamento de um modelo MA(1), com a ACF mostrando magnitude diferente de zero no atraso 1 e zero para os demais atrasos até o atraso 96 e em seguida é igual a zero até o fim da ACF. Dessa forma, o modelo utilizado foi um ARIMA sazonal, ou SARIMA $(4, 1, 0) \times (0, 1, 2)_{96}$, sendo 4 atrasos do AR, identificado na primeira diferenciação da série, 1 indicando a primeira diferença, e 0 indicando a ausência de componente de média móvel, novamente 0 indicando ausência de componente autorregressivo, 1 indica uma diferença sazonal e 2 indicando o atraso 96 e um atrasos da parte do MA. O model pode então ser escrito de forma analítica:

$$(1 - \phi_1 B - \phi_2 B^2 - \phi_3 B^3 - \phi_4 B^4)(1 - B^{96})(1 - B)x_t = (1 + \Theta_1 B^{96} + \Theta_2 B^{2(96)})w_t$$

A partir do estudo das funções de ACF e PACF e da tomada das diferenças da série temporal, os atrasos selecionados para os preditores foram:

- $L = [1, 2, 3, 4, 96, 97]$.

Vale ressaltar que a estrutura de entrada de dados nos modelos de previsão

acabou se ser montada, os modelos irão ter como entrada esses seis atrasos da série temporal.

4.1.2 Parâmetros do Modelo *Naive*

A aplicação do modelo de persistência ou *Naive* foi feita para os dois horizontes da mesma forma, a previsão para o horizonte desejado é a última medida de potência disponível. A Tabela 4.1 foi feita para ilustrar um processo fictício de previsão com o modelo *Naive*.

Tabela 4.1: Exemplo do resultado da previsão de potência utilizando o método de persistência.

Horário	Potência Medida	Previsão 15 Minutos a Frente	Previsão 30 Minutos a Frente
15:30	1340 kW	15:45 → 1340 kW	16:00 → 1340 kW
15:45	1400 kW	16:00 → 1400 kW	16:15 → 1400 kW

Da Tabela 4.1 é possível notar que com o aumento do horizonte de previsão a tendência do erro do modelo de persistência é aumentar. O resultado gráfico de uma previsão utilizando esse método é a própria série temporal atrasada de 1 passo (15 minutos a frente) ou de 2 passos (30 minutos a frente).

4.1.3 Parâmetros do Modelo SARIMA

Para utilizar o modelo SARIMA é necessário passar por três etapas:

1. Criação do modelo;
2. Estimação dos parâmetros do modelo criado;
3. Previsão utilizando o modelo com os parâmetros estimados.

Para a Estimação dos parâmetros do modelo, a matriz de treino é utilizada juntamente com o modelo.

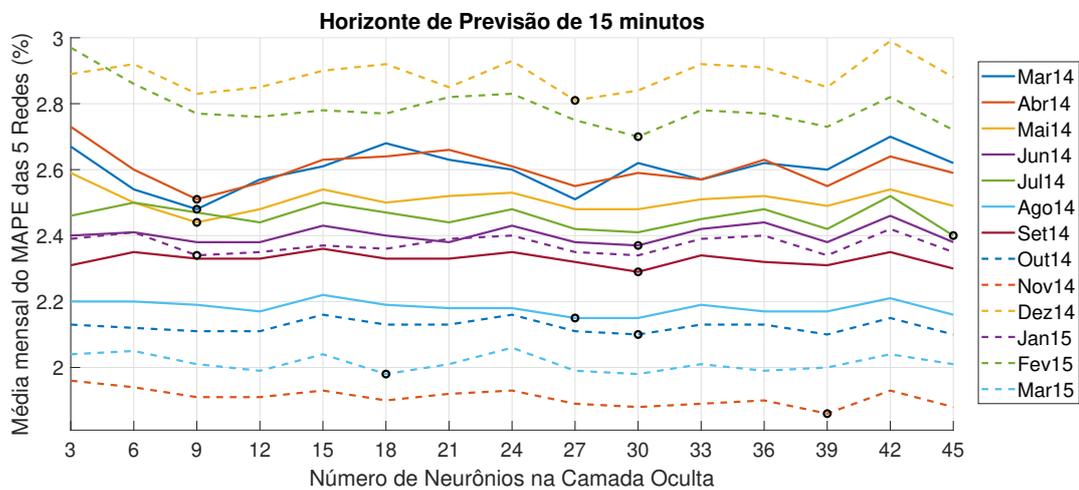
A função que utiliza o modelo estimado para realizar previsões necessita da quantidade de passos a serem previstos e o próprio conjunto de treino para prever os pontos à frente. Para a previsão de 1 passo a frente (15 minutos) concatenou-se o vetor de treino com o conjunto de teste e utilizou-se do conjunto de treino como uma janela móvel, invadindo a cada passo de previsão 1 valor no conjunto concatenado (treino e teste), prevendo sempre o dado na frente e deslocando o vetor de treino à cada ponto previsto. Isso foi feito para todos os conjuntos de teste. De modo similar, para a previsão de dois passos a frente (30 minutos), eram previstos sempre 2 pontos a frente, o primeiro ponto da previsão era excluído, o segundo era armazenado e o vetor de treino era deslocado uma casa para frente. Dois valores na frente eram

previstos novamente, o primeiro valor era excluído e o segundo armazenado, e assim até o último ponto da previsão.

4.1.4 Parâmetros do Modelo de Redes *Feedforward*

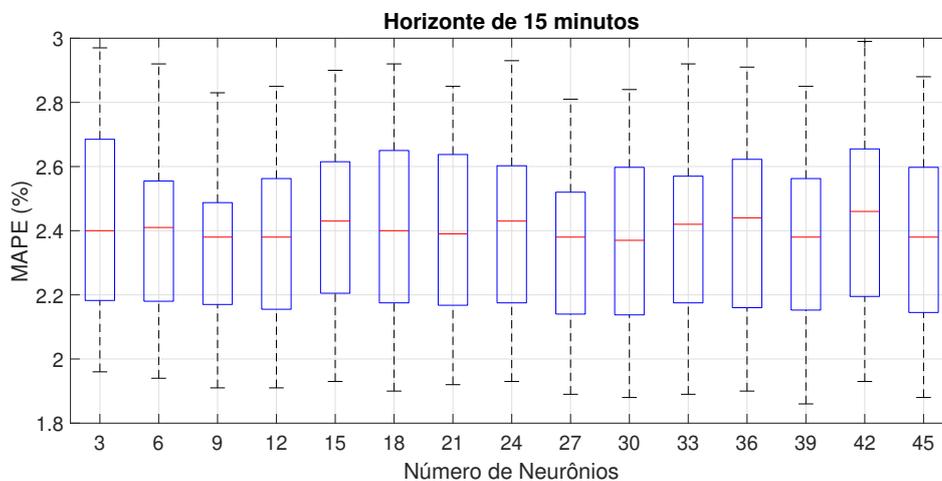
A quantidade de neurônios na camada oculta foi definida variando-se o número de neurônios de 3 em 3 até 45 e calculando a média dos erros médios absolutos percentuais (MAPE) das 5 redes para todos os conjuntos de teste. As Figuras 4.4 e 4.5 foram geradas para o horizonte de previsão de 15 minutos, o mesmo processo foi feito para definir a configuração da rede para o horizonte de 30 minutos.

Figura 4.4: MAPEs médios das 5 redes variando o número de neurônios da camada oculta, horizonte de previsão de 15 minutos.



Fonte: Própria.

Figura 4.5: *Box Plot* dos MAPEs médios das 5 redes variando o número de neurônios da camada oculta, horizonte de previsão de 15 minutos.



Fonte: Própria.

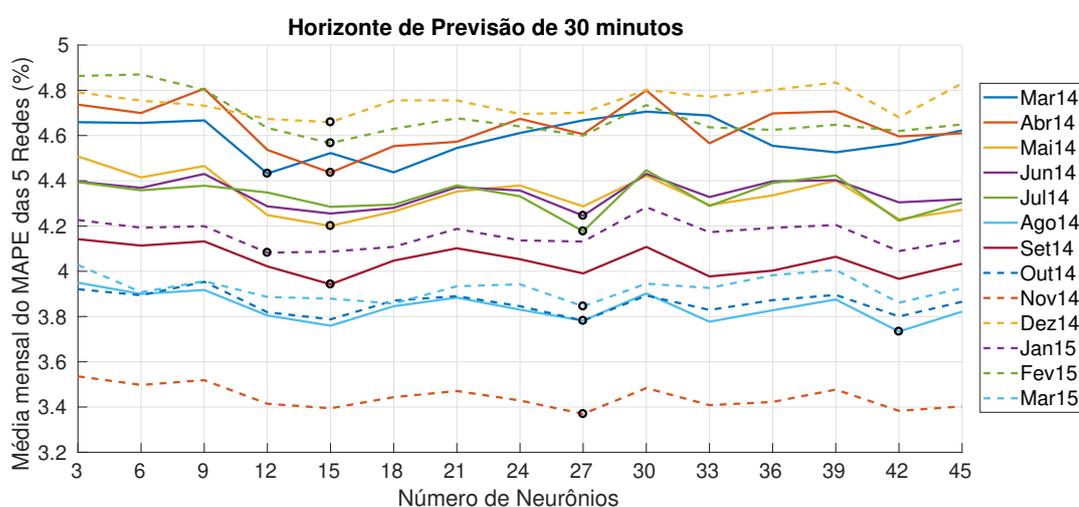
Na Figura 4.4, cada curva representa um conjunto de teste. Para cada conjunto de teste, foram variados os neurônios das 5 redes de 3 a 45 e a média dos MAPEs foi plotado em função da variação dos neurônios. Os círculos pretos representam o ponto de erro mínimo de cada curva.

Na Figura 4.5, as caixas resumem os resultados da Figura 40 em cada ponto do eixo x , sendo a linha em vermelho a mediana de todas as curvas para o ponto em questão do eixo x e as extremidades os valores máximos e mínimos registrados também dentre todas as curvas.

Observando o gráfico de caixas, a escolha da melhor configuração da rede será dada pela caixa que tenha suas duas extremidades (superior e inferior) mais baixas em relação ao eixo y e que possuam seus valores máximos e mínimos também localizados mais abaixo em relação ao eixo y (sem a presença de outliers). Dessa forma, a configuração escolhida foi a de 9 neurônios na camada oculta para prever no horizonte de 15 minutos a frente.

As Figuras 4.6 e 4.7 ilustram o mesmo processo realizado para o horizonte de 30 minutos.

Figura 4.6: MAPEs médios das 5 redes variando o número de neurônios da camada oculta, horizonte de previsão de 30 minutos.

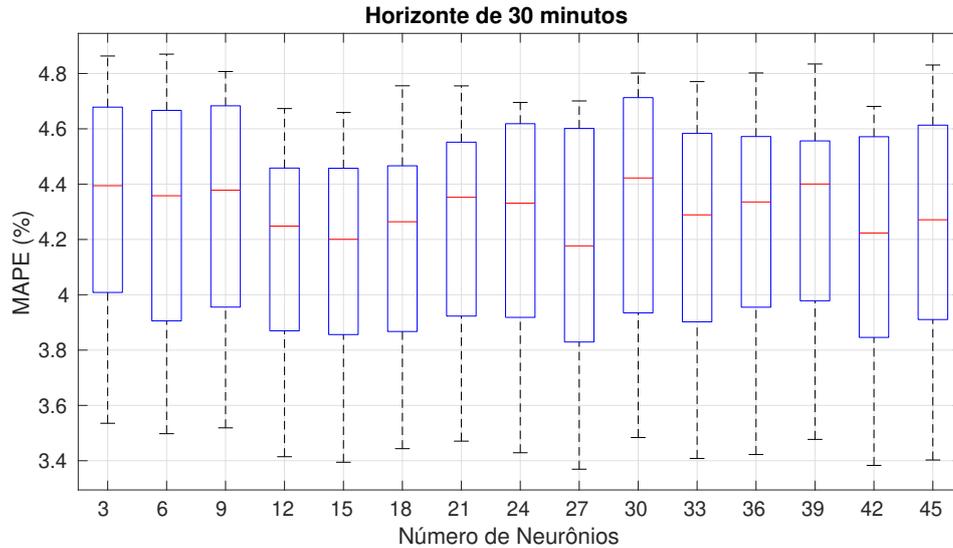


Fonte: Própria.

Observando o gráfico de caixas, a configuração escolhida foi a de 15 neurônios na camada oculta para prever no horizonte de 30 minutos a frente.

As Tabelas 4.2 e 4.3 mostram as configurações que serão utilizadas nas redes para realizar a previsão.

Figura 4.7: *Box Plot* dos MAPEs médios das 5 redes variando o número de neurônios da camada oculta, horizonte de previsão de 30 minutos.



Fonte: Própria.

Tabela 4.2: Configuração das redes *Feedforward* para o horizonte de 15 minutos.

Função de ativação	Algoritmo de treino utilizado	Quantidade de neurônios na camada oculta
<i>Log-sigmoid</i>	<i>Levenberg-Marquadt</i>	9

Tabela 4.3: Configuração das redes *Feedforward* para o horizonte de 30 minutos.

Função de ativação	Algoritmo de treino utilizado	Quantidade de neurônios na camada oculta
<i>Log-sigmoid</i>	<i>Levenberg-Marquadt</i>	15

4.1.5 Parâmetros do Modelo de Redes RBF

Para realizar o treinamento das redes de base radial, é necessário definir os seguintes hiperparâmetros:

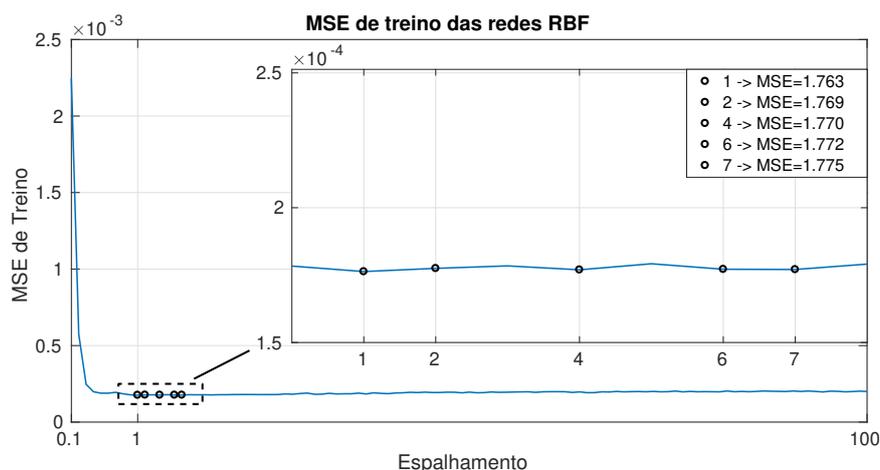
1. Valor da constante de espalhamento;
2. Valor do erro médio quadrático desejado na etapa de treino;
3. Quantidade máxima de neurônios na camada oculta.

O algoritmo de treinamento das redes RBF adiciona neurônios na camada oculta até alcançar o erro médio quadrático desejado definido. Caso o número de neurônios na camada oculta não seja o bastante para alcançar o erro, o algoritmo para e a rede é criada com o número máximo de neurônios definidos.

Para definir as constantes de espalhamento das redes RBF, foram testadas redes com o mesmo número de neurônios das redes *feedforward* que apresentaram os melhores desempenhos para os dois horizontes (9 e 27 neurônios para 15 minutos e 12 e 15 neurônios para 30 minutos). Os melhores desempenhos das redes RBF foram atingidos com 27 neurônios (para o horizonte de 15 minutos) e 15 neurônios (para o horizonte de 30 minutos). Com o número de neurônios definidos para os dois horizontes, a escolha das constantes de espalhamento das 5 redes para cada horizonte foi dada fazendo uma busca exaustiva, variando-se a constante de espalhamento de 0.1 a 1 em passos de 0.1 e de 1 a 100 em passos de 1, adotando-se o erro médio quadrático de treinamento igual a 0.0001. A Figura 4.8 mostra o resultado da busca para o horizonte de 15 minutos.

Nas Figuras 4.8 e 4.9, os círculos pretos na área destacada indicam os cinco menores MSEs atingidos no treino. Todas as redes foram criadas ajustando a quantidade máxima de neurônios para 27 (Figura 4.8) e 15 (Figura 4.9). Por não atingirem o MSE definido para o treino mas chegarem na quantidade máxima de neurônios, as redes são criadas pelo algoritmo. A pergunta a ser feita neste momento é a seguinte: *será que essas redes de 27 e 15 neurônios ainda tinham potencial para diminuir o MSE?* Para responder esta pergunta, foram escolhidos dois valores de constante de espalhamento, 1.0 para o horizonte de 15 minutos e 0.8 para o horizonte de 30 minutos. Com esses dois valores e com o erro de 0.0001 escolhido, ajustou-se para 250 o número máximo de neurônios na camada oculta na etapa de treinamento, e os resultados podem ser vistos nas Figuras 4.10 e 4.11.

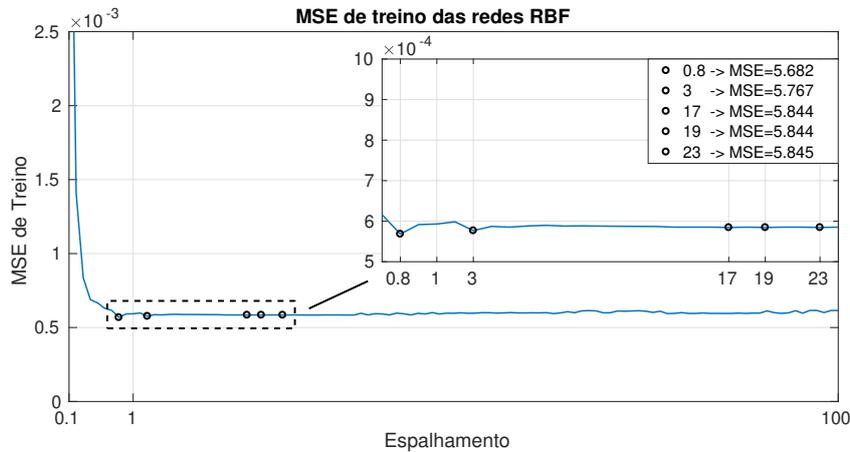
Figura 4.8: Variação da constante de espalhamento para redes RBF com 27 neurônios na camada oculta, horizonte de 15 minutos.



Fonte: Própria.

A Figura 4.9 mostra o resultado da busca para o horizonte de 30 minutos.

Figura 4.9: Variação da constante de espalhamento para redes RBF com 15 neurônios na camada oculta, horizonte de 30 minutos.

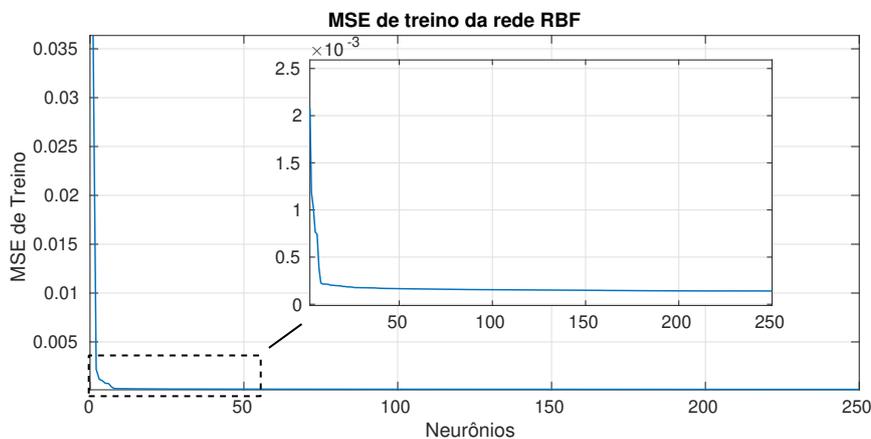


Fonte: Própria.

Observando as Figuras 4.10 e 4.11, de uma forma geral, nota-se que quando a quantidade de neurônios na camada oculta foi aumentada, o MSE de treinamento diminuiu, mas ainda assim, em abos casos, nem com 250 neurônios o erro de 0.0001 definido foi atingido. Chegando neste ponto, questiona-se, valeria realmente a pena aumentar tanto o tamanho das redes para atingirem os 0.0001 de erro médio quadrático? O desempenho seria tão diferente do que será proposto? A Tabela 4.4 foi proposta para mostrar o valor exato do MSE ao aumentar a quantidade de neurônios até 250.

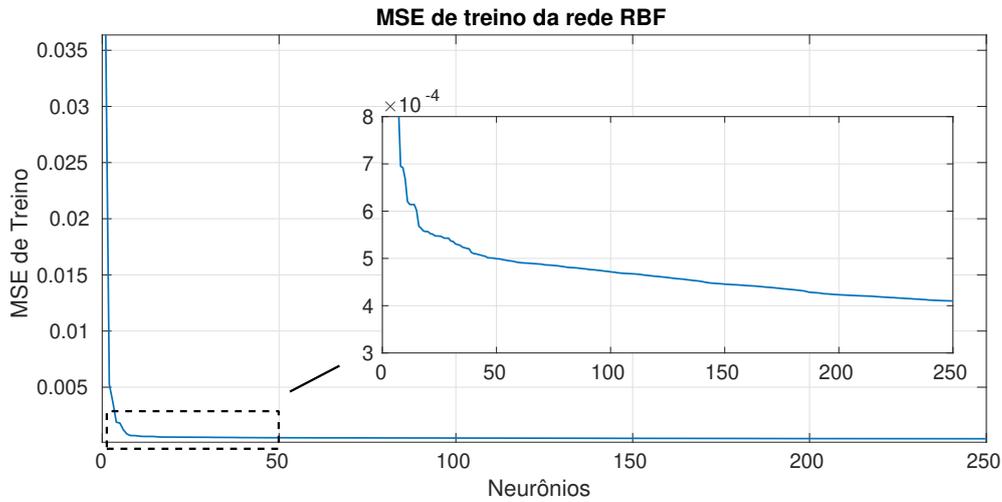
Da Tabela 4.4, nota-se que a redução no MSE foi mais significativa para o horizonte de 30 minutos. Como este estudo foi apenas investigativo, essas redes não serão utilizadas no trabalho, serão utilizadas redes de 27 e de 15 neurônios para comparar o desempenho com as redes *Feedforward*.

Figura 4.10: Variação do número de neurônios para a constante de espalhamento de 1.0, horizonte de 15 minutos.



Fonte: Própria.

Figura 4.11: Variação do número de neurônios para a constante de espalhamento de 0.8, horizonte de 30 minutos.



Fonte: Própria.

Tabela 4.4: Desempenho da rede RBF ao aumentar os neurônios na camada oculta para 250 nos dois horizontes de previsão.

Número de Neurônios	Constante de Espalhamento	Horizonte de Previsão	MSE de Treino	MSE de Treino com 250 Neurônios
27	1.0	15 minutos	0,0001763	0,0001407
15	0.8	30 minutos	0,0005682	0,0004097

Para o horizonte de 15 minutos, as configurações das 5 redes foram descritas na Tabela 4.5

Tabela 4.5: Configuração das Redes RBF

Horizonte de Previsão: 15 minutos	
Constante de Espalhamento	Número de Neurônios
1	27
2	
4	
6	
7	

Para o horizonte de 30 minutos, as configurações das 5 redes foram descritas na Tabela 4.6

Tabela 4.6: Configuração das Redes RBF

Horizonte de Previsão: 30 minutos	
Constante de Espalhamento	Número de Neurônios
0.8	15
3	
17	
19	
23	

4.1.6 Parâmetros do Modelo de Redes Neurais com Estado de Eco

Para realizar o treinamento das ESNs neste trabalho foram observados três hiperparâmetros da rede, são eles:

- Tamanho do reservatório;
- Taxa de vazamento α ;
- Raio espectral.

A escolha dos hiperparâmetros foi feita de forma manual e composta por duas buscas exaustivas: na primeira, o tamanho do reservatório e a taxa de vazamento foram variadas e na segunda apenas a taxa de vazamento foi variada.

Primeira Etapa

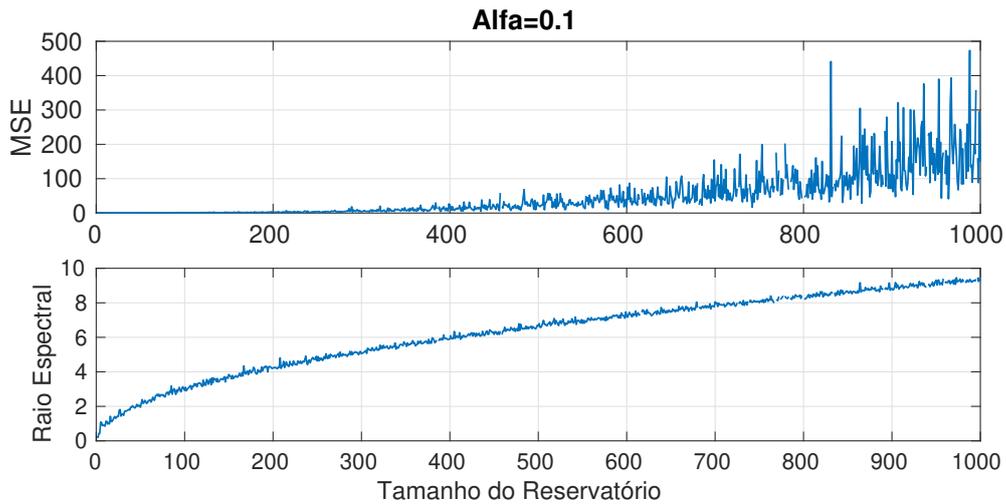
A primeira etapa serviu para definir o tamanho do reservatório e o raio espectral das redes. Foram fixados dez valores de taxa de vazamento e o tamanho do reservatório foi variado de 1 até 1000 para cada um dos valores de α . Em cada iteração realizada, o MSE da previsão foi calculado para os treze conjuntos de teste do Estudo de Caso 1 e a média do MSE para os 13 conjuntos foi guardada. Este processo foi feito para os dois horizontes de previsão. O raio espectral é o valor absoluto do maior autovalor da matriz de pesos recorrentes \mathbf{W} , dessa forma, cada vez que o tamanho do reservatório muda, o raio espectral também muda. A idéia do processo iterativo para cada valor fixo de α foi mostrado na Tabela 4.7:

Tabela 4.7: Exemplo dos processos de busca exaustiva.

Hiperparâmetros	Busca 1	Busca 2	...	Busca 10
α	0,1	0,2	...	1,0
Tamanho do Reservatório	1 até 1000	1 até 1000	...	1 até 1000

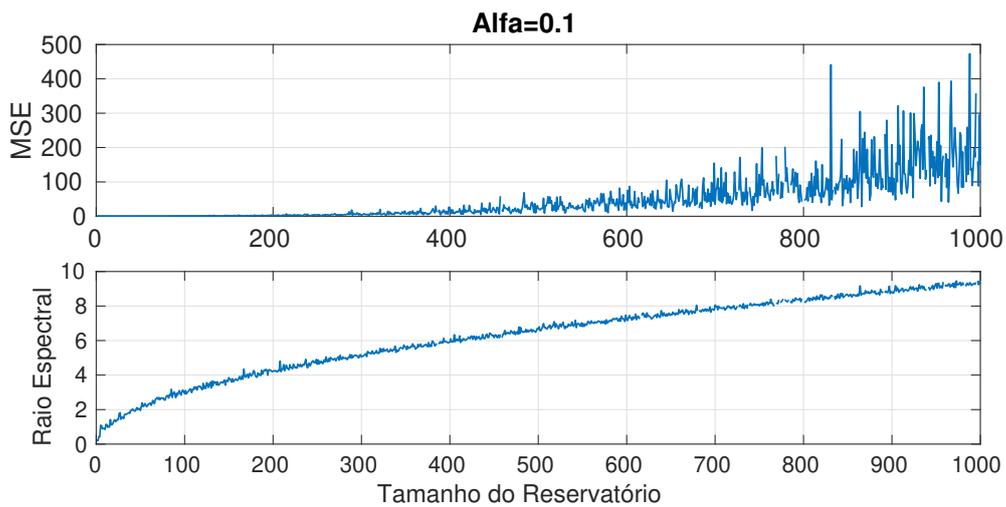
As Figuras 4.12 e 4.13 ilustram a Busca 1 para os horizontes de previsão de 15 minutos e de 30 minutos respectivamente. Nas Figuras, foram plotados o MSE médio dos 13 conjuntos de teste o raio espectral para cada variação do reservatório.

Figura 4.12: Busca 1 para o horizonte de 15 minutos.



Fonte: Própria.

Figura 4.13: Busca 1 para o horizonte de 30 minutos.



Fonte: Própria.

Segunda Etapa

A segunda etapa foi uma busca mais refinada para pequenas variações da taxa de vazamento. O processo se deu da seguinte forma: a configuração que mostrou o menor MSE nas dez buscas da Primeira Etapa foi selecionada (adotando o valor do tamanho do reservatório e do raio espectral dessa configuração) e o α foi variado no intervalo de $[(\alpha - 0,5), (\alpha + 0,5)]$ para o horizonte de 15 minutos e $[(\alpha - 0,25), (\alpha + 0,25)]$ para o horizonte de 30 minutos em passos de 0.01.

As Tabelas 4.8 e 4.9 mostram os menores erros e a respectiva configuração da ESN em cada processo de busca.

Tabela 4.8: Melhores configurações das redes em cada processo de busca no horizonte de 15 minutos.

	MSE med	Tamanho do Reservatório	Raio Espectral
Busca 1	1594,4	26	1,775
Busca 2	1585,6	1	0,220
Busca 3	1579,3	7	0,881
Busca 4	1575,8	16	1,423
Busca 5	1569,6	16	1,423
Busca 6	1566,7	14	1,059
Busca 7	1561,7	12	1,135
Busca 8	1555,2	12	1,135
Busca 9	1554,3	12	1,135
Busca 10	1554,3	14	1,06

Tabela 4.9: Melhores configurações das redes em cada processo de busca no horizonte de 30 minutos.

	MSE med	Tamanho do Reservatório	Raio Espectral
Busca 1	2665,1	39	1,956
Busca 2	2614,4	65	2,388
Busca 3	2529,4	60	2,335
Busca 4	2533,9	98	3,136
Busca 5	2482,2	51	2,181
Busca 6	2520,5	51	2,181
Busca 7	2512,2	200	4,230
Busca 8	2522,7	93	2,971
Busca 9	2531,1	93	2,971
Busca 10	2520,2	164	3,744

Note que na Tabela 4.8, a melhor configuração das Buscas 9 e 10 deram o mesmo valor de erro optou-se por usar a rede de menor reservatório.

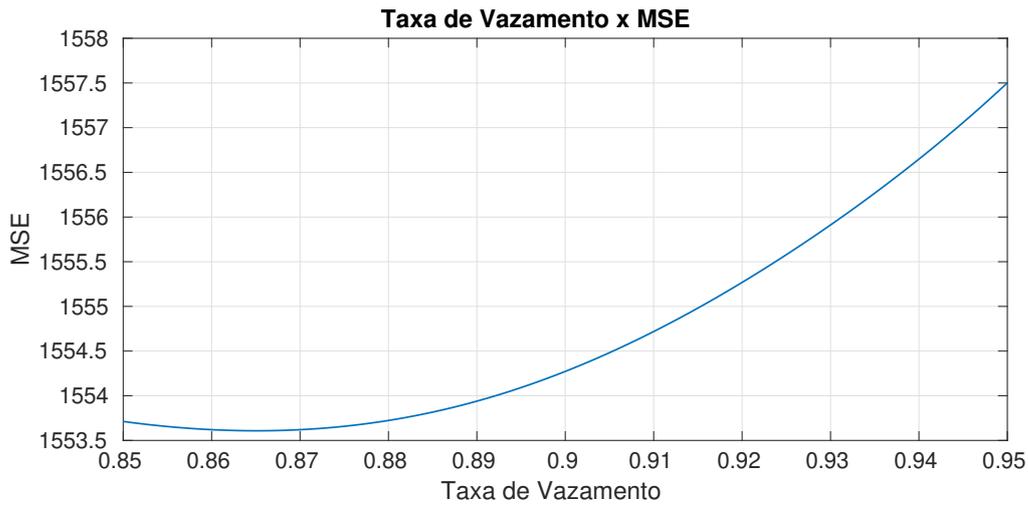
A Tabela 4.10 mostra a configuração de menor MSE para os dois horizontes de previsão e o intervalo em que o α foi variado para ambas.

Tabela 4.10: Configuração das ESNs de menor MSE.

Horizonte	Número da Busca	Intervalo de variação do alfa
15 minutos	9	[8,5 → 9,5]
30 minutos	5	[4,75 → 5,25]

A Figura 4.14 mostra variação do erro de acordo com a variação da taxa de vazamento para o horizonte de 15 minutos.

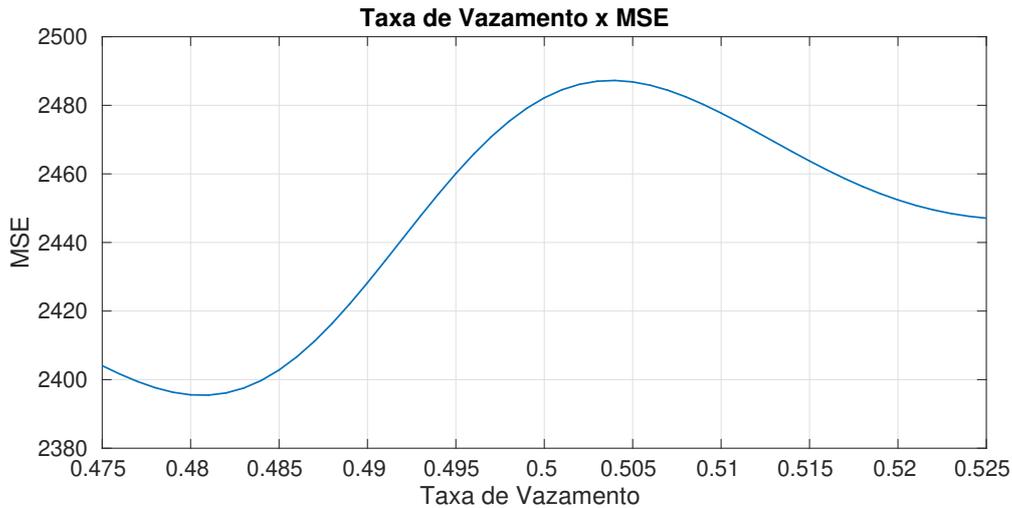
Figura 4.14: MSE versus α no horizonte de previsão de 15 minutos.



Fonte: Própria.

A Figura 4.15 mostra variação do erro de acordo com a variação da taxa de vazamento para o horizonte de 30 minutos.

Figura 4.15: MSE versus α no horizonte de previsão de 30 minutos.



Fonte: Própria.

Para os horizontes de 15 e 30 minutos, as configurações das 5 redes foram descritas na Tabela 4.11

Tabela 4.11: Configuração das redes ESN.

Horizonte	Taxa de Vazamento	Tamanho do Reservatório	Raio Espectral
15 minutos	0.865	16	1.135
30 minutos	0.481	51	2.181

Com o fim do ajuste dos parâmetros dos modelos, foram propostos três estudos de caso para avaliar a melhor forma de entrar com as informações temporais de

potência nos modelos. As seções seguintes mostram os resultados de cada estudo de caso.

4.2 Estudo de Caso 1

4.2.1 Resultados da Previsão Utilizando o Modelo *Naive*

Os resultados da previsão utilizando o método *Naive* foram mostrados nas Tabelas 4.12 e 4.13.

Tabela 4.12: Erros da Previsão para o horizonte de 15 minutos

Teste	MAE	MSE	MAPE (%)
Mar14	25,99	1798,86	3,53
Abr14	25,87	2045,70	3,66
Mai14	22,86	1422,56	3,46
Jun14	18,02	804,90	3,36
Jul14	15,84	622,34	3,26
Ago14	21,77	1128,26	3,56
Set14	24,48	1461,45	3,77
Out14	26,32	1723,22	3,73
Nov14	29,26	2225,08	3,75
Dez14	17,53	1495,06	3,64
Jan15	24,58	2017,78	3,70
Fev15	33,61	3776,60	4,42
Mar15	34,63	3577,35	3,96

Tabela 4.13: Erros da Previsão para o horizonte de 30 minutos

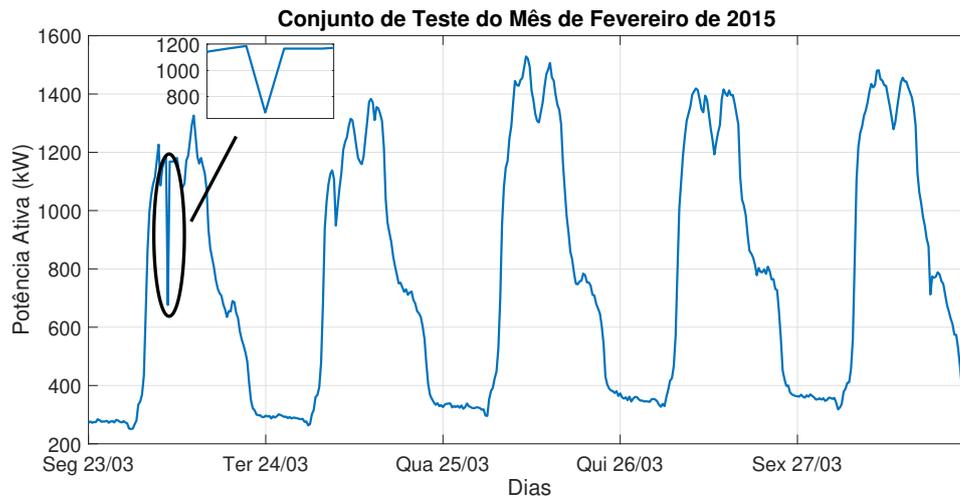
Teste	MAE	MSE	MAPE (%)
Mar14	48,23	6294,56	6,37
Abr14	48,72	7008,77	6,64
Mai14	41,72	4916,59	6,12
Jun14	32,85	2655,90	6,02
Jul14	27,27	1913,99	5,48
Ago14	39,32	3773,19	6,33
Set14	44,64	5100,63	6,70
Out14	49,05	5907,60	6,81
Nov14	55,37	7895,41	6,91
Dez14	29,47	2888,45	5,93
Jan15	44,57	5834,93	6,61
Fev15	60,41	10266,55	7,73
Mar15	65,44	12673,84	7,35

Da Tabela 4.12, a previsão *Naive* mostra bons resultados, com MAPE variando de 3,26% a 4,42% e MAE variando entre 15,84 kW a 34,63 kW de erro. Da Tabela

4.13, com o aumento da dificuldade na tarefa de previsão os erros aumentaram muito, mostrando MAPE entre 5,48% e 7,73%. erros médios e erros médios quadráticos bem superiores. De uma forma geral, o método *Naive* mostra erros altos quando há variação brusca e rápida no valor da potência ativa.

Um outro aspecto importante a ser destacado é a presença de alguns *outliers* em conjuntos de teste, como por exemplo o mês de Fevereiro de 2015, no qual os erros MAPE e MSE destoam muito dos valores dos outros conjuntos de teste na Tabela 4.13. A Figura 4.16 mostra o conjunto de teste do mês de Fevereiro de 2015.

Figura 4.16: *Outlier* na segunda feira da última semana do mês de fevereiro de 2015.



Fonte: Própria

Este tipo de *outlier* pode ter sido originado por algum problema interno do sistema elétrico da universidade ou por um problema momentâneo no fornecimento da energia, mas como pode ser visto, a potência não cai para zero. Isso também acontece nos meses de Dezembro de 2014 e Janeiro de 2015, mas as quedas na potência são menores.

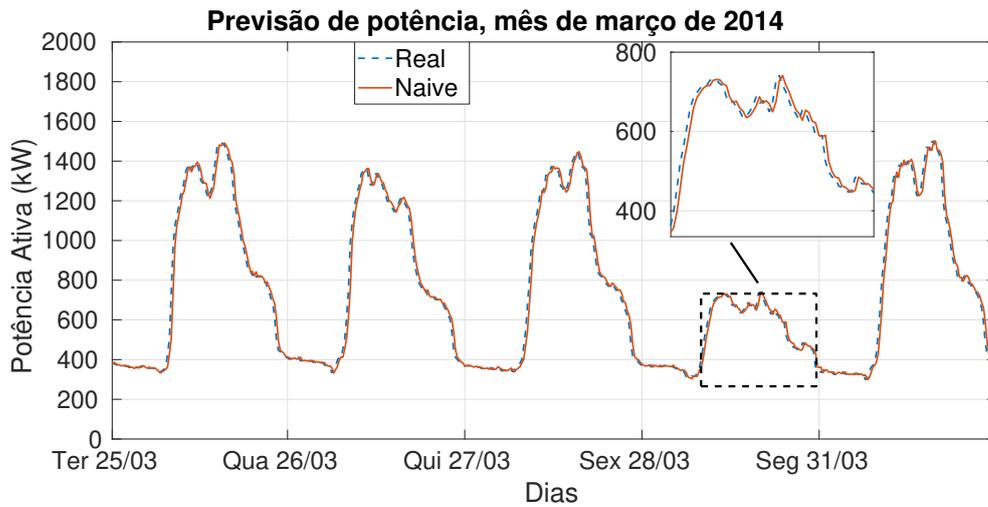
Pelo fato da potência não ter caído para valores abaixo de 240 kW, o dado não foi identificado como um *outlier*, portanto apenas foi identificado na etapa de teste dos preditores.

Nesses pontos de distúrbios momentâneos, cria-se uma grande diferença entre as curvas da previsão e a curva real e os erros tendem a aumentar.

A Figura 4.17 mostra a curva real e a curva do modelo *Naive* do mês de março de 2014 para o horizonte de 15 minutos.

A Figura 4.18 mostra a curva do erro absoluto do método *Naive* do mês de março de 2014 para o horizonte de 15 minutos.

Figura 4.17: Curva da previsão de potência, mês de março de 2014, horizonte de previsão de 15 minutos.



Fonte: Própria

Figura 4.18: Curva do erro absoluto, mês de março de 2014, horizonte de previsão de 15 minutos.

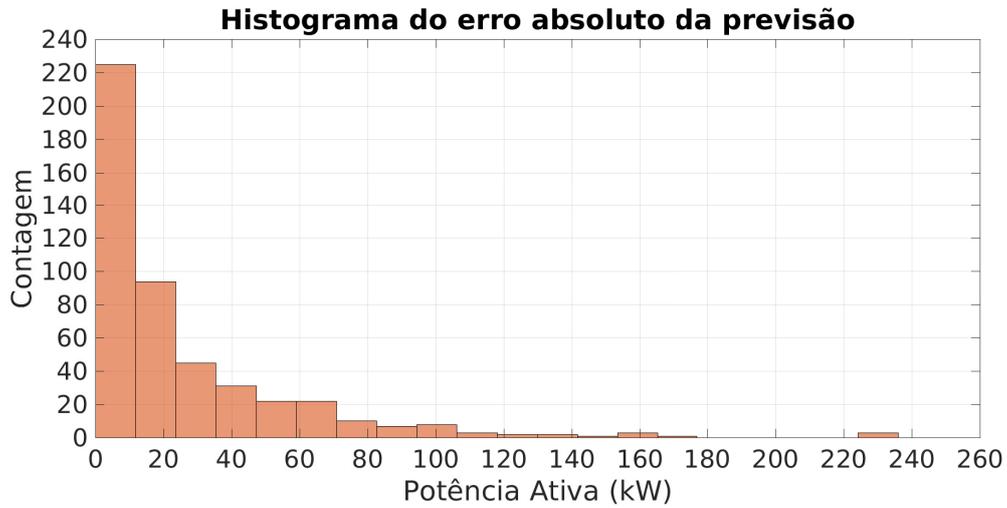


Fonte: Própria

A Figura 4.19 mostra o histograma do erro absoluto do método *Naive* do mês de março de 2014 para o horizonte de 15 minutos.

Como pode ser visto nas Figuras 4.18 e 4.19 o método *Naive* mostra muitos valores de erros absolutos na faixa de 100 e 200 kW e também acima de 200 kW, o que dificultaria muito a utilização deste método em uma aplicação real.

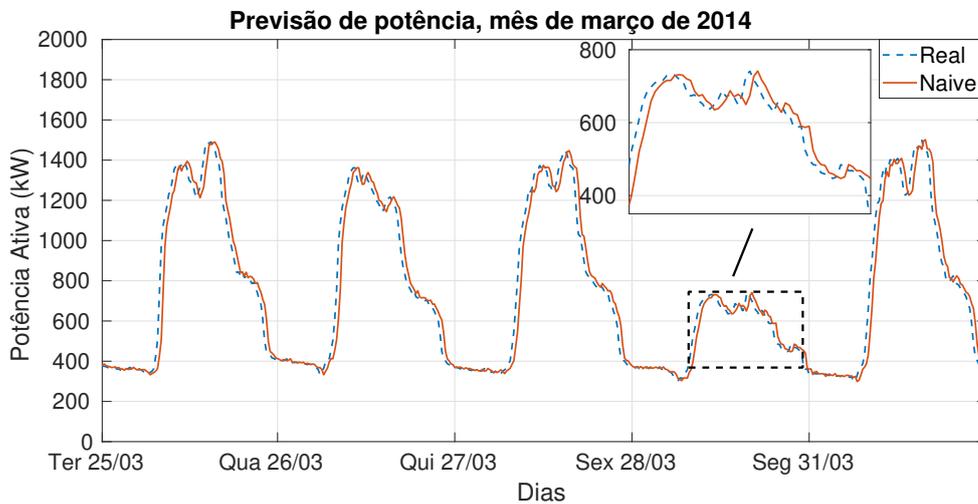
Figura 4.19: Histograma do erro absoluto, mês de março de 2014, horizonte de previsão de 15 minutos.



Fonte: Própria

A Figura 4.20 mostra a curva real e a curva do modelo *Naive* do mês de março de 2014 para o horizonte de 30 minutos.

Figura 4.20: Curva da previsão de potência, mês de março de 2014, horizonte de previsão de 30 minutos.



Fonte: Própria

A Figura 4.21 mostra a curva do erro absoluto do método *Naive* do mês de março de 2014 para o horizonte de 30 minutos.

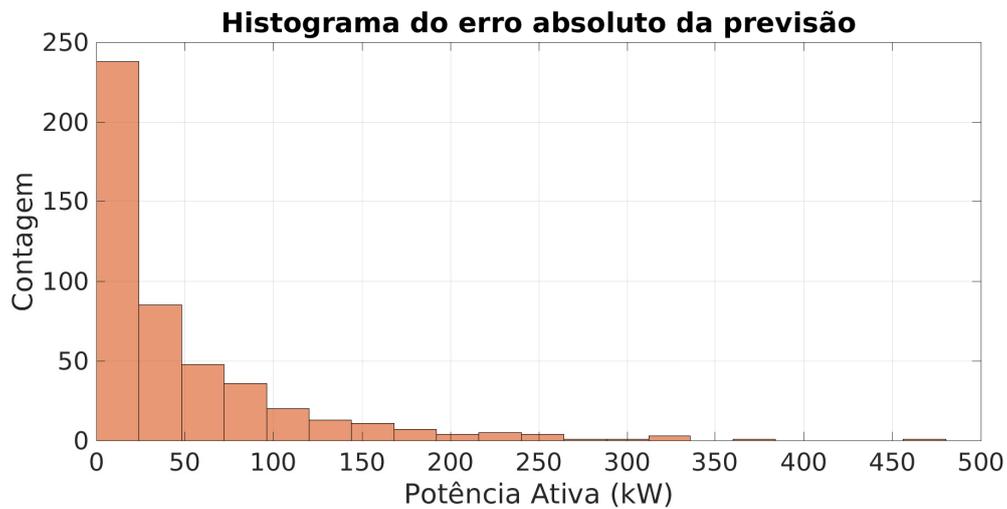
A Figura 4.22 mostra o histograma do erro absoluto do método *Naive* do mês de março de 2014 para o horizonte de 30 minutos.

Figura 4.21: Curva do erro absoluto, mês de março de 2014, horizonte de previsão de 30 minutos.



Fonte: Própria

Figura 4.22: Histograma do erro absoluto, mês de março de 2014, horizonte de previsão de 30 minutos.



Fonte: Própria

Visualmente falando, observando apenas as Figuras 4.17 e 4.20, o método Naive aparenta ser muito bom por se tratar da própria série defasada de 1 passo e de 2 passos respectivamente. Olhando apenas para os gráficos da previsão, não seria necessário partir para métodos mais complexos para a resolução deste problema. Porém, ao analisar as curvas e histogramas de erro absoluto no horizonte de 30 minutos, o método se mostra pouco robusto e chega a atingir a faixa entre 400 e 500 kW (nos pontos onde há oscilação rápida na curva da potência), mostrando a necessidade de utilizar métodos mais robustos e consolidados para solução deste tipo

de problema.

4.2.2 Resultados da Previsão Utilizando o Modelo SARIMA

Os resultados da previsão utilizando o modelo SARIMA foram mostrados nas Tabelas 4.14 e 4.15.

Tabela 4.14: Erros da Previsão para o horizonte de 15 minutos

Teste	MAE	MSE	MAPE (%)
Mar14	22,65	1141,79	3,22
Abr14	19,39	1049,07	3,15
Mai14	18,63	796,15	2,97
Jun14	14,32	446,75	2,66
Jul14	14,91	517,27	3,18
Ago14	16,52	583,05	2,70
Set14	18,03	670,97	2,83
Out14	17,14	620,32	2,51
Nov14	16,39	617,35	2,14
Dez14	16,63	1281,54	3,54
Jan15	17,62	1138,00	2,83
Fev15	25,80	3374,70	3,39
Mar15	18,73	838,66	2,17

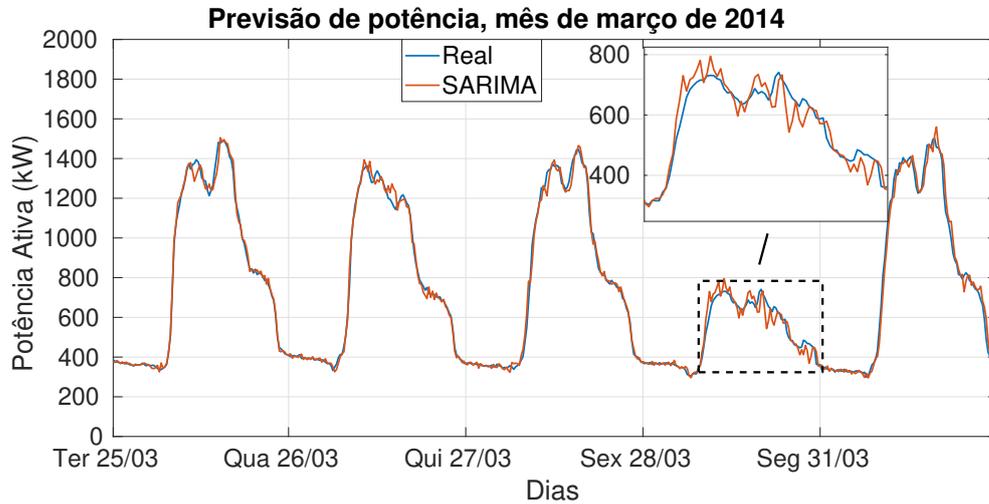
Tabela 4.15: Erros da Previsão para o horizonte de 30 minutos

Teste	MAE	MSE	MAPE (%)
Mar14	36,73	3187,41	5,08
Abr14	29,76	2542,41	4,75
Mai14	28,42	1977,53	4,48
Jun14	19,97	970,01	3,70
Jul14	21,20	1145,27	4,41
Ago14	23,72	1215,48	3,80
Set14	26,72	1601,30	4,06
Out14	25,62	1377,11	3,70
Nov14	24,07	1400,81	2,99
Dez14	23,62	1906,71	4,96
Jan15	24,05	1956,91	3,80
Fev15	35,24	4773,19	4,49
Mar15	26,59	1682,82	3,07

Como segundo método estatístico proposto nesse trabalho, o SARIMA mostrou resultados melhores quando comparados com o método *Naive*, principalmente no horizonte de 30 minutos, onde se mostra muito mais robusto. Houve uma redução de mais de 50% no MAE do conjunto de teste do mês de fevereiro de 2015 em relação ao *Naive* o que mostra maior robustez do método.

A Figura 4.23 mostra a curva real e a curva do modelo SARIMA do mês de março de 2014 para o horizonte de 15 minutos.

Figura 4.23: Curva da previsão de potência, mês de março de 2014, horizonte de previsão de 15 minutos.



Fonte: Própria

A Figura 4.24 mostra a curva do erro absoluto do modelo SARIMA do mês de março de 2014 para o horizonte de 15 minutos.

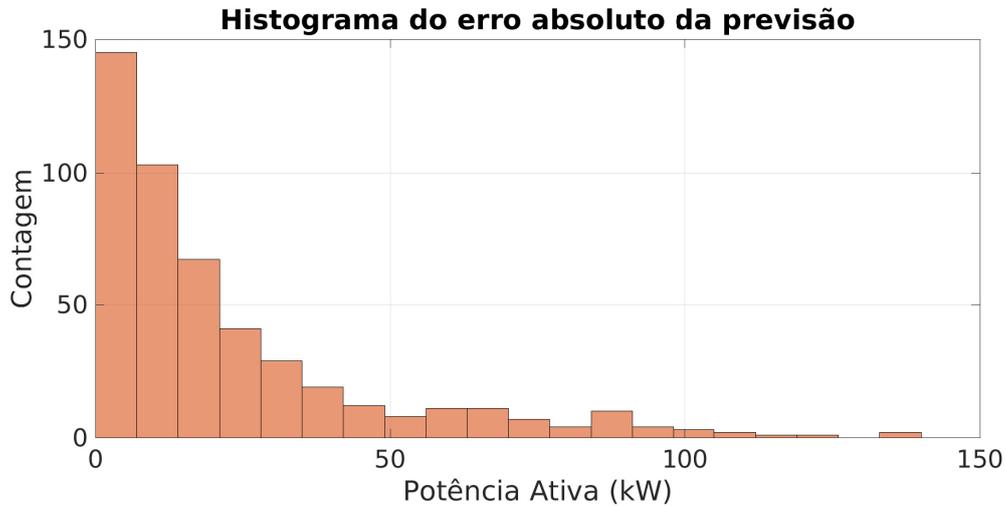
Figura 4.24: Curva do erro absoluto, mês de março de 2014, horizonte de previsão de 15 minutos.



Fonte: Própria

A Figura 4.25 mostra o histograma do erro absoluto do modelo SARIMA do mês de março de 2014 para o horizonte de 15 minutos.

Figura 4.25: Histograma do erro absoluto, mês de março de 2014, horizonte de previsão de 15 minutos.

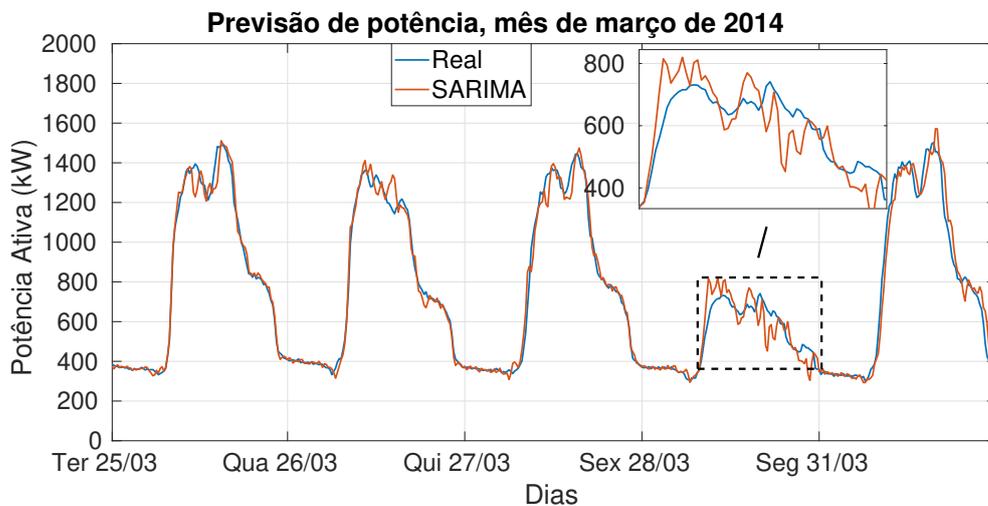


Fonte: Própria

Das Figuras 4.24 e 4.25, nota-se que o método mostrou comportamento melhor em relação ao erro absoluto quando comparado ao *Naive*, o que era esperado pela melhoria nos valores dos erros nas Tabelas 4.14 e 4.15. No que diz respeito ao erro em kW, o método também possui uma região onde os erros são mais concentrados, ela fica na faixa dos horários entre as 11:00 e 16:00 horas, que é o intervalo onde ocorrem dois picos diários de potência e a queda da potência no horário do almoço.

A Figura 4.26 mostra a curva real e a curva do modelo SARIMA do mês de março de 2014 para o horizonte de 30 minutos.

Figura 4.26: Curva da previsão de potência, mês de março de 2014, horizonte de previsão de 30 minutos.



Fonte: Própria

A Figura 4.27 mostra a curva do erro absoluto do modelo SARIMA do mês de março de 2014 para o horizonte de 30 minutos.

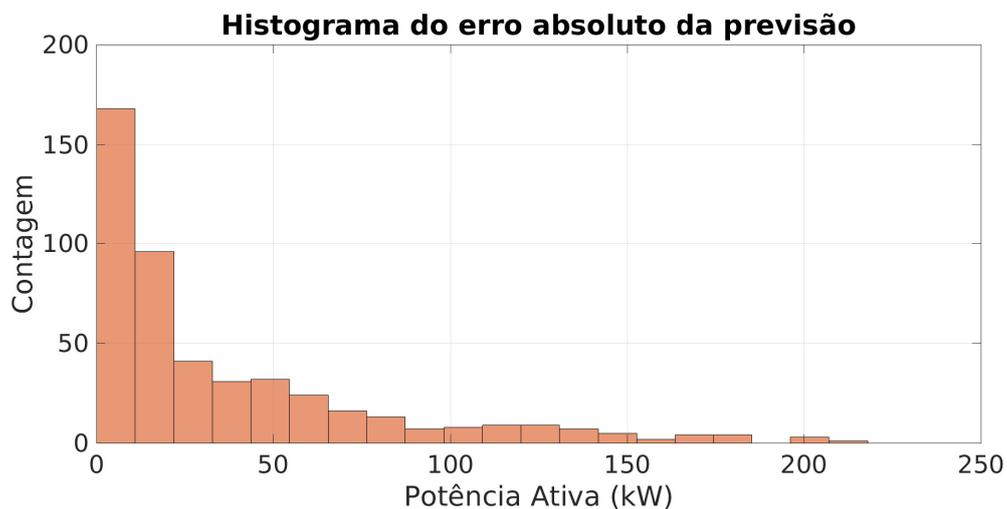
Figura 4.27: Curva do erro absoluto, mês de março de 2014, horizonte de previsão de 30 minutos.



Fonte: Própria

A Figura 4.28 mostra o histograma do erro absoluto do modelo SARIMA do mês de março de 2014 para o horizonte de 30 minutos.

Figura 4.28: Histograma do erro absoluto, mês de março de 2014, horizonte de previsão de 30 minutos.



Fonte: Própria

Quando a tarefa da previsão é aumentada (previsão de 2 passos a frente), o SARIMA mostra picos de erro absoluto na faixa dos 100 e 200 kW e se mostra bem mais presente na faixa dos 100 kW quando comparada com a previsão no horizonte

de 15 minutos. A dificuldade do modelo em prever a região dos dois picos e a queda no horário do almoço foi evidenciada neste horizonte de previsão.

4.2.3 Resultados da Previsão das RNAs *Feedforward*

Após os estudos desenvolvidos, a previsão de potência de curto prazo foi realizada para os horizontes de 15 (1 passo) e 30 minutos (2 passos) a frente, e os resultados foram mostrados nas Tabelas 4.16 e 4.17. A coluna Med na tabela representa a média dos erros das 5 redes neurais, a coluna DP o desvio padrão dos erros das 5 redes e a coluna Ens trata do modelo combinado. Os erros relativos à rede que apresentou menor MAPE para a maioria dos conjuntos de teste foi exibida no campo “M.R.”.

Tabela 4.16: Erros da Previsão das redes *feedforward* para o horizonte de 15 minutos

Teste	MAE				MSE				MAPE (%)			
	Med	DP	M.R.	Ens	Med	DP	M.R.	Ens	Med	DP	M.R.	Ens
Mar14	18,90	1,16	17,88	17,94	945,58	488,74	650,28	702,58	2,68	0,17	2,53	2,55
Abr14	16,54	0,57	15,95	15,75	739,31	78,84	653,81	662,17	2,59	0,07	2,54	2,48
Mai14	15,55	0,38	15,46	15,21	532,52	24,47	527,01	510,00	2,46	0,06	2,45	2,41
Jun14	12,85	0,21	12,96	12,67	364,81	21,10	371,25	348,64	2,38	0,04	2,41	2,34
Jul14	11,40	0,17	11,58	11,29	285,05	7,53	290,66	280,33	2,41	0,05	2,45	2,39
Ago14	13,32	0,07	13,29	13,25	376,35	3,99	371,62	371,29	2,16	0,02	2,17	2,15
Set14	14,70	0,20	14,68	14,63	447,78	15,27	436,27	441,16	2,32	0,03	2,32	2,31
Out14	14,90	0,37	15,09	14,76	480,12	15,95	492,99	470,99	2,11	0,05	2,14	2,09
Nov14	14,07	0,18	14,09	13,89	428,37	12,35	423,56	420,56	1,87	0,03	1,89	1,85
Dez14	13,45	0,41	13,51	13,29	1108,25	280,26	1003,66	1038,55	2,86	0,07	2,88	2,83
Jan15	14,78	0,22	14,86	14,58	761,48	27,82	769,80	746,25	2,34	0,04	2,36	2,31
Fev15	19,42	0,71	19,69	18,84	1485,19	74,98	1516,23	1374,90	2,72	0,09	2,77	2,66
Mar15	18,15	0,81	18,17	17,45	812,39	50,10	784,20	699,76	2,03	0,07	2,05	1,98

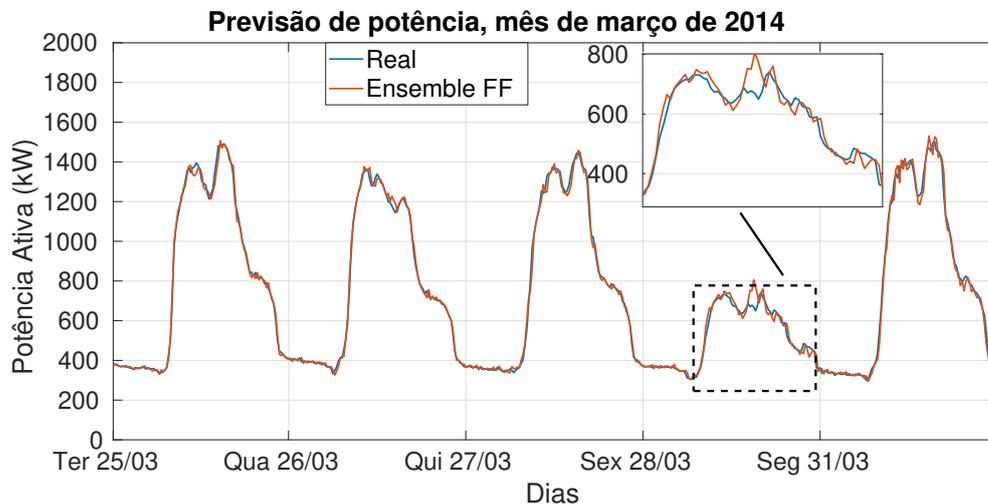
Das Tabelas 4.16 e 4.17, pode-se perceber que a melhor das redes apresentou menores erros em quase todos os conjuntos de teste quando comparada à média dos erros das redes. Percebe-se também que o modelo combinado mostrou menores erros do que a melhor das redes em quase todos os conjuntos de teste. Este é um comportamento esperado ao realizar a combinação dos modelos, pois o comportamento que o *ensemble* médio traz tem o objetivo de suavizar as saídas dos modelos. Portanto, nas tabelas dos próximos métodos de IA a coluna da melhor rede será retirada para melhorar a visualização e reduzir a quantidade de informações. As redes *feedforward* mostraram melhoria no desempenho quando comparadas aos dois métodos estatísticos.

A Figura 4.29 mostra a curva real e a curva do modelo combinado de redes *feedforward* do mês de março de 2014 para o horizonte de previsão de 15 minutos.

Tabela 4.17: Erros da Previsão das redes *feedforward* para o horizonte de 30 minutos

Teste	MAE			MSE			MAPE (%)		
	Med	DP	Ens	Med	DP	Ens	Med	DP	Ens
Mar14	32,19	1,96	30,23	2333,87	361,74	1985,79	4,46	0,21	4,24
Abr14	29,88	0,58	28,35	2389,57	103,67	2164,30	4,60	0,09	4,40
Mai14	27,01	0,83	26,36	1723,07	118,91	1643,15	4,26	0,16	4,17
Jun14	23,22	0,43	22,89	1293,03	81,59	1242,26	4,33	0,07	4,27
Jul14	20,67	0,18	20,37	910,91	12,67	890,32	4,32	0,08	4,25
Ago14	23,23	0,39	22,96	1142,72	31,68	1121,48	3,82	0,09	3,77
Set14	25,70	0,52	25,45	1449,73	62,09	1419,81	4,00	0,10	3,95
Out14	26,41	0,90	26,09	1436,90	88,14	1392,97	3,82	0,13	3,77
Nov14	25,80	0,42	25,44	1516,94	66,37	1478,48	3,41	0,07	3,36
Dez14	22,26	0,78	21,91	1573,20	335,65	1490,30	4,72	0,14	4,64
Jan15	25,52	0,33	24,97	1913,49	58,66	1837,19	4,10	0,06	4,01
Fev15	34,07	1,22	32,79	3645,35	1046,44	3002,70	4,59	0,12	4,46
Mar15	32,48	1,01	30,95	2653,93	220,19	2423,17	3,83	0,11	3,70

Figura 4.29: Curvas da previsão de potência, mês de março de 2014, horizonte de previsão de 15 minutos.



Fonte: Própria

A Figura 4.30 mostra a curva do erro absoluto do modelo combinado de redes *feedforward* do mês de março de 2014 para o horizonte de previsão de 15 minutos.

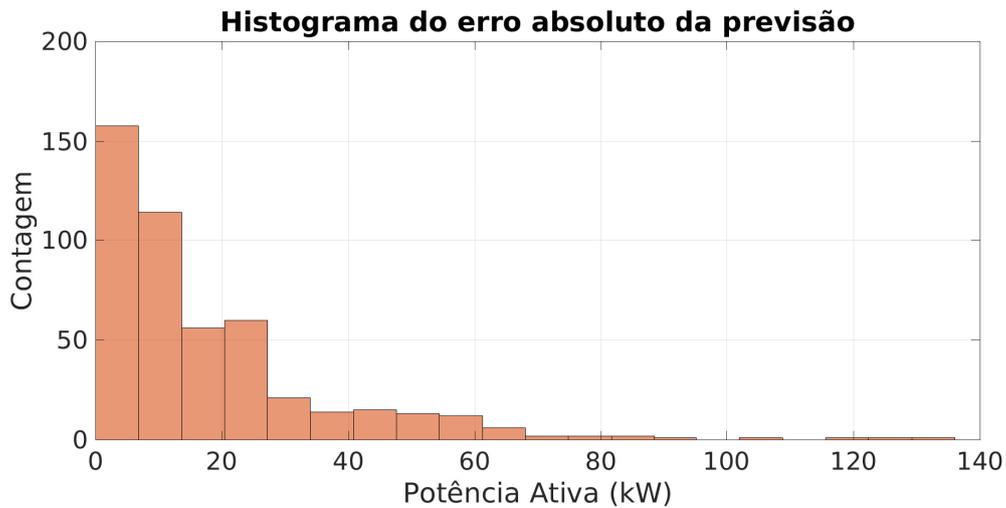
A Figura 4.31 mostra o histograma do erro absoluto do modelo combinado de redes *feedforward* do mês de março de 2014 para o horizonte de 15 minutos.

Figura 4.30: Curva do erro absoluto, mês de março de 2014, horizonte de previsão de 15 minutos.



Fonte: Própria

Figura 4.31: Histograma do erro absoluto, mês de março de 2014, horizonte de previsão de 15 minutos.



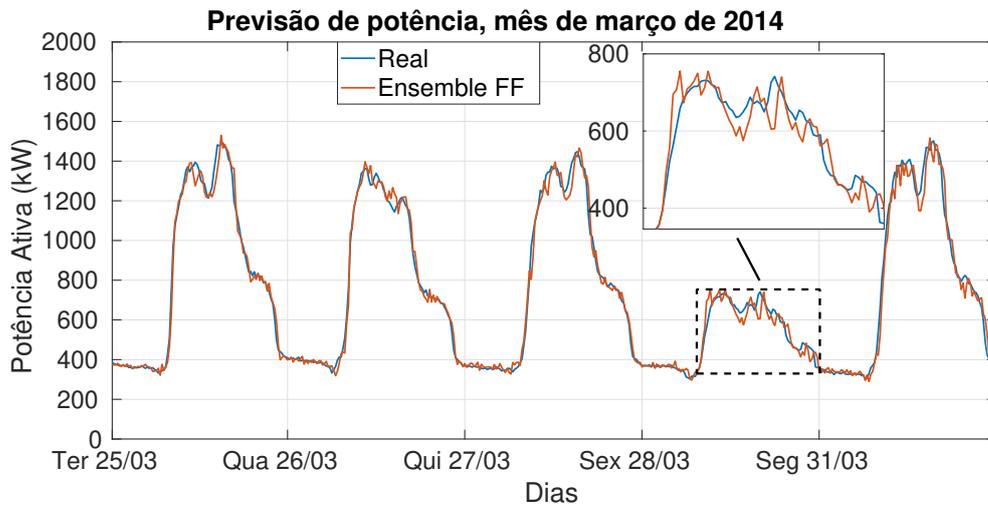
Fonte: Própria

Das Figuras 4.30 e 4.31, é possível notar que as redes *feedforward* atenuaram os erros nos picos de potência diários e na queda de potência durante o horário do almoço e mostraram erro absoluto muito menos presente na faixa dos 100 kW. O modelo apresentou dificuldade em prever potência no dia atípico, o que também é esperado pois não há muitos dias atípicos no conjunto de treino.

A Figura 4.32 mostra a curva real e a curva do modelo combinado das redes *feedforward* do mês de março de 2014 para o horizonte de previsão de 30 minutos.

A Figura 4.33 mostra a curva do erro absoluto do modelo combinado das redes *feedforward* do mês de março de 2014 para o horizonte de previsão de 30 minutos.

Figura 4.32: Curva da previsão de potência, mês de março de 2014, horizonte de previsão de 30 minutos.



Fonte: Própria

Figura 4.33: Curva do erro absoluto, mês de março de 2014, horizonte de previsão de 30 minutos.

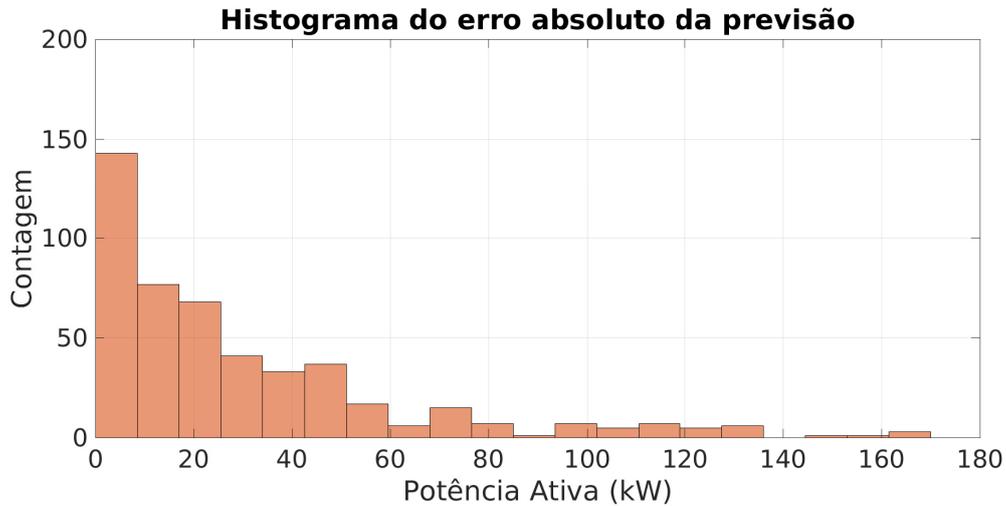


Fonte: Própria

A Figura 4.34 mostra o histograma do erro absoluto do modelo combinado de redes *feedforward* do mês de março de 2014 para o horizonte de previsão de 15 minutos.

Das Figuras 4.33 e 4.34, nota-se o mesmo comportamento do SARIMA, o modelo erra mais nas regiões dos picos diários. O modelo combinado de redes *feedforward* mostrou erros mais presentes na faixa dos 100 kW quando comparado com o horizonte de 15 minutos e mostrou erros absolutos menores do que os modelos estatísticos.

Figura 4.34: Histograma do erro absoluto, mês de março de 2014, horizonte de previsão de 30 minutos.



Fonte: Própria

4.2.4 Resultados da Previsão das Redes RBF

Após os estudos desenvolvidos, a previsão de potência de curto prazo foi realizada para os horizontes de 15 (1 passo) e 30 minutos (2 passos) a frente com as redes RBF, e os resultados foram mostrados nas Tabelas 4.18 e 4.19.

Tabela 4.18: Erros da Previsão das redes de base radial para o horizonte de 15 minutos,

Teste	MAE			MSE			MAPE (%)		
	Med	DP	Ens	Med	DP	Ens	Med	DP	Ens
Mar14	19,11	0,27	18,99	763,28	14,16	748,38	2,71	0,03	2,69
Abr14	16,86	0,16	16,80	743,25	7,21	736,48	2,69	0,02	2,68
Mai14	15,93	0,06	15,86	553,20	2,53	548,94	2,57	0,01	2,56
Jun14	12,85	0,08	12,82	379,04	6,50	376,54	2,38	0,01	2,38
Jul14	11,51	0,04	11,48	281,04	2,10	280,21	2,47	0,01	2,47
Ago14	13,30	0,10	13,27	372,68	4,62	371,44	2,17	0,01	2,17
Set14	14,99	0,08	14,97	463,70	9,67	461,98	2,37	0,01	2,37
Out14	15,23	0,06	15,18	491,99	4,99	489,25	2,18	0,01	2,17
Nov14	14,62	0,05	14,56	473,28	4,39	470,84	1,96	0,01	1,96
Dez14	13,54	0,07	13,47	1076,61	14,35	1071,36	2,90	0,01	2,89
Jan15	15,18	0,05	15,13	824,59	10,65	821,91	2,40	0,01	2,40
Fev15	20,55	0,08	20,49	1653,79	26,89	1644,48	2,87	0,01	2,86
Mar15	18,10	0,09	17,97	781,46	11,76	766,04	2,07	0,00	2,06

Nas Tabelas 4.18 e 4.19 nota-se que o desvio padrão entre as redes foi muito pequeno devido ao MSE de treino das ter sido muito parecido na etapa de treino.

Os resultados das redes RBF foram muito parecidos com os resultados das redes *feedforward*.

A presença de alguns *outliers* nos dados dos conjuntos de teste dos meses de Dezembro de 2014 e Fevereiro de 2015 destoam o valor do MAPE e do MSE dos valores dos outros conjuntos de teste na Tabela 4.18.

Tabela 4.19: Erros da Previsão das redes de base radial para o horizonte de 30 minutos,

Teste	MAE			MSE			MAPE (%)		
	Med	DP	Ens	Med	DP	Ens	Med	DP	Ens
Mar14	34,84	0,43	34,46	2641,93	120,22	2563,19	4,88	0,03	4,84
Abr14	32,13	0,60	31,84	2744,26	113,81	2700,85	4,94	0,06	4,90
Mai14	28,14	0,18	27,94	1869,95	22,26	1843,73	4,57	0,01	4,55
Jun14	23,69	0,31	23,39	1476,55	38,64	1456,36	4,43	0,07	4,38
Jul14	20,59	0,26	20,48	861,50	19,39	852,82	4,41	0,06	4,38
Ago14	23,74	0,27	23,65	1171,13	10,85	1160,48	4,00	0,06	3,99
Set14	26,95	0,18	26,81	1621,46	27,61	1611,19	4,22	0,06	4,20
Out14	27,40	0,18	27,25	1608,62	18,83	1590,84	4,00	0,04	3,98
Nov14	27,82	0,22	27,64	1913,06	93,96	1896,44	3,68	0,00	3,66
Dez14	22,92	0,34	22,83	2044,26	46,04	2035,49	4,90	0,09	4,88
Jan15	27,12	0,15	26,97	2294,96	12,13	2282,61	4,34	0,05	4,32
Fev15	38,63	0,20	38,42	4858,16	201,57	4829,05	5,14	0,04	5,11
Mar15	34,32	0,47	33,70	3070,16	31,60	2978,15	4,06	0,05	4,01

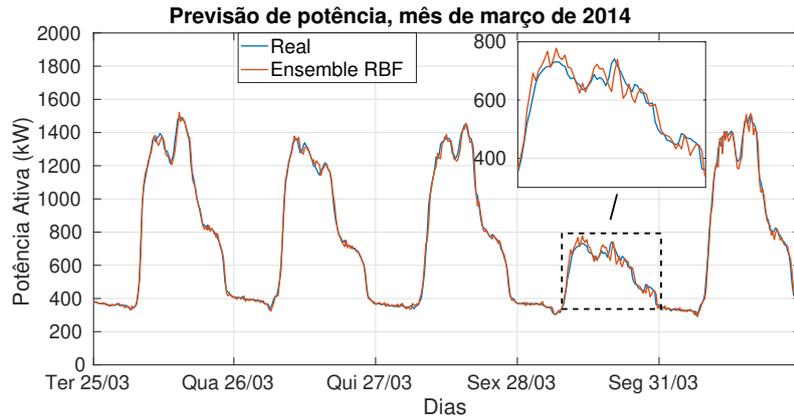
A Figura 4.35 mostra a curva real e a curva do modelo combinado das redes RBF do mês de março de 2014 para o horizonte de previsão de 15 minutos.

A Figura 4.36 mostra a curva do erro absoluto do modelo combinado de redes RBF do mês de março de 2014 para o horizonte de previsão de 15 minutos.

A Figura 4.37 mostra o histograma do erro absoluto do modelo combinado de redes RBF do mês de março de 2014 para o horizonte de previsão de 15 minutos.

Como pode ser visto na Figuras 4.36 e 4.37, o comportamento no erro absoluto das redes RBF foi muito parecido com o das redes *feedforward*, porém o desempenho foi pior. O modelo apresentou erros menores no dia atípico em relação ao modelo combinado de redes *feedforward*.

Figura 4.35: Curva da previsão de potência, mês de março de 2014, horizonte de previsão de 15 minutos.



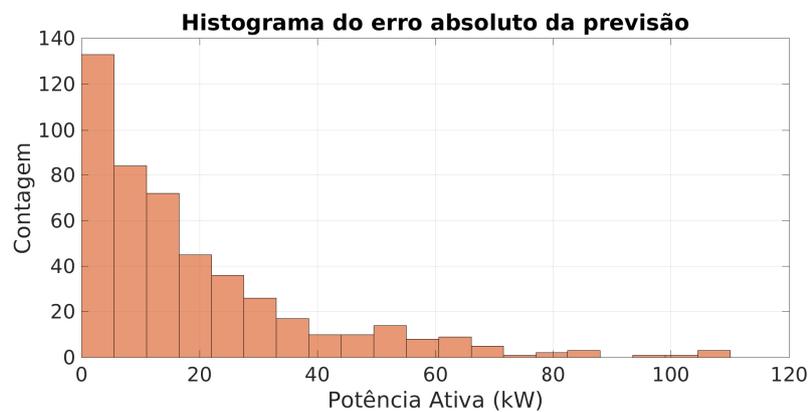
Fonte: Própria

Figura 4.36: Curva do erro absoluto, mês de março de 2014, horizonte de previsão de 15 minutos.



Fonte: Própria

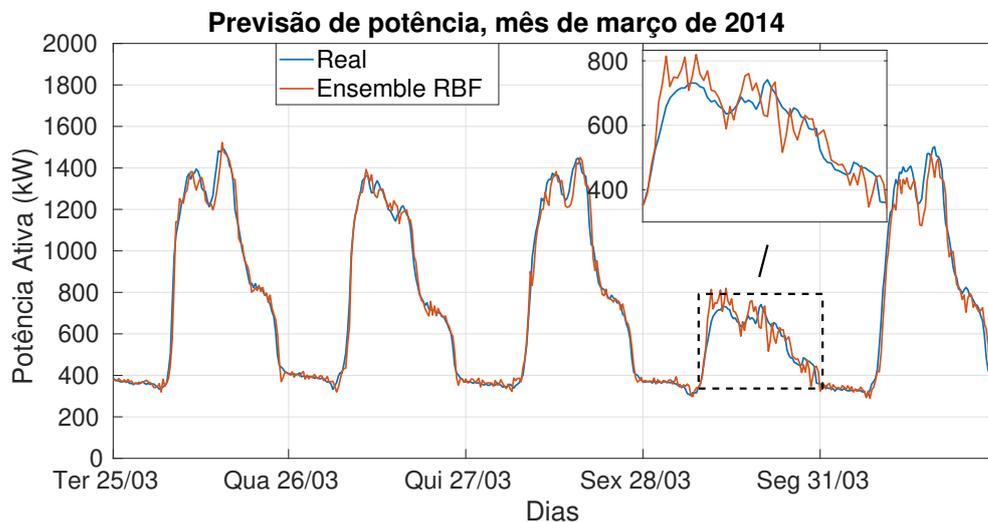
Figura 4.37: Histograma do erro absoluto, mês de março de 2014, horizonte de previsão de 15 minutos.



Fonte: Própria

A Figura 4.38 mostra a curva real e a curva do modelo combinado das redes RBF do mês de março de 2014 para o horizonte de previsão de 30 minutos.

Figura 4.38: Curva da previsão de potência, mês de março de 2014, horizonte de previsão de 30 minutos.



Fonte: Própria

A Figura 4.39 mostra a curva do erro absoluto do modelo combinado de redes RBF do mês de março de 2014 para o horizonte de previsão de 30 minutos.

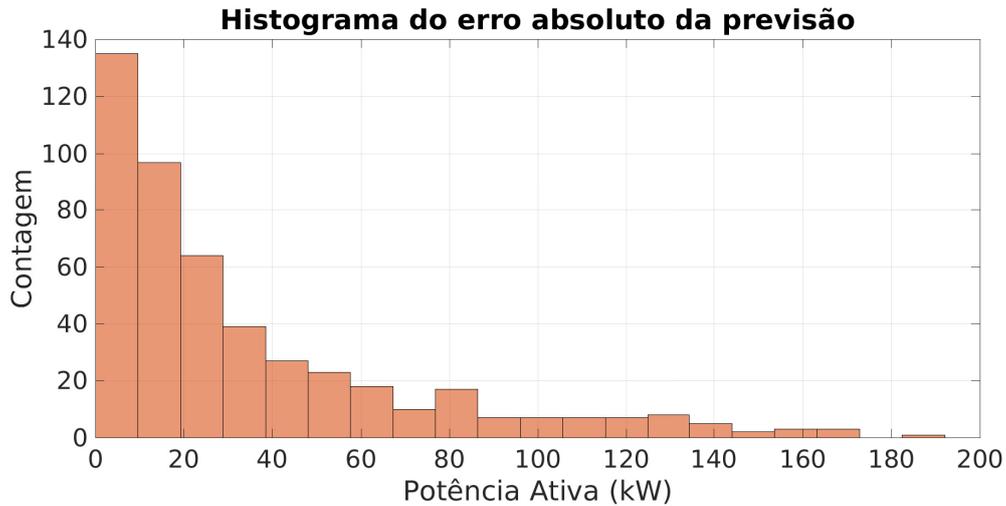
Figura 4.39: Curva do erro absoluto, mês de março de 2014, horizonte de previsão de 30 minutos.



Fonte: Própria

A Figura 4.40 mostra o histograma do erro absoluto do modelo combinado de redes RBF do mês de março de 2014 para o horizonte de previsão de 30 minutos.

Figura 4.40: Histograma do erro absoluto, mês de março de 2014, horizonte de previsão de 30 minutos.



Fonte: Própria

O modelo combinado de redes RBF mostrou a mesma dificuldade do modelo de redes *feedforward* no horizonte de 30 minutos e registrou picos de erro absoluto na faixa dos 100 a 200 kW.

4.2.5 Resultados da Previsão das ESNs

Após os estudos e definição das configurações das ESNs, a previsão de potência foi realizada para os horizontes de 15 e 30 minutos, e os resultados foram mostrados nas Tabelas 4.20 e 4.21.

Tabela 4.20: Erros da previsão para as ESNs no horizonte de 15 minutos

Teste	MAE			MSE			MAPE (%)		
	Med	DP	Ens	Med	DP	Ens	Med	DP	Ens
Mar14	29,42	0,71	28,82	1860,56	90,92	1779,65	4,28	0,11	4,21
Abr14	27,68	0,31	27,31	1962,44	42,86	1904,74	4,45	0,08	4,40
Mai14	26,26	0,31	25,78	1499,25	16,90	1462,94	4,30	0,05	4,22
Jun14	20,59	0,59	20,31	1218,27	52,60	1195,94	3,89	0,07	3,83
Jul14	18,11	0,25	17,95	637,15	26,57	628,21	3,92	0,05	3,88
Ago14	21,39	0,22	21,25	867,44	18,42	856,64	3,68	0,04	3,65
Set14	21,91	0,15	21,77	1037,92	29,45	1025,07	3,59	0,02	3,57
Out14	22,95	0,21	22,77	1075,70	6,69	1055,64	3,38	0,06	3,35
Nov14	23,87	0,26	23,73	1158,47	12,94	1138,99	3,22	0,04	3,20
Dez14	21,38	0,42	21,13	1829,78	62,87	1808,81	4,55	0,08	4,48
Jan15	22,12	0,33	21,92	1518,93	22,32	1497,18	3,57	0,09	3,52
Fev15	32,25	0,20	31,96	3728,00	102,63	3689,66	4,40	0,05	4,35
Mar15	29,16	1,40	28,93	2155,89	109,31	2117,02	3,42	0,14	3,39

Tabela 4.21: Erros da previsão para as ESNs no horizonte de 30 minutos

Teste	MAE			MSE			MAPE (%)		
	Med	DP	Ens	Med	DP	Ens	Med	DP	Ens
Mar14	41,09	2,31	37,04	3141,02	316,55	2550,65	6,15	0,41	5,48
Abr14	38,96	2,92	33,95	3320,49	454,93	2764,32	6,44	0,57	5,59
Mai14	37,92	1,14	34,57	2740,83	139,43	2345,67	6,35	0,27	5,77
Jun14	32,05	1,92	29,15	2166,86	251,09	1835,08	6,44	0,43	5,84
Jul14	30,94	2,40	28,22	1620,39	234,45	1380,65	7,16	0,63	6,51
Ago14	30,73	1,10	28,34	1741,20	81,89	1493,87	5,51	0,29	5,00
Set14	32,22	0,55	29,70	2107,32	74,57	1859,12	5,21	0,07	4,79
Out14	32,50	1,02	29,40	1902,82	124,03	1616,83	4,98	0,17	4,51
Nov14	33,01	0,72	30,12	2077,29	76,88	1798,89	4,56	0,13	4,15
Dez14	33,91	2,41	31,29	2683,44	299,79	2410,69	7,57	0,43	7,00
Jan15	35,28	1,90	32,04	2521,87	199,55	2144,63	6,44	0,42	5,80
Fev15	43,67	2,34	39,38	4852,96	495,77	4289,12	6,17	0,36	5,53
Mar15	38,82	3,41	30,74	3071,59	523,88	2099,41	4,85	0,35	3,93

De acordo com as Tabelas 4.20 e 4.21, como nas outras redes, é possível notar que a presença de *outliers* em alguns conjuntos de teste faz os erros aumentarem muito em relação aos outros conjuntos. Um ponto importante a ser destacado aqui é que as ESNs são muito sensíveis à inicialização, logo o desempenho inferior em relação aos outros métodos pode estar ligado a isso. Pode-se notar também que o modelo combinado melhorou o resultado da média das 5 redes em todos os conjuntos de teste.

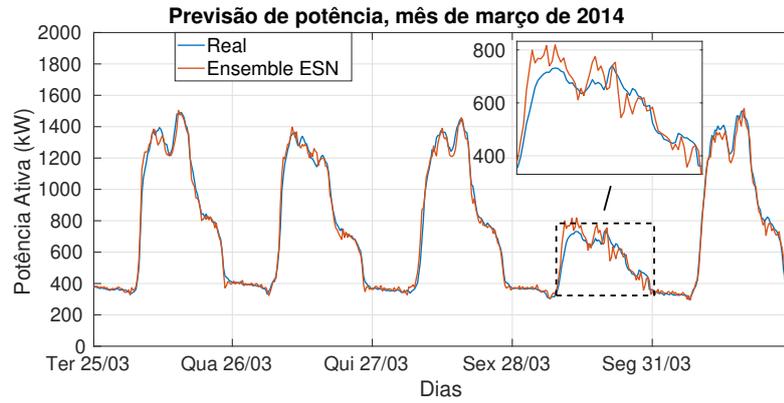
A Figura 4.41 mostra a curva real e a curva do modelo combinado de ESNs do mês de março de 2014 para o horizonte de 15 minutos.

A Figura 4.42 mostra a curva do erro absoluto do modelo combinado de ESNs do mês de março de 2014 para o horizonte de 15 minutos.

A Figura 4.43 mostra o histograma do erro absoluto do modelo combinado de ESNs do mês de março de 2014 para o horizonte de 15 minutos.

Como pode ser visto nas Figuras 4.42 e 4.43, o modelo combinado de ESNs mostrou muita dificuldade de prever o primeiro pico de potência ativa nos quatro primeiros dias da última semana do mês de março de 2014, registrando picos com valores maiores que 100 kW em todos. A magnitude do erro absoluto aumentou em todo o conjunto de teste de uma forma geral quando comparado com os outros dois modelos de IA.

Figura 4.41: Curva da previsão de potência, mês de março de 2014, horizonte de previsão de 15 minutos.



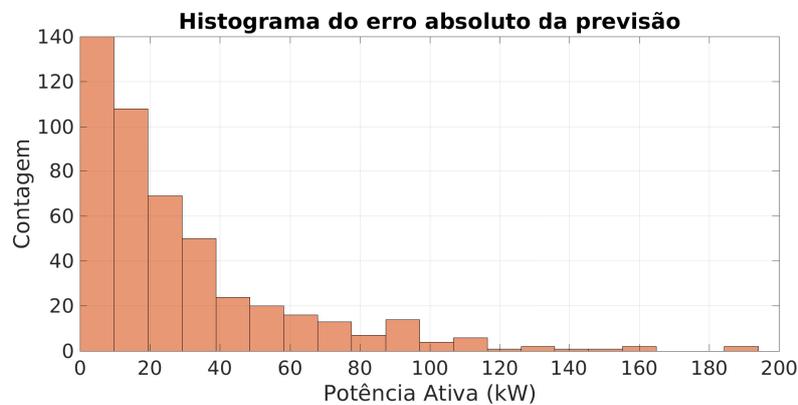
Fonte: Própria

Figura 4.42: Curva do erro absoluto, mês de março de 2014, horizonte de previsão de 15 minutos.



Fonte: Própria

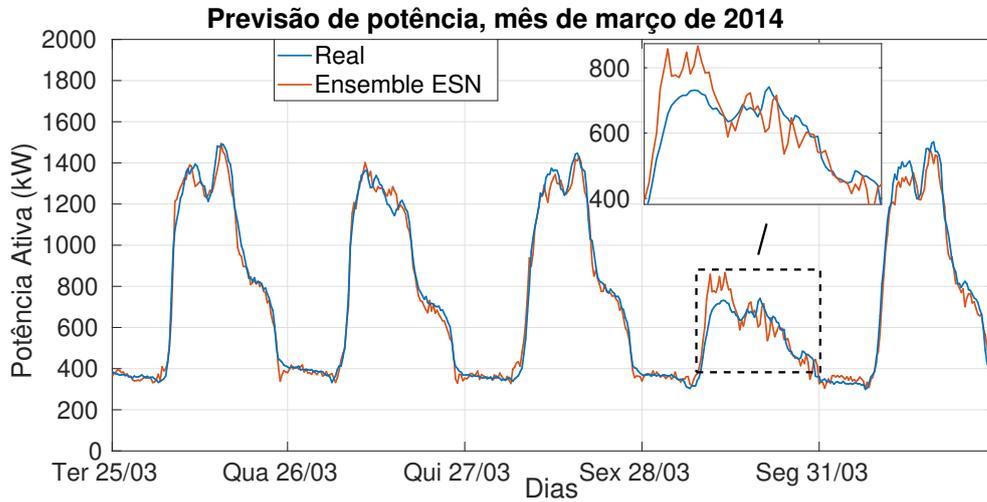
Figura 4.43: Histograma do erro absoluto, mês de março de 2014, horizonte de previsão de 15 minutos.



Fonte: Própria

A Figura 4.44 mostra a curva real e a curva do modelo combinado de ESNs do mês de março de 2014 para o horizonte de 30 minutos.

Figura 4.44: Curva da previsão de potência, mês de março de 2014, horizonte de previsão de 30 minutos.



Fonte: Própria

A Figura 4.45 mostra a curva do erro absoluto do modelo combinado de ESNs do mês de março de 2014 para o horizonte de 30 minutos.

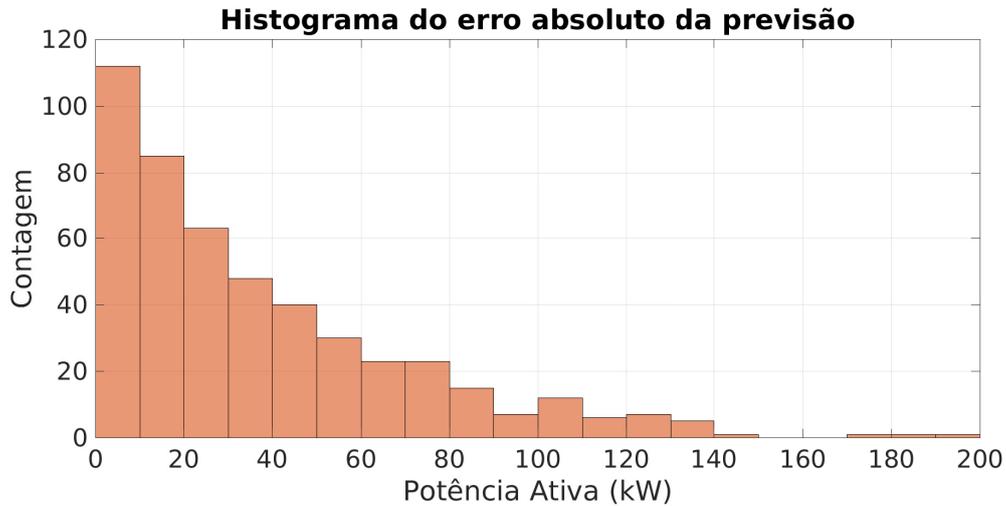
Figura 4.45: Curva do erro absoluto, mês de março de 2014, horizonte de previsão de 30 minutos.



Fonte: Própria

A Figura 4.46 mostra o histograma do erro absoluto do modelo combinado de ESNs do mês de março de 2014 para o horizonte de 30 minutos.

Figura 4.46: Histograma do erro absoluto, mês de março de 2014, horizonte de previsão de 30 minutos.



Fonte: Própria

De acordo com as figuras 4.45 e 4.46, quanto à dificuldade de prever nos picos de demanda diários no horizonte de 30 minutos o modelo combinado de ESNs mostrou o mesmo comportamento dos outros dois modelos, registrando os maiores erros absolutos nesse intervalo de tempo. O modelo também apresentou dificuldade de realizar a previsão de potência no dia atípico, mostrando seu maior pico de erro absoluto.

4.2.6 Comparação Entre Métodos

Nos próximos Estudos de Caso, a quantidade de modelos de previsão aplicados foi reduzida e apenas os dois melhores modelos deste Estudo serão utilizados (o melhor modelo de IA e o melhor modelo estatístico).

Os melhores modelos utilizados foram escolhidos com base nas Figuras 4.47 e 4.48.

As Figuras 4.47 e 4.48 mostram o *box plot* do MAPE de todos os conjuntos de teste dos métodos aplicados neste estudo de caso para os horizontes de previsão de 15 e 30 minutos respectivamente.

Como esperado, o método *Naive* por ser um método de previsão simples, que leva em conta apenas o último valor de potência disponível mostrou maiores erros dentre os preditores em ambos horizontes, portanto, o método estatístico escolhido foi o SARIMA.

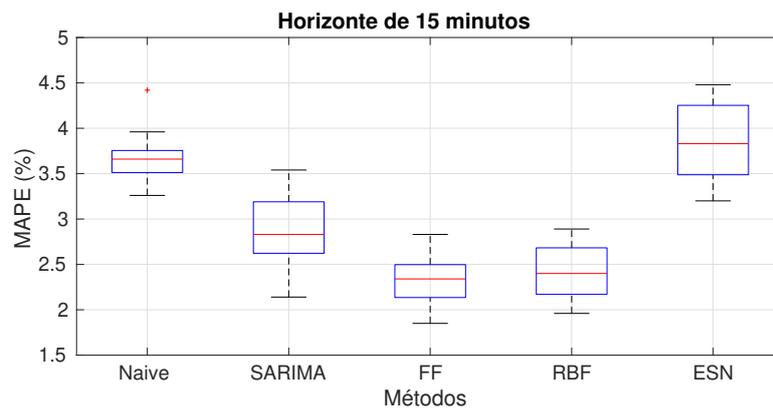
O método SARIMA mostrou resultados bons devido a sua estrutura de equações, que leva em conta as diferenciações e os componentes autorregressivos e de médias móveis da série temporal.

Os métodos *Feedforward* e RBF mostraram desempenho muito próximos nos dois horizontes e melhores do que os outros métodos em geral, solidificando a idéia de que as redes alimentadas para frente quando possuem atrasos temporais selecionados de forma a ajudar nas previsões

A ESN mostrou o pior desempenho dos métodos de IA, porém apresentou treinamento mais rápido. Como o desempenho da rede depende muito da forma como a rede foi inicializada (e ela é inicializada de forma aleatória), o desempenho dessas redes recorrentes não foi capaz de superar os bons resultados das redes alimentadas para frente. É bem possível que dispendo de um bom critério de inicialização essa rede mostre resultados melhores.

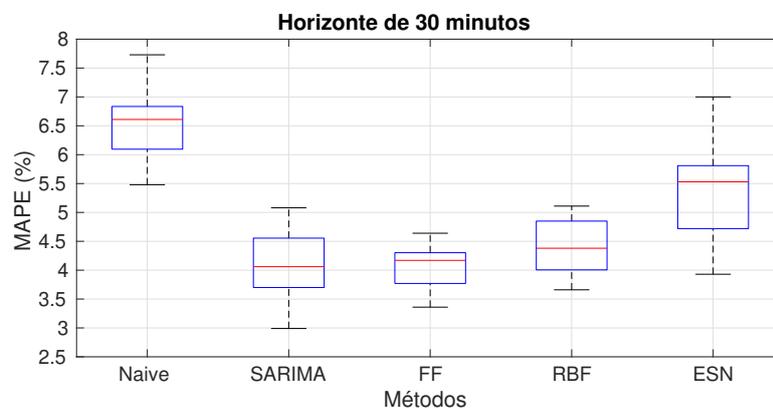
O método que mostrou os menores erros (melhor desempenho) em ambos horizontes foi o conjunto de Redes Neurais *Feedforward*, portanto ele foi o método de IA escolhido.

Figura 4.47: *Box plot* do MAPE dos modelos de previsão aplicados no horizonte de 15 minutos.



Fonte: Própria

Figura 4.48: *Box plot* do MAPE dos modelos de previsão aplicados no horizonte de 30 minutos.



Fonte: Própria

4.3 Estudo de Caso 2

No Estudo de Caso 2, o modelo SARIMA utilizado foi o mesmo ajustado para o Estudo de Caso 1 (seção 3.4) e adotou-se a mesma configuração do modelo de redes *Feedforward* proposto inicialmente, as Tabelas 4.2 e 4.3 mostram a configuração utilizada.

4.3.1 Resultados da Previsão do Modelo SARIMA

A previsão para o mês de março de 2015 foi realizada para os horizontes de 15 (1 passo) e 30 minutos (2 passos) a frente, e os resultados foram mostrados nas Tabelas 4.22 e 4.23.

Tabela 4.22: Erros da Previsão do modelo SARIMA para o horizonte de 15 minutos

Teste	MAE	MSE	MAPE (%)
Mar15	19,25	899,54	2,37

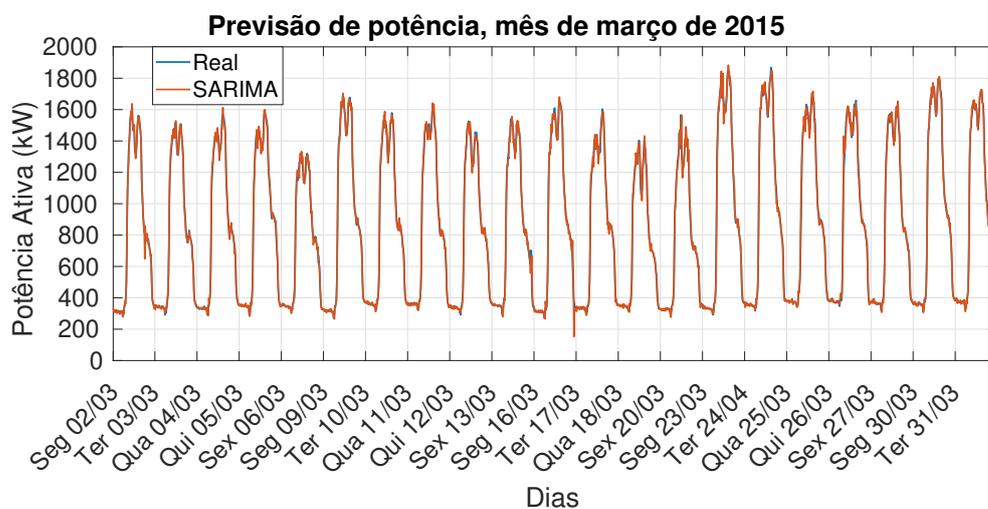
Tabela 4.23: Erros da Previsão do modelo SARIMA para o horizonte de 30 minutos

Teste	MAE	MSE	MAPE (%)
Mar15	27,05	1829,61	3,30

Como pode ser visto nas Tabelas 4.22 e 4.23, O modelo SARIMA performou muito bem na tarefa de previsão mensal e apresentou erros baixos para ambos horizontes.

A Figura 4.49 mostra a curva real e a curva do modelo SARIMA do mês de março de 2014 para o horizonte de previsão de 15 minutos.

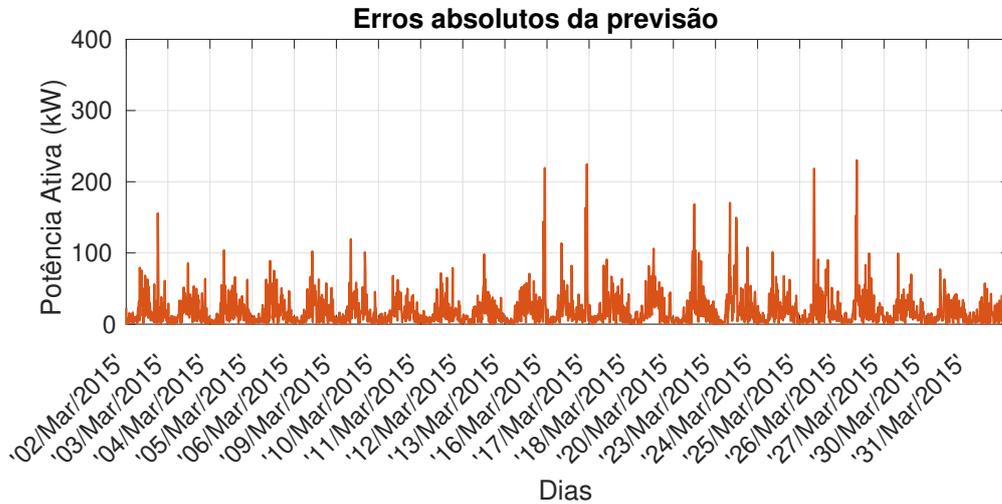
Figura 4.49: Curvas da previsão de potência, mês de março de 2014, horizonte de previsão de 15 minutos.



Fonte: Própria

A Figura 4.50 mostra a curva do erro absoluto do modelo SARIMA do mês de março de 2014 para o horizonte de previsão de 15 minutos.

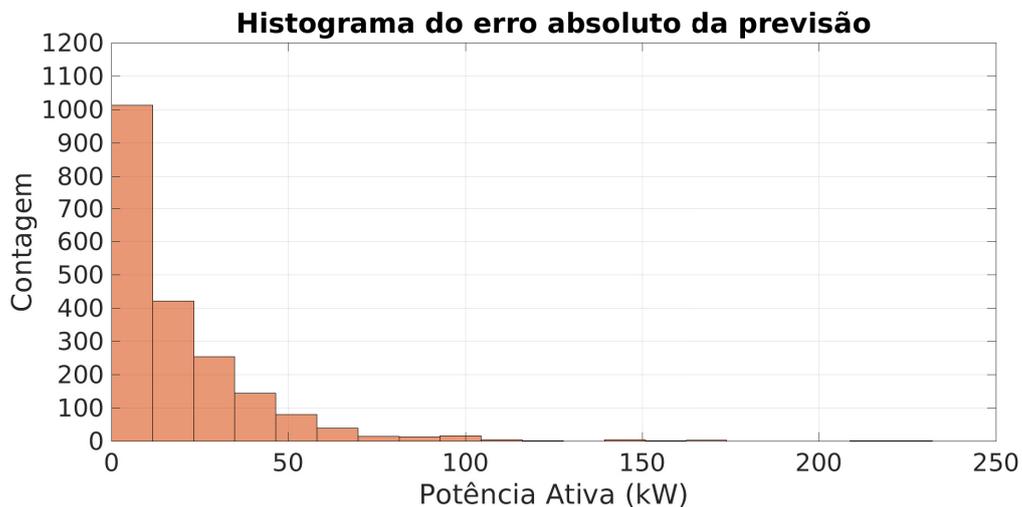
Figura 4.50: Curva do erro absoluto, mês de março de 2014, horizonte de previsão de 15 minutos.



Fonte: Própria

A Figura 4.51 mostra o histograma do erro absoluto do modelo SARIMA do mês de março de 2014 para o horizonte de previsão de 15 minutos.

Figura 4.51: Histograma do erro absoluto, mês de março de 2014, horizonte de previsão de 15 minutos.

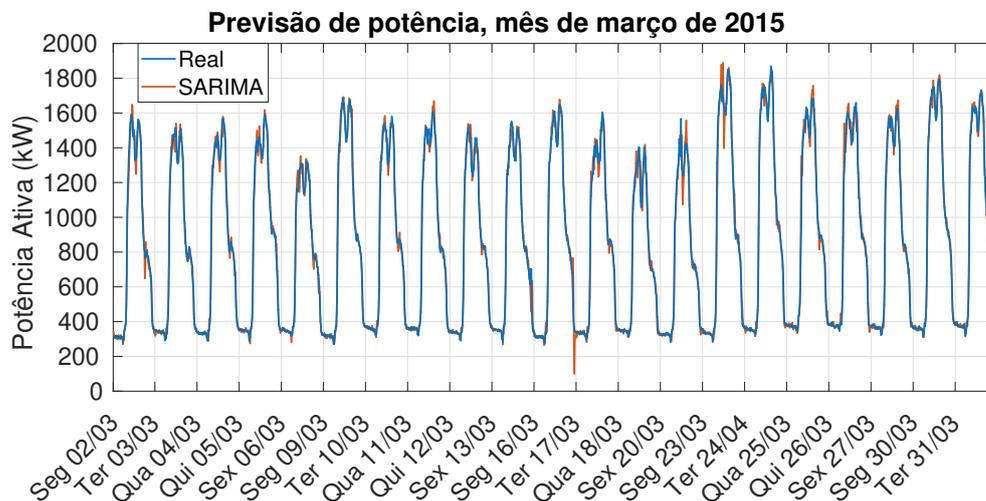


Fonte: Própria

Como pode ser visto na Figura 4.50, mais de 1600 pontos (de um total de 2016) da curva do erro absoluto do modelo combinado estão entre 0 a 30 kW e pela curva do erro absoluto é possível notar que a magnitude do erro atinge a faixa de 100 e 200 kW algumas vezes para este conjunto de teste.

A Figura 4.52 mostra a curva real e a curva do modelo SARIMA do mês de março de 2014 para o horizonte de previsão de 30 minutos.

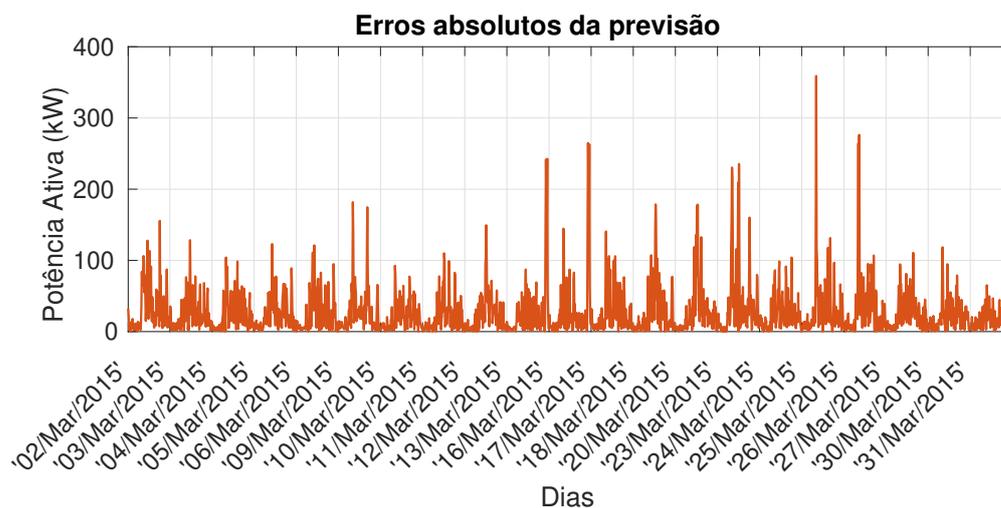
Figura 4.52: Curva da previsão de potência, mês de março de 2014, horizonte de previsão de 30 minutos.



Fonte: Própria

A Figura 4.53 mostra a curva do erro absoluto do modelo SARIMA do mês de março de 2014 para o horizonte de previsão de 30 minutos.

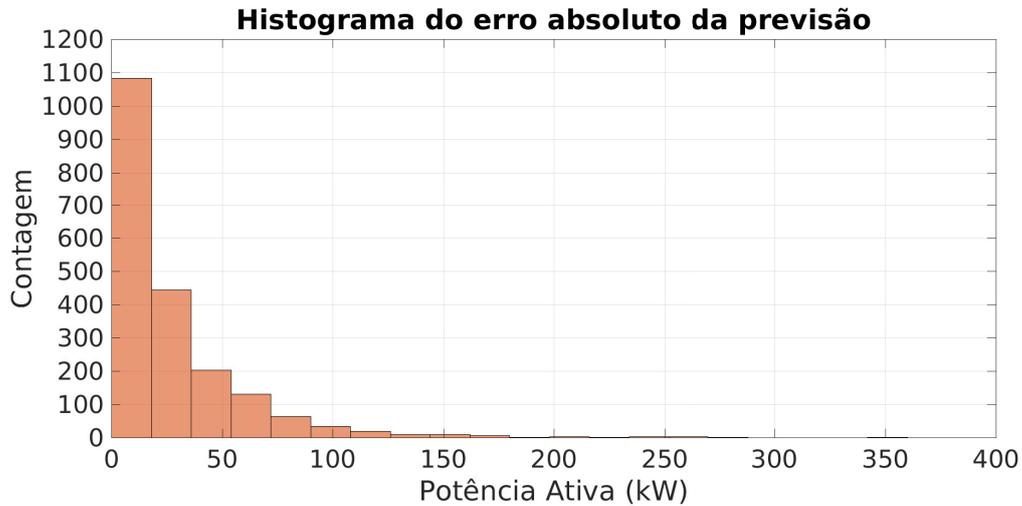
Figura 4.53: Curva do erro absoluto, mês de março de 2014, horizonte de previsão de 30 minutos.



Fonte: Própria

A Figura 4.54 mostra o histograma do erro absoluto do modelo SARIMA do mês de março de 2014 para o horizonte de previsão de 30 minutos.

Figura 4.54: Histograma do erro absoluto, mês de março de 2014, horizonte de previsão de 30 minutos.



Fonte: Própria

Como pode ser visto nas Figuras 4.53 e 4.54, aumentando-se a dificuldade da tarefa de previsão, a magnitude do erro absoluto aumenta muito e os erros se tornam muito presentes na faixa dos 100 e 200 kW apesar do bom desempenho do modelo no erro médio percentual e médio absoluto, porém o que surpreende é que o método chegou a atingir 300 KW de erro absoluto mais de uma vez no horizonte de 30 minutos.

4.3.2 Resultados da Previsão das RNAs *Feedforward*

A previsão para o mês de março de 2015 foi realizada para os horizontes de 15 (1 passo) e 30 minutos (2 passos) a frente, e os resultados foram mostrados nas Tabelas 4.24 e 4.25.

Tabela 4.24: Erros da Previsão das redes *Feedforward* para o horizonte de 15 minutos

Teste	MAE			MSE			MAPE (%)		
	MED	DP	Eens	MED	DP	Eens	MED	DP	Eens
Mar15	19,66	1,93	17,88	1029,56	293,76	772,93	2,30	0,11	2,18

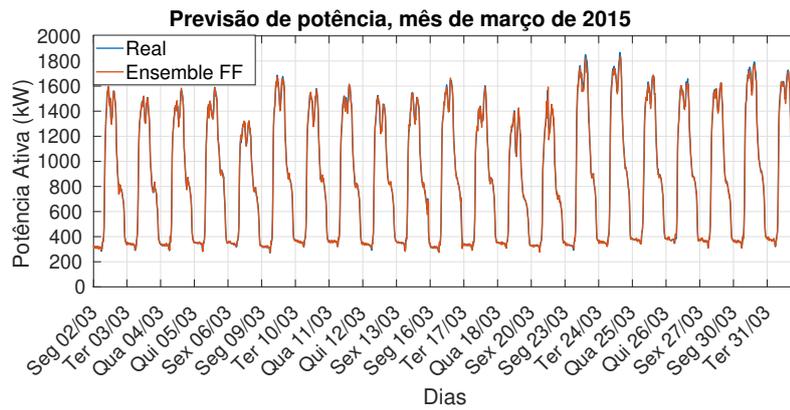
Tabela 4.25: Erros da Previsão das redes *Feedforward* para o horizonte de 30 minutos

Teste	MAE			MSE			MAPE (%)		
	MED	DP	Eens	MED	DP	Eens	MED	DP	Eens
Mar15	35,69	0,90	33,95	3157,60	144,30	2874,27	4,32	0,10	4,16

Como pode ser visto nas Tabelas 4.24 e 4.25, o modelo combinado de redes *feedforward* apresenta erros menores do que o SARIMA no horizonte de 15 minutos, mas perde no desempenho para o SARIMA no horizonte de 30 minutos, o que mostra que o SARIMA teve um ganho muito grande no desempenho mudando a forma de entrar com os dados no preditor.

A Figura 4.55 mostra a curva real e a curva do modelo combinado das redes *feedforward* do mês de março de 2014 para o horizonte de previsão de 15 minutos.

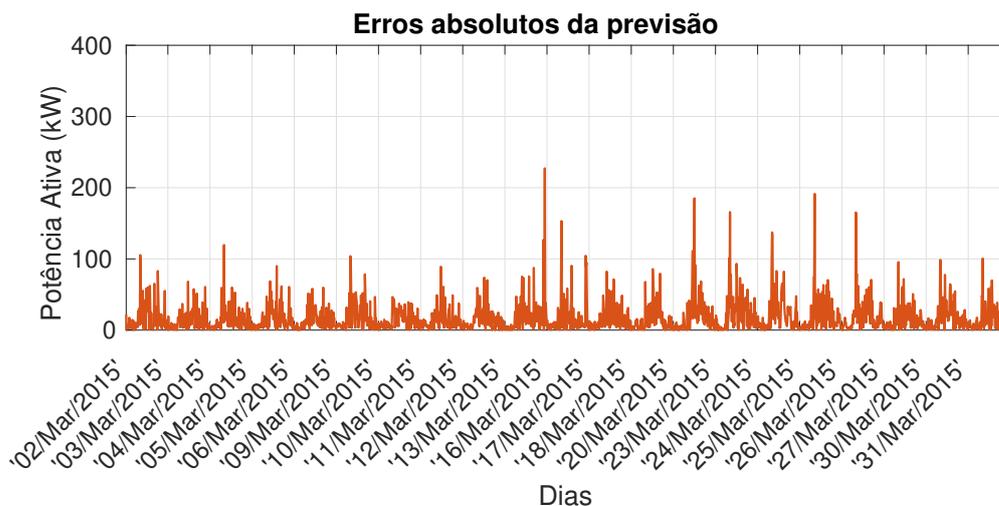
Figura 4.55: Curvas da previsão de potência, mês de março de 2014, horizonte de previsão de 15 minutos.



Fonte: Própria

A Figura 4.56 mostra a curva do erro absoluto do modelo combinado das redes *feedforward* do mês de março de 2014 para o horizonte de previsão de 15 minutos.

Figura 4.56: Curva do erro absoluto, mês de março de 2014, horizonte de previsão de 15 minutos.

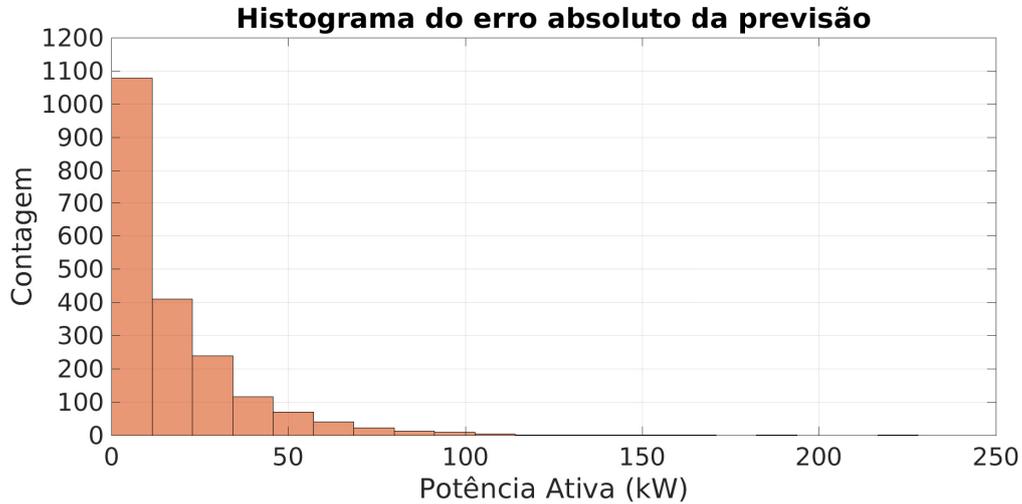


Fonte: Própria

A Figura 4.57 mostra o histograma do erro absoluto do modelo combinado das

redes *feedforward* do mês de março de 2014 para o horizonte de previsão de 15 minutos.

Figura 4.57: Histograma do erro absoluto, mês de março de 2014, horizonte de previsão de 15 minutos.

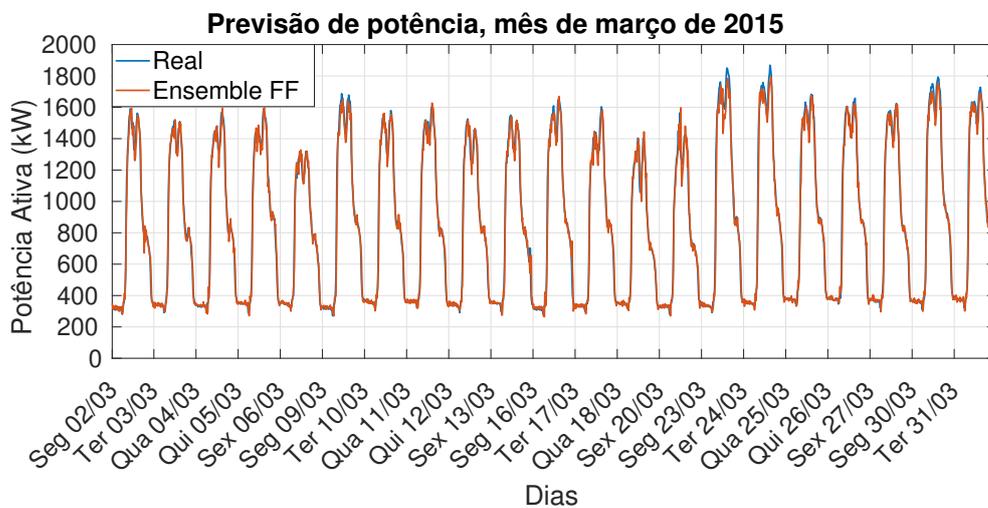


Fonte: Própria

Como pode ser visto nas Figuras 4.56 e 4.57, o modelo combinado de redes *feedforward* mostrou bom desempenho no horizonte de 15 minutos, com poucas aparições de erro absoluto entre 100 e 200 kW, superando o desempenho do modelo SARIMA.

A Figura 4.58 mostra a curva real e a curva do modelo combinado das redes *feedforward* do mês de março de 2015 para o horizonte de previsão de 30 minutos.

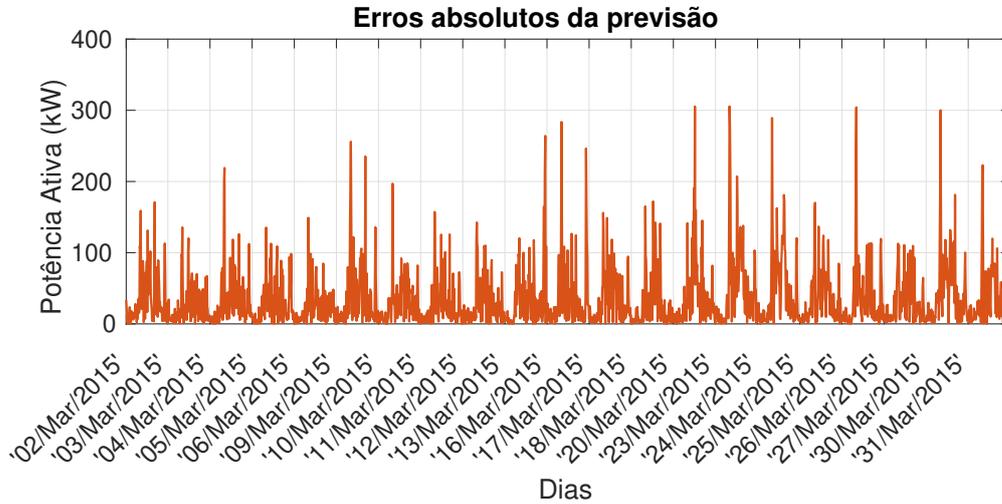
Figura 4.58: Curva da previsão de potência, mês de março de 2014, horizonte de previsão de 30 minutos.



Fonte: Própria

A Figura 4.59 mostra a curva do erro absoluto do modelo combinado das redes *feedforward* do mês de março de 2014 para o horizonte de previsão de 30 minutos.

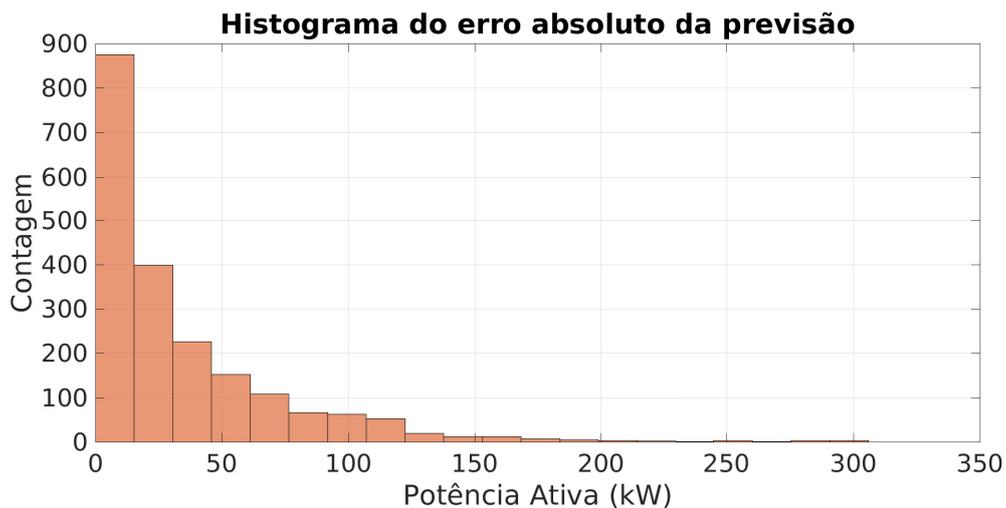
Figura 4.59: Curva do erro absoluto, mês de março de 2014, horizonte de previsão de 30 minutos.



Fonte: Própria

A Figura 4.60 mostra o histograma do erro absoluto do modelo combinado das redes *feedforward* do mês de março de 2014 para o horizonte de previsão de 30 minutos.

Figura 4.60: Histograma do erro absoluto, mês de março de 2014, horizonte de previsão de 30 minutos.



Fonte: Própria

Já no horizonte de 30 minutos, o modelo combinado de redes *feedforward* mostrou o mesmo problema da dificuldade de prever os picos de potência e a queda na potência para o almoço no intervalo entre 12:00 e 14:00 horas, registrando altos valores de

erro absoluto, muito presentes na faixa de 100 e 200 kW e atingindo por mais de uma vez 300 kW de erro absoluto.

4.4 Estudo de Caso 3

No Estudo de Caso 3, o modelo SARIMA utilizado foi o mesmo ajustado para o Estudo de Caso 1 (seção 3.4) e adotou-se a mesma configuração do modelo de redes *Feedforward* proposto inicialmente, as Tabelas 4.2 e 4.3 mostram a configuração utilizada.

4.4.1 Resultados da Previsão do Modelo SARIMA

A previsão para a primeira semana dos meses de maio de 2014 a março de 2015 foi realizada para os horizontes de 15 (1 passo) e 30 minutos (2 passos) a frente, e os resultados foram mostrados nas Tabelas 4.26 e 4.27.

Tabela 4.26: Erros da Previsão do modelo ARIMA para o horizonte de 15 minutos

Mod	Teste	MAE	MSE	MAPE (%)
1	Mai14	21.77	969.06	3.24
2	Jun14	14.39	372.80	2.33
3	Jul14	16.61	701.54	3.86
4	Ago14	13.71	363.74	2.55
5	Set14	14.72	410.66	2.43
6	Out14	17.47	754.86	3.14
7	Nov14	30.73	5479.18	4.23
8	Dez14	16.49	585.56	2.42
9	Jan15	16.83	1245.38	3.25
10	Fev15	17.49	1271.82	2.63
11	Mar15	25.26	1423.10	3.09

Tabela 4.27: Erros da Previsão do modelo ARIMA para o horizonte de 30 minutos

Mod	Teste	MAE	MSE	MAPE (%)
1	Mai14	23.34	1114.79	3.20
2	Jun14	20.44	857.84	3.18
3	Jul14	25.25	1770.49	6.01
4	Ago14	19.32	769.14	3.59
5	Set14	20.46	828.37	3.38
6	Out14	26.35	1602.70	4.58
7	Nov14	43.95	10435.92	6.01
8	Dez14	83.57	38841.73	11.52
9	Jan15	21.16	1572.05	4.04
10	Fev15	31.49	2277.94	5.01
11	Mar15	26.57	1414.25	3.25

Como pode ser visto nas Tabelas 4.26 e 4.27, os modelos SARIMA apresentaram erros baixos nos dois casos para a tarefa de previsão semanal em ambos horizontes, mas os outliers presentes nas primeiras semanas dos meses de novembro e dezembro de 2014 fizeram os erros aumentarem muito no horizonte de previsão de 30 minutos.

A Figura 4.61 mostra a curva real e a curva do modelo SARIMA da primeira semana do mês de maio de 2014 para o horizonte de previsão de 15 minutos.

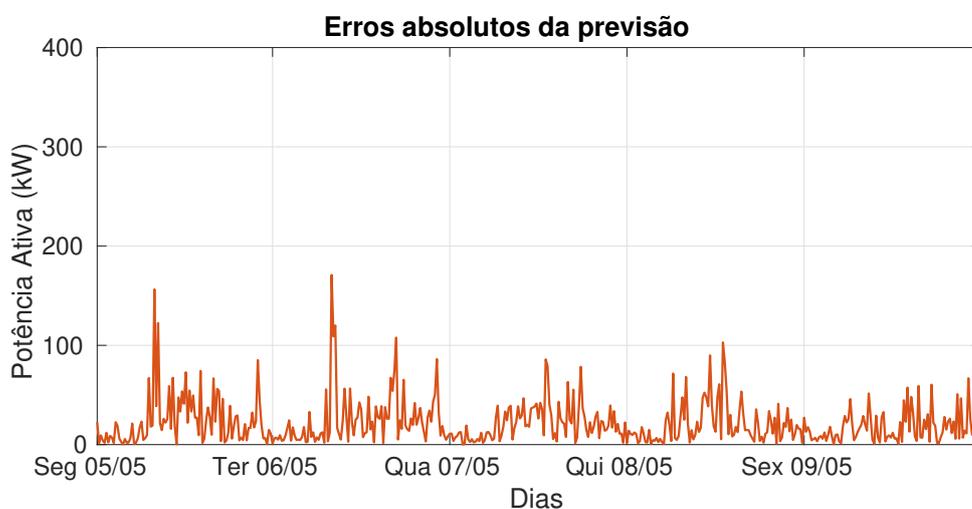
Figura 4.61: Curvas da previsão de potência, mês de maio de 2014, horizonte de previsão de 15 minutos.



Fonte: Própria

A Figura 4.62 mostra a curva do erro absoluto do modelo SARIMA da primeira semana do mês de maio de 2014 para o horizonte de previsão de 15 minutos.

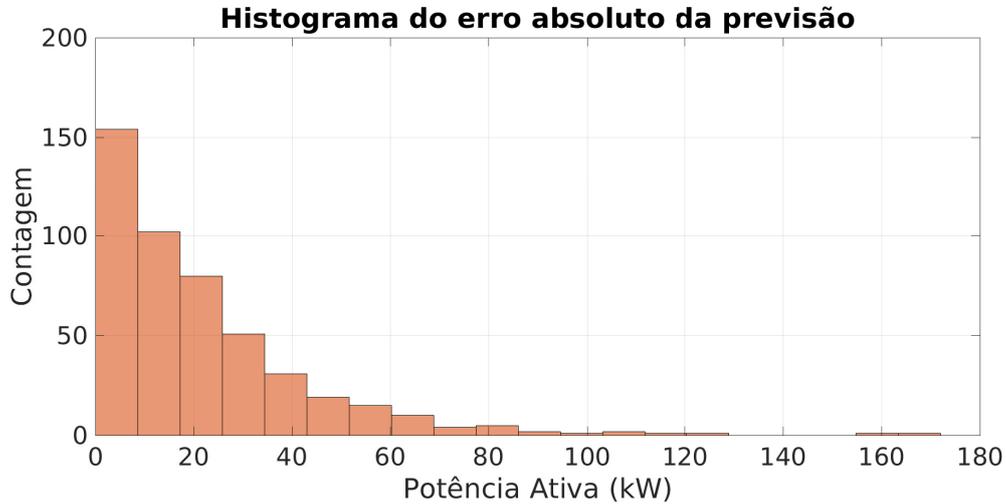
Figura 4.62: Curva do erro absoluto, mês de maio de 2014, horizonte de previsão de 15 minutos.



Fonte: Própria

A Figura 4.63 mostra o histograma do erro absoluto do modelo SARIMA da primeira semana do mês de maio de 2014 para o horizonte de previsão de 15 minutos.

Figura 4.63: Histograma do erro absoluto, mês de maio de 2014, horizonte de previsão de 15 minutos.



Fonte: Própria

Como pode ser visto nas Figuras 4.62 e 4.63, o SARIMA não executou bem a previsão nos dois primeiros picos da segunda 05/05 e da terça 06/05 e mostrou erros absolutos entre 100 e 200 kW apesar do bom desempenho no restante dos dias da semana.

A Figura 4.64 mostra a curva real e a curva do modelo SARIMA da primeira semana do mês de maio de 2014 para o horizonte de previsão de 30 minutos.

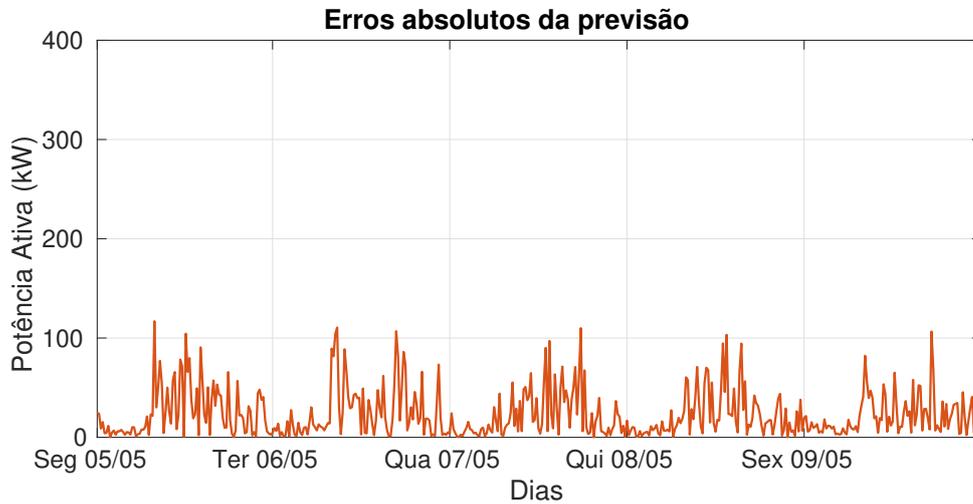
Figura 4.64: Curva da previsão de potência, mês de maio de 2014, horizonte de previsão de 30 minutos.



Fonte: Própria

A Figura 4.65 mostra a curva do erro absoluto do modelo SARIMA da primeira semana do mês de maio de 2014 para o horizonte de previsão de 30 minutos.

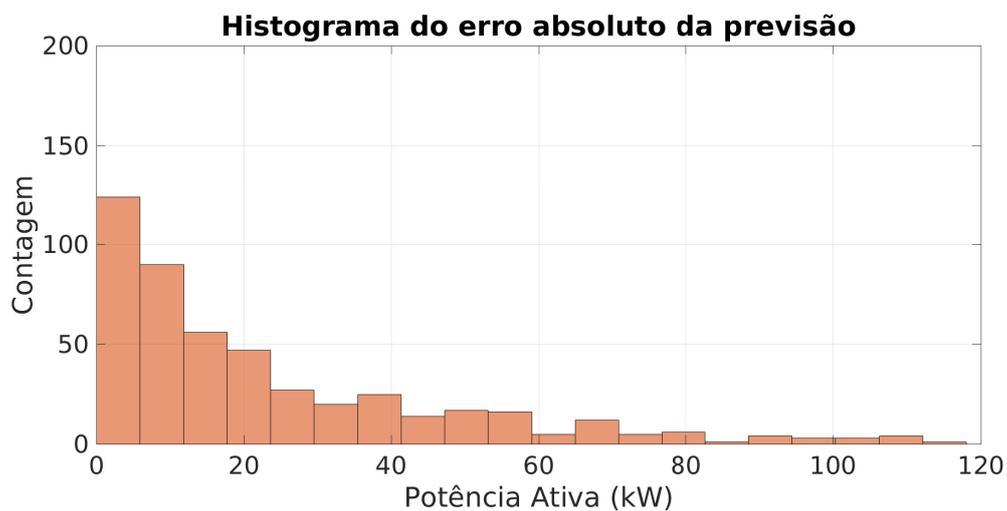
Figura 4.65: Curva do erro absoluto, mês de maio de 2014, horizonte de previsão de 30 minutos.



Fonte: Própria

A Figura 4.66 mostra o histograma do erro absoluto do modelo SARIMA da primeira semana do mês de maio de 2014 para o horizonte de previsão de 30 minutos.

Figura 4.66: Histograma do erro absoluto, mês de maio de 2014, horizonte de previsão de 30 minutos.



Fonte: Própria

Como pode ser visto nas Figuras 4.65 e 4.66, o SARIMA melhorou seu desempenho no horizonte de 30 minutos mostrando picos de erros absolutos contidos e menores do que os picos do horizonte de 15 minutos, bem próximos dos 100 kW, porém a

média do erro absoluto aumentou por se tratar de uma tarefa mais complexa prever 2 passos a frente.

4.4.2 Resultados da Previsão das RNAs *Feedforward*

A previsão para a primeira semana de cada mês, de maio de 2014 a março de 2015 foi realizada para os horizontes de 15 (1 passo) e 30 minutos (2 passos) a frente, e os resultados foram mostrados nas Tabelas 4.28 e 4.29.

Tabela 4.28: Erros da Previsão das redes *Feedforward* para o horizonte de 15 minutos

Mod	Teste	MAE			MSE			MAPE (%)		
		Med	DP	Ens	Med	DP	Ens	Med	DP	Ens
1	Mai14	15.86	0.26	15.22	506.48	22.19	462.50	2.23	0.05	2.14
2	Jun14	12.89	0.25	12.30	312.21	11.73	290.16	2.05	0.05	1.95
3	Jul14	14.48	0.39	13.48	462.27	35.80	388.11	3.22	0.11	2.97
4	Ago14	16.54	2.33	14.87	887.48	399.15	530.61	2.71	0.22	2.50
5	Set14	18.20	2.08	15.38	812.78	240.40	526.25	2.60	0.24	2.31
6	Out14	15.78	0.40	15.22	645.29	79.13	598.09	2.82	0.09	2.72
7	Nov14	24.83	2.24	22.76	3973.69	1084.77	3099.54	3.49	0.24	3.21
8	Dez14	15.27	0.66	14.26	491.92	53.31	429.90	2.21	0.07	2.08
9	Jan15	14.69	0.41	13.29	764.01	92.67	553.12	2.86	0.08	2.63
10	Fev15	17.26	0.64	15.65	1072.31	153.41	889.86	2.60	0.18	2.37
11	Mar15	19.25	1.50	16.97	819.76	106.59	608.76	2.42	0.13	2.18

Tabela 4.29: Erros da Previsão das redes *Feedforward* para o horizonte de 30 minutos

Mod	Teste	MAE			MSE			MAPE (%)		
		Med	DP	Ens	Med	DP	Ens	Med	DP	Ens
1	Mai14	28.18	1.25	26.06	1748.09	160.67	1459.58	3.80	0.08	3.50
2	Jun14	24.12	0.42	22.81	1142.75	59.99	1046.24	3.82	0.08	3.57
3	Jul14	24.88	1.47	23.01	1307.58	185.16	1119.88	5.62	0.48	5.14
4	Ago14	31.26	3.68	29.24	2826.02	1136.20	2152.17	5.19	0.45	4.87
5	Set14	32.88	4.62	29.14	2588.14	967.22	1880.82	4.68	0.37	4.28
6	Out14	28.28	0.50	26.74	2002.76	138.85	1833.67	4.90	0.09	4.61
7	Nov14	42.82	3.79	38.18	9483.21	2913.08	6898.43	6.25	0.61	5.60
8	Dez14	27.78	0.27	26.72	1550.21	45.60	1439.29	4.12	0.06	3.95
9	Jan15	25.67	1.15	25.06	2165.56	428.44	2059.17	5.02	0.21	4.88
10	Fev15	28.21	2.41	25.78	2316.05	559.60	1931.18	4.28	0.28	4.00
11	Mar15	31.84	2.06	29.33	2131.62	310.87	1789.62	4.06	0.22	3.71

Como pode ser visto nas Tabelas 4.28 e 4.29, o modelo combinado de redes *Feedforward* performou melhor do que o modelo SARIMA no horizonte de 15 minutos e em alguns modelos performou melhor do que o SARIMA no horizonte de 30 minutos.

A Figura 4.67 mostra a curva real e a curva do modelo combinado das redes *feedforward* do mês de maio de 2014 para o horizonte de previsão de 15 minutos.

Figura 4.67: Curvas da previsão de potência, mês de maio de 2014, horizonte de previsão de 15 minutos.



Fonte: Própria

A Figura 4.68 mostra a curva do erro absoluto do modelo combinado das redes *feedforward* do mês de março de 2014 para o horizonte de previsão de 15 minutos.

Figura 4.68: Curva do erro absoluto, mês de maio de 2014, horizonte de previsão de 15 minutos.

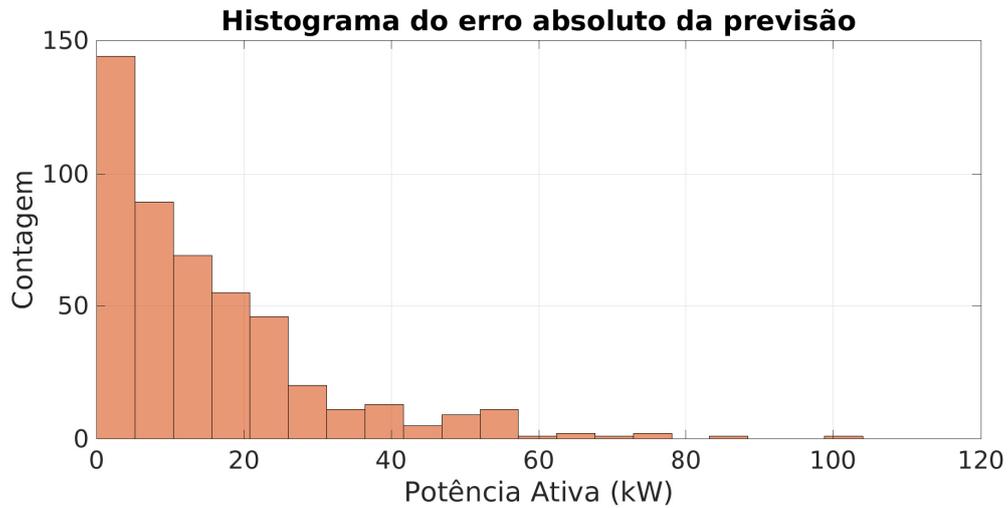


Fonte: Própria

A Figura 4.69 mostra o histograma do erro absoluto do modelo combinado das redes *feedforward* do mês de março de 2014 para o horizonte de previsão de 15 minutos.

Como pode ser visto nas Figuras 4.68 e 4.69, o modelo combinado de redes *feedforward* que prevê em março de 2014 mostrou desempenho muito bom, tendo sua curva ultrapassado apenas uma vez a faixa dos 100 kW de erro absoluto.

Figura 4.69: Histograma do erro absoluto, mês de maio de 2014, horizonte de previsão de 15 minutos.



Fonte: Própria

A Figura 4.70 mostra a curva real e a curva do modelo combinado das redes *feedforward* do mês de março de 2015 para o horizonte de previsão de 30 minutos.

Figura 4.70: Curva da previsão de potência, mês de maio de 2014, horizonte de previsão de 30 minutos.



Fonte: Própria

A Figura 4.71 mostra a curva do erro absoluto do modelo combinado das redes *feedforward* do mês de maio de 2014 para o horizonte de previsão de 30 minutos.

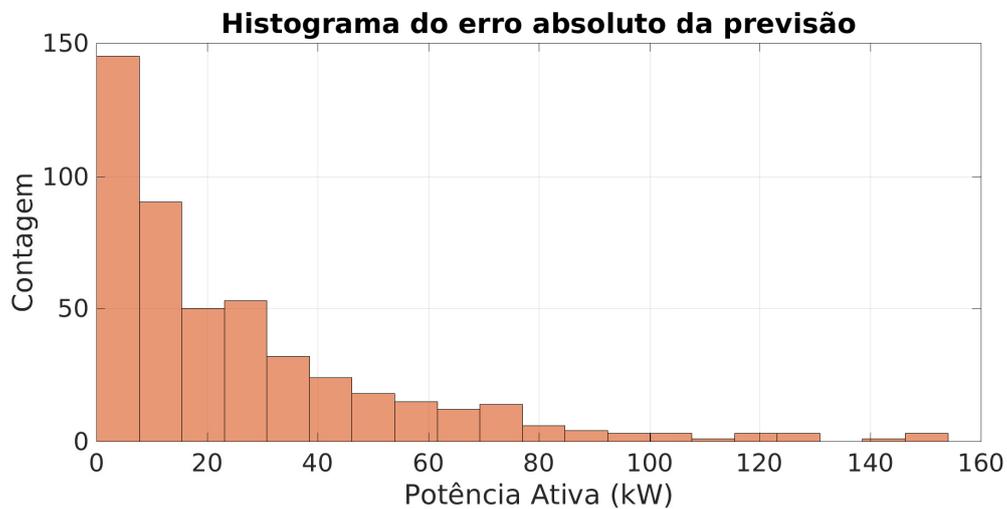
Figura 4.71: Curva do erro absoluto, mês de maio de 2014, horizonte de previsão de 30 minutos.



Fonte: Própria

A Figura 4.72 mostra o histograma do erro absoluto do modelo combinado das redes *feedforward* do mês de maio de 2014 para o horizonte de previsão de 30 minutos.

Figura 4.72: Histograma do erro absoluto, mês de maio de 2014, horizonte de previsão de 30 minutos.



Fonte: Própria

Como pode ser visto nas Figuras 4.71 e 4.72, o conjunto de redes *feedforward* piorou bastante seu desempenho no horizonte de 30 minutos, mostrando diversas vezes erros absolutos maiores do que 100 kW.

4.5 Escolha da Melhor Forma de Inserir os Dados Temporais nos Modelos

Se considerarmos que o mês de março de 2015 foi utilizado como teste nos Estudos de Caso 1 e 2 (mesmo que tenha sido só uma das 4 semanas) pode-se comparar os três estudos de caso para dar início a essa seção de comparação entre os estudos e escolha da melhor forma de inserir dados nos métodos de previsão. A Tabela 4.30 agrupa o MAPE dos métodos do Estudo de Caso 1 para os horizontes de 15 e 30 minutos.

Tabela 4.30: Tabela com o MAPE de todos os métodos do Estudo de Caso 1 para o horizonte de 15 e 30 minutos.

Teste	MAPE (%) horizonte de 15 minutos					MAPE (%) horizonte de 30 minutos				
	Naive	SARIMA	Ens FF	Ens RBF	Ens ESN	Naive	SARIMA	Ens FF	Ens RBF	Ens ESN
Mar14	3,53	3,22	2,55	2,69	4,21	6,37	5,08	4,24	4,84	5,48
Abr14	3,66	3,15	2,48	2,68	4,40	6,64	4,75	4,4	4,9	5,49
Mai14	3,46	2,97	2,41	2,56	4,22	6,12	4,48	4,17	4,55	5,77
Jun14	3,36	2,66	2,34	2,38	3,83	6,02	3,7	4,27	4,38	5,84
Jul14	3,26	3,18	2,39	2,47	3,88	5,48	4,41	4,25	4,38	6,51
Ago14	3,56	2,7	2,15	2,17	3,65	6,33	3,8	3,77	3,99	5,00
Set14	3,77	2,83	2,31	2,37	3,57	6,7	4,06	3,95	4,2	4,79
Out14	3,73	2,51	2,09	2,17	3,35	6,81	3,7	3,77	3,98	4,51
Nov14	3,75	2,14	1,85	1,96	3,20	6,91	2,99	3,36	3,66	4,15
Dez14	3,64	3,54	2,83	2,89	4,48	5,93	4,96	4,64	4,88	7,00
Jan15	3,7	2,83	2,31	2,4	3,52	6,61	3,8	4,01	4,32	5,80
Fev15	4,42	3,39	2,66	2,86	4,35	7,73	4,49	4,46	5,11	5,53
Mar15	3,96	2,17	1,98	2,06	3,39	7,35	3,07	3,7	4,01	3,93

Na Tabela 4.30 o melhor método para o horizonte de 15 minutos foi o modelo combinado de redes *feedforward* em todos os conjuntos de teste e para o horizonte de 30 minutos o modelo combinado de redes *feedforward* mostrou o melhor desempenho em 8 dos 13 conjuntos de teste.

A Tabela 4.31 agrupa o MAPE dos métodos do Estudo de Caso 2 para os horizontes de 15 e 30 minutos.

Tabela 4.31: Tabela com o MAPE de todos os métodos do Estudo de Caso 2 para o horizonte de 15 e 30 minutos.

Teste	MAPE (%) 15 minutos		MAPE (%) 30 minutos	
	SARIMA	Ens FF	SARIMA	Ens FF
Mar15	2,37	2,18	3,30	4,16

Na Tabela 4.31 o melhor método para o horizonte de 15 minutos foi o modelo combinado de redes *feedforward* e para o horizonte de 30 minutos foi o modelo SARIMA.

A Tabela 4.32 agrupa o MAPE dos métodos do Estudo de Caso 3 para os horizontes de 15 e 30 minutos.

Tabela 4.32: Tabela com o MAPE de todos os métodos do Estudo de Caso 3 para o horizonte de 15 e 30 minutos.

Teste	MAPE (%) 15 minutos		MAPE (%) 30 minutos	
	SARIMA	Ens FF	SARIMA	Ens FF
Mai14	3.24	2.14	3.20	3.50
Jun14	2.33	1.95	3.18	3.57
Jul14	3.86	2.97	6.01	5.14
Ago14	2.55	2.50	3.59	4.87
Set14	2.43	2.31	3.38	4.28
Out14	3.14	2.72	4.58	4.61
Nov14	4.23	3.21	6.01	5.60
Dez14	2.42	2.08	11.52	3.95
Jan15	3.25	2.63	4.04	4.88
Fev15	2.63	2.37	5.01	4.00
Mar15	3.09	2.18	3.25	3.71

Na Tabela 4.32 o melhor método para o horizonte de 15 minutos foi o modelo combinado de redes *feedforward* e para o horizonte de 30 minutos foi o modelo SARIMA.

Como o mês de março de 2015 esteve presente nos três estudos de caso, com base nas Tabelas 4.30, 4.31 e 4.32 o método que mostrou melhor desempenho no horizonte de 15 minutos foi o de redes *feedforward* do Estudo de Caso 1 (modelo anual de previsão semanal), que no conjunto de teste do mês de março de 2015 apresentou MAPE de 1,98% (menor que no Estudo de Caso 2) e comparando com o Estudo de Caso 3, apresentou menores MAPEs em 7 dos 11 conjuntos de teste comparados (maio de 2014 a março de 2015).

Para o Horizonte de 30 minutos, com base nas Tabelas 4.30, 4.31 e 4.32, o SARIMA no Estudo de Caso 3 apresentou MAPE de 3,25% para o conjunto de teste do mês de março de 2015 superando o desempenho no Estudo de Caso 2 e quando comparados os 11 conjuntos de teste (maio de 2014 a março de 2015) dos Estudos de Caso 1 e 3, os modelos SARIMA e *feedforward* do Estudo de Caso 3 apresentaram melhor desempenho em 7 dos 11 conjuntos de teste, portanto, para o horizonte de 30 minutos o modelo mensal de previsão semanal (Estudo de Caso 3) é a melhor opção.

4.6 Comparações com Resultados da Literatura

Em [8], os autores comparam os resultados da previsão de potência utilizando três métodos de treinamento de redes neurais artificiais em diferentes estações do ano para o horizonte de 1 hora a frente. No trabalho, a rede recebe como entrada o dia da semana, uma entrada que indica se o dia é um dia de trabalho ou não, a hora do dia, a temperatura do ponto de orvalho, a umidade, e os atrasos de uma hora anterior, do dia anterior na mesma hora e da semana anterior no mesmo dia e na mesma hora. No trabalho são usadas quatro técnicas de aprendizado diferentes em redes *feedforward* e o desempenho final das redes são comparados. As técnicas utilizadas são a *Levenberg-Marquadt* (LM), *Backpropagation* (BP), Melhor Partícula Global de Otimização de Enxame (GPSO) e Otimização de Enxame de Partículas (PSO).

A Tabela 4.33 mostra uma visão geral do trabalho [8].

Tabela 4.33: Visão geral dos dados e componentes do trabalho

Autor, Ref.	Estrutura da Rede	Técnicas de Aprendizado	F. Ativação	Métricas	Base de Dados	Entradas
Raza, M, Q et al, [8]	-8 Entradas -20 Neurônios C. Oculta -1 Saída	PSO GPSO LM BP	Sigmoid	MAPE	Real	Potência + Dados Externos

A Tabela 4.34 mostra os resultados do trabalho.

Tabela 4.34: Resultados da previsão no horizonte de 1 hora a frente da fonte [8]

Estação	MAPE (%)		
	BP	LM	GPSO
Inverno	4.303	2.726	1.869
Primavera	4.088	3.163	1.760
Verão	4.665	3.823	1.408
Outono	4.5	2.919	1.577

Em [23], os autores comparam os resultados da previsão de potência utilizando combinação de redes neurais e métodos estatísticos em sete prédios de escritórios para prever no horizonte de uma hora a frente. Inicialmente, somente dados de potência foram dados como entrada para as redes e posteriormente foram adicionadas mais quatro entradas, a hora do dia, se o dia é ou não um dia de trabalho, o consumo horário de água quente, e a luminosidade do local. O método RNCL é um método de combinação de métodos de previsão, que o autor denomina de aprendizado regularizado pela correlação negativa.

A Tabela 4.35 mostra uma visão geral do trabalho [23].

Tabela 4.35: Visão geral dos dados e componentes do trabalho

Autor, Ref.	Algoritmos	Métricas	Base de Dados	Entradas	Dados Externos
De Felice, [23]	RBF RNCL NAIVE ARIMA	MAPE MSE MAE	Real	-Potência -Potência + Dados Externos	-Hora do Dia -Dia Normal -Cons. de Água Quente por H. -Luminosidade

A Tabela 4.36 mostra os resultados do trabalho.

Tabela 4.36: Resultados da previsão no horizonte de 1 hora a frente da fonte [23]

Prédios	Apenas Potência				Dados Externos	
	MAPE (%)					
	Melhor RBF	RNCL	Naive	SARIMA	RNCL	SARIMA
A	9,69	16,21	5,06	4,27	4,60	4,23
B	8,35	12,84	3,60	2,9	3,60	2,91
C	7,43	11,86	4,96	3,19	4,1	3,02
D	8,96	17,49	6,03	5,91	6,84	5,95
E	4,22	4,26	5,14	3,93	4,16	3,88
F	8,41	8,48	9,2	8,58	8,51	8,57
G	2,66	2,55	2,76	2,42	2,6	2,39

No geral, o que se encontra na literatura são trabalhos que realizam previsão no horizonte de 1 hora a frente ou 24 horas a frente. A questão é que não se detalha tanto a estrutura dos dados, não é falado se os registros são horários ou se são de 15 em 15 minutos, e por isso, torna-se difícil realizar uma comparação mais direta entre esse trabalho e os da literatura. No entanto, se os registros forem horários (e neste caso está sendo feita a previsão de 1 passo a frente) nota-se que o desempenho do trabalho e o desempenho dos trabalhos da literatura são parecidos, sendo que os resultados do trabalho de [8] usando o GPSO mostram desempenho maior do que as redes *feedforward* para o horizonte de previsão de 15 minutos no Estudo de Caso 1 e os resultados de [23] mostram desempenho menor que as redes *feedforward* para o horizonte de previsão de 15 minutos no Estudo de Caso 1. Vale ressaltar que a complexidade do modelo proposto neste trabalho é muito simples em comparação com os outros, com apenas 6 entradas, todas elas da potência ativa (sem entradas externas) o desempenho chegou muito próximo do que foi exposto nos outros trabalhos.

4.7 Como Economizar Aplicando um Sistema Preditor de Potência

Nessa etapa, como não foi fornecido a modalidade de tarifação da universidade nem o valor ou valores de demanda contratada, realizou-se um estudo das curvas de carga da universidade nos diferentes períodos (seco e úmido), definiu-se qual a melhor modalidade para a universidade e fez-se uma análise de quanto de demanda contratada poderia ser reduzida dispondo do sistema preditor de potência proposto nesse trabalho fazendo a compensação de demanda com GMGs.

Como foi exposto nos resultados, o erro absoluto da previsão no horizonte de 30 minutos sai muito da faixa dos 100 kW, logo, nesta etapa, optou-se por trabalhar apenas com a previsão de 15 minutos a frente, caso contrário aumentar-se-ia muito a incerteza da quantidade de potência gerada a ser injetada no sistema. Um aspecto importante a ser destacado é que a universidade possui diferentes tipos de cargas: as que não podem sofrer queda de energia (nos pavilhões de Biologia, medicina e medicina veterinária), as que podem ter uma interrupção momentânea (nos pavilhões de engenharia) e as que não sofrem interrupção ao entrar com GMGs pois possuem *nobreaks* instalados. Caso seja necessário entrar com os GMGs para assumir parte da carga (quando for constatado a ultrapassagem na demanda pelo preditor) o ideal seria acionar os grupos que atendem os pavilhões onde a carga pode ser interrompida momentaneamente ou onde a carga não seria interrompida até que o GMG assuma a carga do local.

Como foi visto no Capítulo 3, a universidade é atendida em média tensão (13,8/15 kV) e portanto é classificada como consumidor do grupo A (atendidos com tensão maior que 2,3 kV) subgrupo A4 (com tensão de fornecimento entre 2,3 a 25 kV), portanto, as modalidades tarifárias nas quais este tipo de consumidor pode ser enquadrada são:

- Tarifação Convencional;
- Tarifação Horo-Sazonal Verde;
- Tarifação Horo-Sazonal Azul.

Os consumidores do grupo A possuem tarifação binômia, logo são tarifados tanto pela demanda contratada quanto pela energia consumida.

As tarifações horo-sazonal Verde e horo-sazonal Azul permitem que sejam contratados dois valores diferentes de demanda, um para o período seco (de maio a novembro) e um para o período úmido (de dezembro a abril). A diferença entre as duas é que os consumidores inseridos na tarifação horo-sazonal Azul podem contratar

valores diferentes para a demanda nos horários de ponta e fora de ponta em cada período (seco e úmido).

4.7.1 Propondo Redução de Demanda Contratada

As Figuras 4.73 e 4.74 mostram as curvas de carga com maiores registros de potência nos períodos seco e úmido respectivamente.

Figura 4.73: Curva de carga com maior registro de potência no período seco.



Fonte: Própria

Figura 4.74: Curva de carga com maior registro de potência no período úmido.



Fonte: Própria

Analisando as Figuras 4.73 e 4.74, nota-se um perfil de curva de carga bem parecido em ambas, porém o período seco registra menores picos de potência e o período úmido mantém a demanda alta por mais tempo no primeiro pico. Pode ser observado na Figura 3.3 que, dos meses do período seco, os únicos que atingem a faixa dos 1400 kW são os meses de maio, outubro e novembro.

Da Figura 4.73, nota-se que no horário fora de ponta a curva mostra dois picos de potência com valores máximos bem próximos (na faixa de 1500 a 1600 kW), o primeiro, situado entre 10 e 12 horas e o segundo, situado entre 14 e 16 horas. No horário de ponta (das 18 as 21 horas) a curva já está em processo de queda (processo ligado primordialmente ao desligamento dos ar condicionados e ao fim do turno da tarde de alguns cursos) a curva mostra valores máximos entre 900 e 1000 kW.

Da Figura 4.74, nota-se um comportamento parecido com a Figura 4.73, porém o segundo pico tem valor mais alto, chegando quase a 200 kW a mais do que o máximo do primeiro pico. No horário fora de ponta a curva mostra valores máximos entre 1700 e 1900 kW e no horário de ponta mostra valores máximos também entre 900 e 1000 kW.

A Tabela 4.37 mostra os valores máximos de demanda em kW registrados nos períodos seco e úmido nos horários fora de ponta e na ponta.

Tabela 4.37: Maiores registros de demanda nos períodos seco e úmido em horários de ponta e fora de ponta.

Período	Horários	
	Ponta	Fora de Ponta
Seco	944,16 kW	1540 kW
Úmido	1060,6 kW	1868 kW

Das análises anteriores, tem-se valores de demanda de potência em faixas diferentes, tanto no horário de ponta quanto no horário fora de ponta em função dos períodos seco e úmido definidos pela Agência Nacional de Energia Elétrica (ANEEL). Logo, o modelo mais adequado para a universidade é o horo-sazonal Azul.

Tomando como base a Tabela 4.37 é possível definir valores adequados para as demandas contratadas na universidade nos dois períodos. Aqui neste ponto vale lembrar que os consumidores do subgrupo A4 possuem 10% de tolerância acima do valor da demanda contratada sem que seja cobrado ultrapassagem, logo, quando há registros de demanda no intervalo de até 10% acima do valor da demanda contratada o consumidor paga pela maior demanda medida, porém sem tarifa de ultrapassagem. Portanto, considerando a margem dos 10%, define-se aqui quatro valores de demandas contratados pela universidade no período dos dados do trabalho (levando em consideração que o modelo tarifário é o horo-sazonal Azul e que neste período estudado nunca houve multa por ultrapassagem). A Tabela 4.38 mostra essas informações.

Tabela 4.38: Demandas contratadas pela universidade definidas com base na análise dos dados.

Período	Demandas Contratadas	
	Ponta	Fora de Ponta
Seco	860 kW	1400 kW
Úmido	965 kW	1700 kW

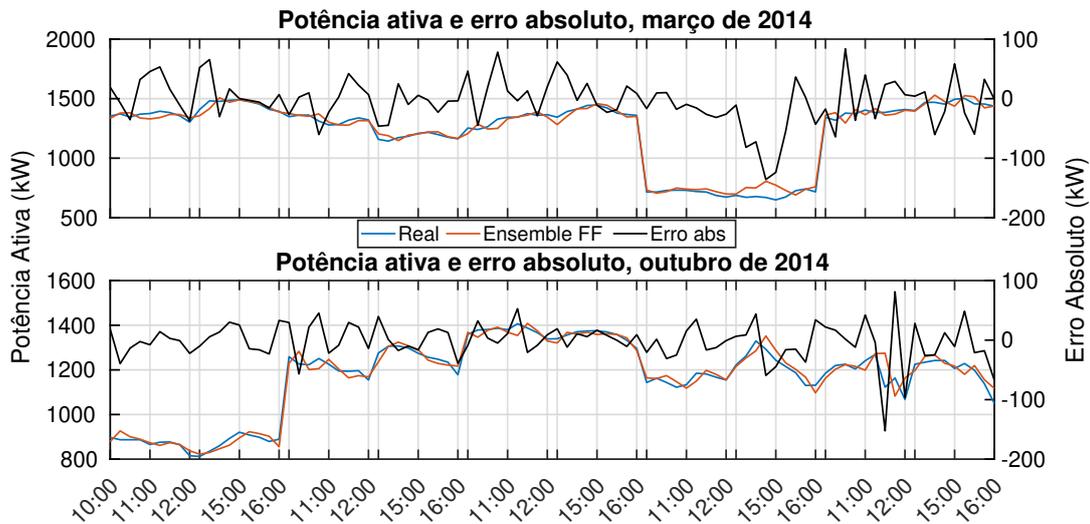
Para definir a incerteza do modelo de previsão proposto no horário fora de ponta, os registros de demanda dos picos dos horários entre as 10 e 12 horas e entre as 14 e 16 horas (que são os pontos principais da análise pois são nos picos onde se pode atuar para reduzir a demanda contratada) foram retirados dos dados de potência e das curvas de previsão do modelo de redes *feedforward*. Os quatro erros absolutos máximos entre a curva real e a curva de previsão (no horário fora de ponta) para todos os conjuntos de teste foram listados na Tabela 4.39.

Tabela 4.39: Erros absolutos máximos da previsão nos horários fora de ponta onde os picos são registrados.

Teste	Erros Absolutos Máximos (kW)			
Mar14	135,88	123,84	83,61	81,79
Abr14	99,75	78,03	71,07	53,24
Mai14	75,28	74,51	59,21	55,60
Jun14	91,79	80,83	56,83	42,63
Jul14	67,90	50,35	49,33	41,26
Ago14	96,61	85,86	61,01	59,64
Set14	67,52	43,48	43,02	41,88
Out14	152,39	96,39	81,22	67,51
Nov14	110,41	53,23	50,48	48,38
Dez14	336,33	248,50	71,78	44,98
Jan15	369,59	96,63	80,45	55,65
Fev15	522,74	109,75	104,73	82,54
Mar15	107,92	69,56	69,27	69,07

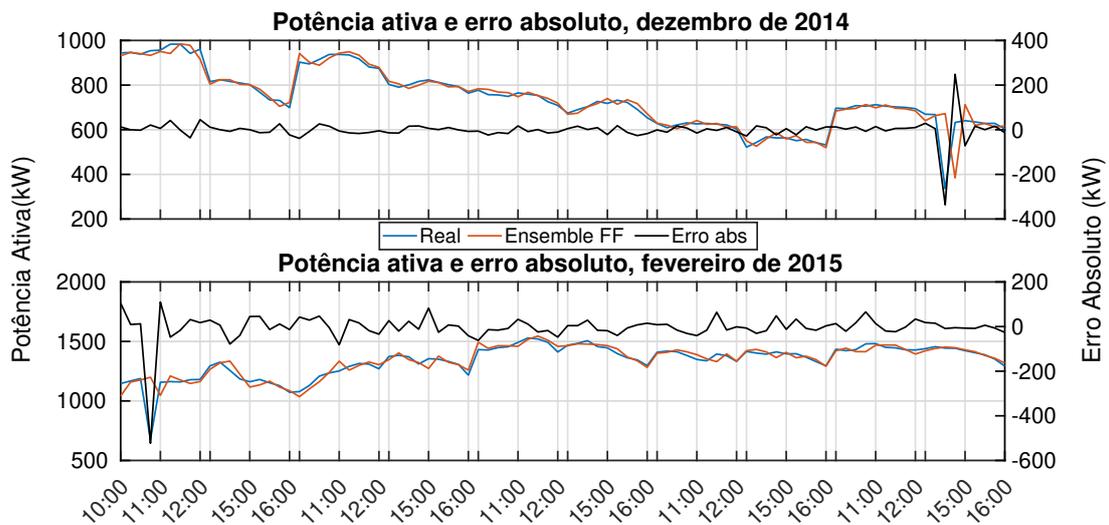
As Figuras 4.75, 4.76 e 4.77 mostram a potência ativa e o erro absoluto (em dois eixos Y na mesma Figura) durante os picos (das 10 às 12 horas e das 14 às 16 horas) de alguns conjuntos de teste para auxiliar nas análises da Tabela 4.39.

Figura 4.75: Potência ativa e erro absoluto nos intervalos de pico dos meses de março e outubro de 2014.



Fonte: Própria

Figura 4.76: Potência ativa e erro absoluto nos intervalos de pico dos meses de dezembro de 2014 e fevereiro de 2015.

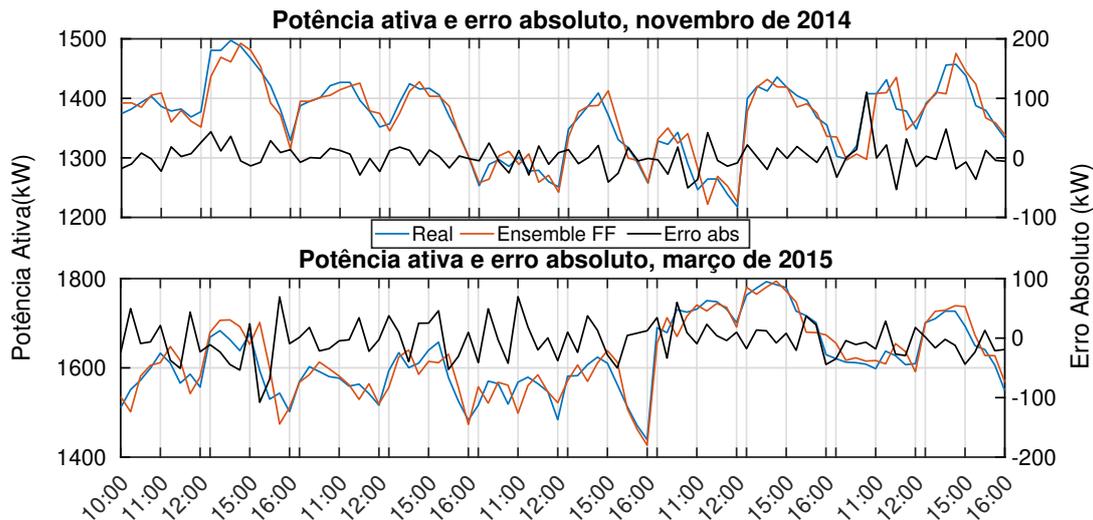


Fonte: Própria

Os conjuntos de teste dos meses de março e abril de 2014 possuem dias atípicos e por não ter muitos dias como este no conjunto de treino, o preditor tem dificuldade de prever a potência. A Tabela 4.39 mostra isso nas duas primeiras linhas, sendo que no mês de março de 2014 os erros registrados no dia atípico foi maior do que no mês de abril, fato que pode ser verificado na Figura 4.75. Tirando os erros do dia atípico, o preditor registrou erros absolutos abaixo de 100 kW. O mês de maio a setembro de 2014 também mostraram erros abaixo dos 100 kW e os meses de junho a setembro são meses mais frios, e a potência registra valores bem abaixo da demanda

contratada. O conjunto de teste do mês de outubro mostrou erro absoluto de 152,39 kW, mas além de o preditor ter errado para um valor acima do valor real (o que não acarretaria em ultrapassagem de demanda) o ponto em que o preditor erra está bem abaixo do valor da demanda contratada (1400 kW). Os meses de dezembro janeiro e fevereiro possuem *outliers* (pode ser visto na Figura 4.76 onde o mês de dezembro e o mês de fevereiro foram mostrados). Os meses de novembro de 2014 e março de 2015 mostraram erros absolutos maiores do que 100 kW e pelo preditor errar próximo da faixa das demandas contratadas (1400 e 1700 kW), porém abaixo da faixa dos 10% de tolerância, o que não acarretaria em ultrapassagem da demanda. Tendo toda essa análise em vista, o valor escolhido para a incerteza do preditor foi o erro absoluto máximo de 110,31 kW registrado em novembro de 2014, porém, ainda para adicionar uma margem de segurança, será adotado o valor de 120 kW, e este valor de potência será injetado como geração através de grupos motor-gerador que a universidade possui instalados para funcionamento em caráter emergencial.

Figura 4.77: Potência ativa e erro absoluto nos intervalos de pico dos meses de novembro de 2014 e fevereiro de 2015.

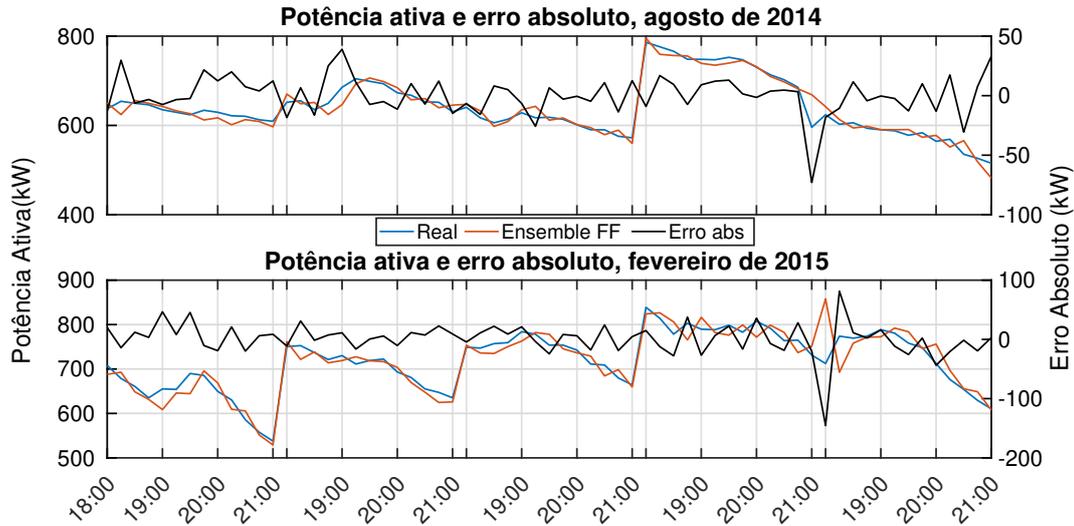


Fonte: Própria

Para definir a incerteza do modelo de previsão proposto no horário de ponta, os registros de demanda dos horários de 18 às 21 horas foram retirados de todos os conjuntos de teste dos dados de potência e das curvas de previsão do modelo de redes *feedforward*. Os erros absolutos máximos entre a curva real e a curva de previsão para todos os conjuntos de teste foram listados na Tabela 4.40.

A Figura 4.78 mostra a potência ativa e o erro absoluto (em dois eixos Y na mesma Figura) no horário de ponta para os conjuntos de teste do mês de agosto de 2014 e fevereiro de 2015.

Figura 4.78: Potência ativa e erro absoluto no horário de ponta dos meses de agosto de 2014 e fevereiro de 2015.



Fonte: Própria

Nesse ponto, destaca-se que as previsões para o horário de ponta foram mais precisas do que para o horário fora de ponta, período no qual os modelos mostraram maior dificuldade nas previsões de uma forma geral. Como pode ser visto na Tabela 4.40, fora o conjunto de teste do mês de fevereiro de 2015, os erros absolutos máximos não atingiram 75 kW.

Tabela 4.40: Erros absolutos máximos da previsão nos horários de ponta.

Teste	Erros Absolutos Máximos (kW)			
Mar14	61,10	60,93	35,96	35,31
Abr14	33,53	30,67	27,88	25,75
Mai14	52,65	45,24	44,80	42,16
Jun14	24,06	19,14	18,98	17,24
Jul14	30,50	22,80	20,15	17,60
Ago14	72,88	38,95	33,11	30,60
Set14	67,28	50,67	49,34	42,07
Out14	34,76	33,71	32,10	25,08
Nov14	51,68	51,35	50,06	42,10
Dez14	36,07	26,87	20,36	20,22
Jan15	47,31	45,22	41,66	36,21
Fev15	145,49	81,30	46,5	45,45
Mar15	44,83	40,74	28,78	27,93

Na Figura 4.78 foram mostrados os conjuntos de teste que registraram os maiores erros absolutos. O mês de agosto de 2014 registrou erro absoluto no valor de 72,88

kW e o mês de fevereiro de 2015 registrou o maior erro absoluto. Analisando a Figura 4.78, é possível perceber que o preditor está errando com potência acima da curva real, portanto o sistema não correria risco de registrar demanda de ultrapassagem, o que poderia ocorrer seria o acionamento do grupo motor-gerador de forma indevida até a chegada do próximo valor de previsão para o sistema. Tendo essa análise em vista e considerando que o sistema preditor registrou apenas em um ponto em todos os conjuntos de teste valor acima de 75 kW, o valor escolhido para a incerteza do preditor foi de 85 kW, e este valor de potência será injetado através de grupo motor-gerador toda vez que o preditor acusar ultrapassagem da demanda contratada mais os 10% de tolerância.

Definidas as incertezas do preditor nos horários de ponta e fora de ponta, é possível propor uma redução de demanda contratada em ambos horários, nos períodos seco e úmido. Para os horários fora de ponta, nos dois períodos (seco e úmido) será proposta uma redução na demanda contratada de 100 kW. No período seco (de maio a novembro), propondo uma demanda contratada de 1300 kW e estendendo aos 10% de tolerância, o valor máximo de demanda registrada sem pagamento de multa seria 1430 kW e todo valor de demanda de potência previsto acima de 1430 kW seria compensado com os grupos motor-gerador (assumindo parte das cargas da universidade em um pavilhão específico) e se necessário, desligamento de cargas até que o preditor entregue valor de potência abaixo dos 1430 kW. Pensando na análise feita e observando a Figura 3.3, com a redução de demanda e o preditor proposto nesse trabalho, só seria necessário compensar demanda nos meses de maio, outubro e novembro do período seco, em apenas apenas onze dias (contando a quantidade de vezes que as curvas diárias passam da linha dos 1400 kW na Figura 3.3). Supondo que o sistema de geração tenha que compensar potência durante todas as horas do horário fora de ponta dos onze dias (nos picos de potência que aparecem das 10 às 12 e das 14 às 16 horas) no período seco inteiro o grupo funcionaria por apenas 44 horas, o que mostra que além de economizar durante todos os outros meses do período, o sistema não ficaria compensando sempre a demanda com os grupos motor-gerador, e isso reflete em menos gastos com combustível (para manter o grupo operando), menos horas de funcionamento para as máquinas e menos manutenções preventivas e corretivas.

Ainda para o horário fora de ponta, no período úmido (de dezembro a abril), propondo uma demanda contratada de 1600 kW e estendendo aos 10% de tolerância, o valor máximo de demanda registrada sem pagamento de multa por ultrapassagem seria 1760 kW. Observando a Figura 3.3, com a redução de demanda e o preditor proposto nesse trabalho seria necessário compensar demanda com os grupos apenas no mês de março de 2015 em apenas apenas quatro dias (contando a quantidade de vezes que as curvas diárias passam da metade do intervalo entre as linhas dos

1600 e dos 1800 kW na Figura 3.3). Supondo que o sistema de geração tenha que compensar potência durante todas as horas do horário fora de ponta nos 4 dias, os grupos funcionariam por apenas 16 horas (destaco aqui que a economia poderia ser ainda maior caso a demanda contratada fosse reduzida para 1500 kW, mas isso também acarretaria em aumentar a quantidade de potência que os grupos teriam que assumir aumentando assim a quantidade de grupos funcionando durante as horas de compensação) o que mostra como o preditor poderia otimizar o contrato de demanda da universidade durante o horário fora de ponta.

Para o horário de ponta no período seco (de maio a novembro) será proposta uma redução na demanda contratada de 50 kW. Propondo uma demanda contratada de 810 kW e estendendo aos 10% de tolerância, o valor máximo de demanda registrada sem pagamento de multa por ultrapassagem seria de 891 kW. No horário de ponta fica um pouco mais complicado para avaliar a quantidade de dias e horas em que o grupo entraria compensando a demanda da universidade, mas a Tabela 4.41 mostra os cinco maiores registros de potência durante o horário de ponta em todos os conjuntos de teste.

Tabela 4.41: Cinco maiores registros de potência em todos os conjuntos de teste durante o horário de ponta.

Teste	Erros Absolutos Máximos (kW)				
Mar14	926,24	887,04	881,44	870,24	844,48
Abr14	845,6	833,28	812	801,92	790,72
Mai14	982,24	938,56	922,88	872,48	787,36
Jun14	627,2	613,76	600,32	596,96	585,76
Jul14	496,16	495,04	486,08	479,36	472,64
Ago14	786,24	776,16	766,08	752,64	748,16
Set14	826,56	819,84	805,28	796,32	773,92
Out14	832,16	829,92	818,72	814,24	813,12
Nov14	935,2	916,16	884,8	872,48	864,64
Dez14	484,96	450,24	449,12	446,88	444,64
Jan15	580,16	576,8	570,08	568,96	551,04
Fev15	838,88	814,24	807,52	803,04	798,56
Mar15	1013,6	997,92	973,28	967,68	949,76

De acordo com a Tabela 4.41, os cinco máximos valores de potência registrados nos conjuntos de teste vão ultrapassar a margem de tolerância dos 10% no período seco nos meses de maio e novembro de 2014 em 5 situações, três no mês de maio de 2014 e duas no mês de novembro de 2014. Supondo que o grupo ficaria compensando a demanda durante todo o horário de ponta (o que seria muito difícil de acontecer pois o perfil do horário de ponta é de queda de cargas e geralmente o maior registro

fica sendo às 18 horas), o grupo trabalharia por 15 horas num total de (contando os 5 dias de cada conjunto de teste e os 7 meses do período seco seriam um total de 35 dias) 35 dias compensando potência menor do que 100 kW.

Para horário de ponta no período úmido será proposta uma redução na demanda contratada de 100 kW. Propondo uma demanda contratada de 865 kW e estendendo aos 10% de tolerância, o valor máximo de demanda registrada sem pagamento de multa por ultrapassagem seria de 951,5 kW. Como pode ser visto na 4.41, o valor é atingido apenas no mês de março de 2015, em cinco situações diferentes e o valor a ser compensado não chega a 100 kW. Supondo que a demanda excedente seja toda atendida pelo grupo (ou grupos) durante as três horas do horário de ponta nos 5 dias do conjunto de teste do mês de março de 2015 seriam um total de 15 horas de funcionamento do grupo em 30 dias (contando os cinco dias dos conjuntos de testes em cada um dos seis meses do período úmido de dados disponíveis para o trabalho). O sistema proposto foi capaz de economizar em todos os períodos do ano nos horários de ponta e fora do ponta e a Tabela 4.42 resume o que foi definido neste estudo.

Tabela 4.42: Demandas contradas após o estudo feito com os modelos de previsão de potência.

Demandas Contratadas		
Período	Ponta	Fora de Ponta
Seco	810 kW	1300 kW
Úmido	865 kW	1600 kW

Com base nos estudos, foi possível propor uma redução de 50 e 100 kW no período seco nos horários de ponta e fora de ponta respectivamente e uma redução de 100 kW nos horários de ponta e fora de ponta no período úmido, fazendo a compensação da demanda excedente do contratado somada com os 10% de tolerância primordialmente com grupo motor gerador e ainda com a possibilidade de desligar algumas cargas (como ar condicionados em um pavilhão específico por exemplo) caso seja necessário.

Com o auxílio da Tabela 3.2 podemos definir a quantidade de grupos que atuariam para compensar os 85 kW (considerando a incerteza do preditor) do horário de ponta do período seco pode-se propor a atuação dos grupos Leon Heimer do NBCGIB e o Stanford da Unidade de Pesquisa e Desenvolvimento, com potência de compensação de até 136 kW. O NBCGIB e a Unidade de Pesquisa e Desenvolvimento são locais propícios para colocar os grupos compensando potência pois os equipamentos possuem *nobreaks*, mantendo as cargas ligadas até o grupo assumir a carga do local.

Para os casos de compensação de 100 kW (período seco fora de ponta e período úmido na ponta e fora de ponta), os grupos do NBCGIB e o da Unidade de Pesquisa e Desenvolvimento Organizacional, também serão relacionados.

Fechando esta parte, a central de análise e otimização (3.10) que enviaria os comandos para acionamento dos grupos precisaria das seguintes informações:

- Dia, hora e mês;
- Período (seco ou úmido)
- Valor de demandas contratadas nos dois períodos na ponta e fora de ponta;
- Valor da previsão de demanda de potência para os 15 minutos a frente.

4.7.2 Cálculo da Economia

É necessário salientar que as análises anteriores foram feitas em cima dos conjuntos de teste, que corresponderam a apenas 5 dias de cada um dos meses (a última semana de cada mês). Neste ponto, para realizar um cálculo econômico, foi necessário fazer algumas extrapolações baseadas no que foi visto, são elas:

Período seco, horário de ponta: num total de 35 dias (a última semana de cada um dos sete meses do período seco), houve operação dos grupos durante 15 horas. Considerando esse tempo de operação constante durante os meses e sabendo que o período seco vai de maio a novembro e tem um total de 214 dias, com uma regra de três simples, tem-se um total de 30,57 horas de funcionamento dos grupos durante todo o período seco no horário de ponta. Com base nas informações do GMG Heimer no capítulo Apêndice B, e considerando que ambos fossem do mesmo modelo do anexo, o consumo de óleo diesel por hora em cada grupo corresponde a 17,8 litros. Utilizando o valor de R\$ 3,582 para um litro de óleo diesel custo do consumo total de combustível ficaria:

$$31 \text{ horas} \times 2 \text{ grupos} \times 17,8 \text{ litros} \times R\$ 3,582 \text{ litro do diesel} = R\$ 3.953,09$$

no cálculo acima, o valor de 30,57 horas de funcionamento foi aproximado para 31.

Utilizando as tarifas de energia do período de 01/07/2020 a 21/04/2021 do site da concessionária COELBA, o valor do custo de 1 kW no período seco no horário de ponta para os consumidores A4 com modelo de tarifação horossazonal azul é R\$ 65,0741. Como a redução proposta foi de 50 kW, o sistema economizaria 50 kW em cada um dos meses do período seco. A economia sem o custo de operação ficaria:

$$65,0741 \times 50 \text{ kW} \times 7(\text{total de meses do período seco}) = R\$ 22.775,83$$

A economia total com o custo de operação dos grupos ficaria:

$$R\$ 22.775,83 - R\$ 3.953,09 = R\$ 18.822,84$$

Período seco, horário fora de ponta: foi visto que os durante todo o período seco no horário fora de ponta os GMGs estariam operando por apenas 44 horas. Sendo assim o custo do consumo total de combustível ficaria:

$$44 \text{ horas} \times 2 \text{ grupos} \times 17,8 \text{ litros} \times R\$ 3,582 \text{ litro do diesel} = R\$ 5.610,84$$

Utilizando as tarifas de energia do período de 01/07/2020 a 21/04/2021 do site da concessionária COELBA, o valor do custo de 1 kW no período seco no horário fora de ponta para os consumidores A4 com modelo de tarifação horossazonal azul é R\$ 24,3516. Como a redução proposta foi de 100 kW, o sistema economizaria 100 kW em cada um dos meses do período seco. A economia sem o custo de operação ficaria:

$$24,3516 \times 100 \text{ kW} \times 7(\text{total de meses do período seco}) = R\$ 17.046,12$$

A economia total com o custo de operação dos grupos ficaria:

$$R\$ 17.046,12 - R\$ 5.610,84 = R\$ 11.435,28$$

Período úmido, horário de ponta: num total de 30 dias (a última semana de cada um dos seis meses do período úmido de dados disponíveis para este trabalho), houve operação dos grupos durante 15 horas, todas as operações no mês de março de 2015. Considerando esse tempo de operação constante durante os dias, os grupos entrariam em funcionamento em todos os dias de semana do mês de março de 2015, sendo um total de 22 dias de semana, com o funcionamento de 3 horas por dia, daria um total de 66 horas de funcionamento durante todo o período úmido no horário de ponta. Com base nas informações do GMG Heimer no capítulo Apêndice B, e considerando que ambos fossem do mesmo modelo do anexo, o consumo de óleo diesel por hora em cada grupo corresponde a 17,8 litros. Utilizando o valor de R\$ 3,582 para um litro de óleo diesel custo do consumo total de combustível ficaria:

$$66 \text{ horas} \times 2 \text{ grupos} \times 17,8 \text{ litros} \times R\$ 3,582 \text{ litro do diesel} = R\$ 8.416,27$$

Utilizando as tarifas de energia do período de 01/07/2020 a 21/04/2021 do site

da concessionária COELBA, o valor do custo de 1 kW no período úmido no horário de ponta para os consumidores A4 com modelo de tarifação horossazonal azul é R\$ 65,0741. Como a redução proposta foi de 100 kW, o sistema economizaria 100 kW em cada um dos meses do período úmido. A economia sem o custo de operação ficaria:

$$65,0741 \times 100 \text{ kW} \times 6(\text{total de meses do período úmido}) = R\$ 39.044,46$$

A economia total com o custo de operação dos grupos ficaria:

$$R\$ 39.044,46 - R\$ 8.416,27 = R\$ 30.628,19$$

Período úmido, horário fora de ponta: foi visto que os durante todo o período úmido no horário fora de ponta os GMGs estariam operando por apenas 16 horas. Sendo assim o custo do consumo total de combustível ficaria:

$$16 \text{ horas} \times 2 \text{ grupos} \times 17,8 \text{ litros} \times R\$ 3,582 \text{ litro do diesel} = R\$ 2.040,31$$

Utilizando as tarifas de energia do período de 01/07/2020 a 21/04/2021 do site da concessionária COELBA, o valor do custo de 1 kW no período seco no horário fora de ponta para os consumidores A4 com modelo de tarifação horossazonal azul é R\$ 24,3516. Como a redução proposta foi de 100 kW, o sistema economizaria 100 kW em cada um dos meses do período seco. A economia sem o custo de operação ficaria:

$$24,3516 \times 100 \text{ kW} \times 6(\text{total de meses do período úmido}) = R\$ 14.610,96$$

A economia total com o custo de operação dos grupos ficaria:

$$R\$ 14.610,96 - R\$ 2.040,31 = R\$ 12.570,65$$

Sendo assim, a Tabela 4.43 agrupa as informações anteriores.

Tabela 4.43: Resumo dos cálculos econômicos por período do ano e por posto diário.

Período	Economia (R\$)	
	Ponta	Fora de Ponta
Seco	18.822,84	11.435,28
Úmido	30.628,19	12.570,65

De acordo com a Tabela 4.43, com as considerações que foram feitas durante esta análise, seria possível economizar um total de R\$ 73.456,96 caso o sistema preditor proposto no trabalho fosse aplicado na universidade durante o período abrangido pelos dados analisados.

Capítulo 5

Conclusões

Este trabalho avaliou a aplicação de cinco métodos de previsão de potência, três baseados IA e dois métodos estatísticos para prever demanda de potência de uma universidade usando como entrada apenas dados de potência ativa nos horizontes de 15 e de 30 minutos a frente.

Nesse contexto, foi proposto um estudo da série temporal de potência ativa do local com as etapas de pré-processamento, estimação de um modelo ARIMA, sintonização dos hiperparâmetros de todos os modelos de IA utilizados e por fim os resultados das previsões de três estudos de caso para definir qual a melhor forma de entrar com os dados temporais nos modelos.

Na etapa de pré-processamento, mostrou-se os principais parâmetros do conjunto de teste utilizado, foram retirados os finais de semana e feriados dos dados bem como *outliers* nos quais a potência ativa teve queda para zero e a estimação do modelo ARIMA definiu os atrasos temporais que foram utilizados como entrada nos modelos.

Em seguida, foram propostos três estudos de caso, um estudo de caso de previsão semanal em qualquer mês do ano, aplicando cinco modelos, um estudo de caso de previsão mensal utilizando os dois melhores modelos do primeiro estudo de caso e um último estudo de caso de previsão semanal, também utilizando os dois melhores modelos do primeiro estudo de caso usando como treino os registros de potência do mês anterior para prever a semana seguinte.

O desempenho dos métodos de previsão foi avaliado utilizando os erros MAPE, MAE e MSE. Os resultados das previsões nos três estudos de caso mostraram que os preditores tem dificuldade de prever os picos de potência registrados durante os horários das 10 às 12 horas e das 14 às 16 e a queda de potência durante o horário do almoço que ocorre entre as 12 e 14 horas, concentrando seus erros absolutos mais altos nessa região das curvas diárias (e neste ponto fica óbvio o porquê de ter tantos trabalhos na literatura focados em previsão de picos de potência em instalações elétricas).

O Estudo de Caso 1 mostrou o melhor desempenho para prever no horizonte de

15 minutos utilizando um conjunto de redes neurais *feedforward* com MAE variando de 11,29 a 18,84 kW, MSE variando de 280,33 a 1374,90 kW² e MAPE variando de 1,85% a 2,83%.

O Estudo de Caso 3 mostrou o melhor desempenho para prever no horizonte de 30 minutos utilizando um conjunto de redes neurais *feedforward* e o método SARIMA com MAE variando de 19,32 a 38,18 kW, MSE variando de 769,14 a 6898,43 kW² MAPE variando de 3,18% a 5,60% kW.

Das técnicas estatísticas o SARIMA realmente é uma técnica muito sólida, que leva em consideração os atrasos temporais da série e as componentes sazonais e autorregressivas que a série possui. O desempenho apresentado foi muito bom e certamente se tratando de um problema de séries temporais ela deve ser aplicada. Dentre as técnicas de IA, a ESN mostrou-se muito sensível às inicializações, e por isso mostrou desempenho um pouco abaixo das demais redes, por ser inicializada de forma aleatória. Um bom critério de inicialização dos pesos poderia melhorar bastante os resultados, a técnica é extremamente interessante pela velocidade na etapa de treinamento. Como foi visto na literatura, o modelo de redes *feedforward* realmente é um modelo indispensável de ser aplicado em problemas de previsão de curto prazo de potência ativa, a técnica apresentou os melhores resultados.

Trazer um trabalho de eficiência e otimização para aplicação real é sempre um processo desafiador. Tratando-se deste trabalho foi um pouco mais desafiador pois não havia informações sobre os valores de demanda contratada da universidade no período dos dados e nem o modelo de tarifação em que a mesma estava inserida. Logo, foi necessário realizar um estudo das curvas de carga do local para definir da melhor forma possível esses dois pontos antes de fazer qualquer análise. Utilizando GMGs em aplicação em conjunta com o modelo de previsão proposto nesse trabalho para o horizonte de 15 minutos, foi possível e viável propor uma redução na demanda contratada nos dois períodos (seco e úmido) nos horários de ponta e fora de ponta. No período seco, foi possível propor uma redução de 50 kW de demanda contratada no horário de ponta e 100 kW no horário fora de ponta. No período úmido foi possível propor redução de 100 kW de potência nos horários de ponta e fora de ponta. Com as considerações feitas na etapa da análise econômica, foi possível mostrar que seria possível economizar um total de R\$ 73.456,96 aplicando o preditor proposto no trabalho juntamente com a operação dos grupos e reduzindo as demandas contratadas da universidade.

Os trabalhos futuros da pesquisa devem ser voltados para inserção de dados além da potência ativa, como temperatura, hora do dia, dia da semana e mês do ano para avaliar os efeitos sobre os resultados da previsão, a idéia é reduzir ainda mais os erros absolutos e aumentar a precisão dos preditores. Um outro ponto interessante seria propor uma outra fonte de geração, com placas solares, por exemplo, através de

um projeto com os geradores na modalidade *grid zero*, que não necessitam solicitar mudança de contrato com a concessionária. Esse tipo de modalidade de geração fotovoltaica não injeta potência para a concessionária, apenas é usado para o consumo imediato e atendem a demanda de determinado quadro de distribuição. Com esta outra forma de geração seria possível retirar a compensação da demanda utilizando GMGs do horário fora de ponta, trabalhando apenas com os geradores fotovoltaicos, podendo aumentar ainda mais a economia no processo.

Referências Bibliográficas

- [1] SOLIMAN, S. A.-H., AL-KANDARI, A. M. *Electrical load forecasting: modeling and model construction*. Burlington, MA, USA, Elsevier, 2010.
- [2] NOSE FILHO, K. “Previsão de carga multinodal utilizando redes neurais de regressão generalizada”, 2011.
- [3] ROCCO, S. M. D. “Previsão de demandas para controle dos montantes de uso do sistema de transmissão para distribuidoras de energia elétrica”, 2008.
- [4] PERÇUKU, A., MINKOVSKA, D., STOYANOVA, L. “Big Data And Time Series Use In Short Term Load Forecasting In Power Transmission System”, *Procedia Computer Science*, v. 141, pp. 167–174, 2018.
- [5] ABREU, T., AMORIM, A. J., SANTOS-JUNIOR, C. R., et al. “Multinodal load forecasting for distribution systems using a fuzzy-artmap neural network”, *Applied Soft Computing*, v. 71, pp. 307–316, 2018.
- [6] SRUTHI, J., CATHERINE, R. H. “A Review on Electrical Load Forecasting in Energy Management”, *Int. J. Innovative Sci. Eng. Technol*, v. 2, n. 3, pp. 670–676, 2015.
- [7] WELIKALA, S., DINESH, C., EKANAYAKE, M. P. B., et al. “Incorporating appliance usage patterns for non-intrusive load monitoring and load forecasting”, *IEEE Transactions on Smart Grid*, v. 10, n. 1, pp. 448–461, 2019.
- [8] RAZA, M. Q., NADARAJAH, M., HUNG, D. Q., et al. “An intelligent hybrid short-term load forecasting model for smart power grids”, *Sustainable Cities and Society*, v. 31, pp. 264–275, 2017.
- [9] NAGY, G. I., BARTA, G., KAZI, S., et al. “GEFCom2014: Probabilistic solar and wind power forecasting using a generalized additive tree ensemble approach”, *International Journal of Forecasting*, v. 32, n. 3, pp. 1087–1093, 2016.

- [10] YUAN, C., LIU, S., FANG, Z. “Comparison of China’s primary energy consumption forecasting by using ARIMA (the autoregressive integrated moving average) model and GM (1, 1) model”, *Energy*, v. 100, pp. 384–390, 2016.
- [11] FUMO, N., BISWAS, M. R. “Regression analysis for prediction of residential energy consumption”, *Renewable and Sustainable Energy Reviews*, v. 47, pp. 332–343, 2015.
- [12] HAYDARI, Z., KAVEHNIA, F., ASKARI, M., et al. “Time-series load modelling and load forecasting using neuro-fuzzy techniques”. In: *Electrical Power Quality and Utilisation, 2007. EPQU 2007. 9th International Conference on*, pp. 1–6. IEEE, 2007.
- [13] ZHANG, F., DEB, C., LEE, S. E., et al. “Time series forecasting for building energy consumption using weighted Support Vector Regression with differential evolution optimization technique”, *Energy and Buildings*, v. 126, pp. 94–103, 2016.
- [14] HADRI, S., NAITMALEK, Y., NAJIB, M., et al. “A Comparative Study of Predictive Approaches for Load Forecasting in Smart Buildings”, *Procedia Computer Science*, v. 160, pp. 173–180, 2019.
- [15] GORDILLO-ORQUERA, R., LOPEZ-RAMOS, L. M., MUÑOZ-ROMERO, S., et al. “Analyzing and forecasting electrical load consumption in healthcare buildings”, *Energies*, v. 11, n. 3, pp. 493, 2018.
- [16] NEPAL, B., YAMAHA, M., YOKOE, A., et al. “Electricity load forecasting using clustering and ARIMA model for energy management in buildings”, *Japan Architectural Review*, v. 3, n. 1, pp. 62–76, 2020.
- [17] DAGDOUGUI, H., BAGHERI, F., LE, H., et al. “Neural network model for short-term and very-short-term load forecasting in district buildings”, *Energy and Buildings*, v. 203, pp. 109408, 2019.
- [18] KIM, Y., SON, H.-G., KIM, S. “Short term electricity load forecasting for institutional buildings”, *Energy Reports*, v. 5, pp. 1270–1280, 2019.
- [19] NETO, A. H., FIORELLI, F. A. S. “Comparison between detailed model simulation and artificial neural network for forecasting building energy consumption”, *Energy and buildings*, v. 40, n. 12, pp. 2169–2176, 2008.
- [20] AYDINALP-KOKSAL, M., UGURSAL, V. I. “Comparison of neural network, conditional demand analysis, and engineering approaches for modeling

- end-use energy consumption in the residential sector”, *Applied Energy*, v. 85, n. 4, pp. 271–296, 2008.
- [21] BELSHAW, M., TAATI, B., SNOEK, J., et al. “Towards a single sensor passive solution for automated fall detection”. In: *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pp. 1773–1776, Boston, Massachusetts, USA, 2011. IEEE.
- [22] VAZQUEZ, R., AMARIS, H., ALONSO, M., et al. “Assessment of an adaptive load forecasting methodology in a smart grid demonstration project”, *Energies*, v. 10, n. 2, pp. 190, 2017.
- [23] DE FELICE, M., YAO, X. “Short-term load forecasting with neural network ensembles: A comparative study [application notes]”, *IEEE Computational Intelligence Magazine*, v. 6, n. 3, pp. 47–56, 2011.
- [24] SAPANKEVYCH, N. I., SANKAR, R. “Time series prediction using support vector machines: a survey”, *IEEE Computational Intelligence Magazine*, v. 4, n. 2, 2009.
- [25] BROCKWELL, P. J., DAVIS, R. A., CALDER, M. V. *Introduction to time series and forecasting*, v. 2. New York, New York, USA, Springer, 2002.
- [26] FEINBERG, E. A., GENETHLIOU, D. “Load forecasting”. In: *Applied mathematics for restructured electric power systems*, Springer, pp. 269–285, 2005.
- [27] 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.
- [28] KIRCHGÄSSNER, G., WOLTERS, J., HASSLER, U. *Introduction to modern time series analysis*. Berlin, Berlin, Alemanha, Springer Science & Business Media, 2012.
- [29] MORETTIN, P. A., TOLOI, C. “Análise de séries temporais”. In: *Análise de séries temporais*, São Paulo, São Paulo, Brasil, 2006.
- [30] MENEZES JUNIOR, J. “Contribuições ao problema de predição recursiva de séries temporais univariadas usando redes neurais recorrentes.” Fortaleza, Ceará, Brasil, 2012.
- [31] BOX, G. E., JENKINS, G. M., REINSEL, G. C., et al. *Time series analysis: forecasting and control*. San Francisco, CA:, John Wiley & Sons, 2015.

- [32] SHUMWAY, R. H., STOFFER, D. S. *Time series analysis and its applications: with R examples*. New York, New York, USA, Springer, 2017.
- [33] FACELI, K., LORENA, A. C., GAMA, J., et al. “Inteligência Artificial: Uma abordagem de aprendizado de máquina”, Rio de Janeiro, Brasil, 2011.
- [34] DE PÁDUA BRAGA, A., DE LEON FERREIRA, A. C. P., LUDERMIR, T. B. *Redes neurais artificiais: teoria e aplicações*. Rio de Janeiro, Rio de Janeiro, Brasil, LTC Editora, 2007.
- [35] HAYKIN, S. *Neural networks: a comprehensive foundation*. Hamilton, Ontario, Canada, Prentice Hall PTR, 1994.
- [36] SIMEÓN, E. J. A. “Prognóstico de falhas baseado em redes neurais com estados de eco”, Brasília, 2015.
- [37] HOPFIELD, J. J. “Neural networks and physical systems with emergent collective computational abilities”, *Proceedings of the national academy of sciences*, v. 79, n. 8, pp. 2554–2558, 1982.
- [38] WERBOS, P. J. “Backpropagation through time: what it does and how to do it”, *Proceedings of the IEEE*, v. 78, n. 10, pp. 1550–1560, 1990.
- [39] WILLIAMS, R. J., ZIPSER, D. “A learning algorithm for continually running fully recurrent neural networks”, *Neural computation*, v. 1, n. 2, pp. 270–280, 1989.
- [40] DOS SANTOS, E. P., VON ZUBEN, F. J. “Efficient second-order learning algorithms for discrete-time recurrent neural networks”. In: *Recurrent Neural Networks*, CRC Press, pp. 55–83, Campinas, São Paulo, Brasil, 1999.
- [41] LUKOŠEVIČIUS, M. “A practical guide to applying echo state networks”. In: *Neural networks: Tricks of the trade*, Springer, pp. 659–686, 2012.
- [42] JAEGER, H. *Tutorial on training recurrent neural networks, covering BPPT, RTRL, EKF and the “echo state network” approach*, v. 5. GMD-Forschungszentrum Informationstechnik Bonn, 2002.
- [43] JAEGER, H. “The “echo state” approach to analysing and training recurrent neural networks-with an erratum note”, *Bonn, Germany: German National Research Center for Information Technology GMD Technical Report*, v. 148, n. 34, pp. 13, 2001.

- [44] CYBENKO, G. “Approximation by superpositions of a sigmoid function.-
Mathematics of Control, Signals and Systems, vol. 2”, Berlin, Alemanha,
1989.
- [45] WEDDING II, D. K., CIOS, K. J. “Time series forecasting by combining RBF
networks, certainty factors, and the Box-Jenkins model”, *Neurocomputing*,
v. 10, n. 2, pp. 149–168, 1996.
- [46] BOCCATO, L., OTHERS. “Novas propostas e aplicações de redes neurais com
estados de eco”, Campinas, São Paulo, Brasil, 2013.
- [47] SAVIOZZI, M., MASSUCCO, S., SILVESTRO, F. “Implementation of advanced
functionalities for Distribution Management Systems: Load forecasting
and modeling through Artificial Neural Networks ensembles”, *Electric
Power Systems Research*, v. 167, pp. 230–239, 2019.

Apêndice A

Trabalhos Publicados

Durante o desenvolvimento do trabalho, os artigos foram aceitos para apresentação em congressos nacionais listados a seguir:

A.1 Artigos apresentados em Congressos

Weyll, A. L. C., Simas Filho, E. F., Samejima, k., Cruz, F. C. “Previsão de Curto Prazo da Potência Ativa em Instalação de Médio Porte Utilizando um Conjunto de Redes Neurais Artificiais.” In: *14th BRAZILIAN COMPUTATIONAL INTELLIGENCE MEETING*. Belém, 2019.

Resumo: A previsão de carga é um processo fundamental para uma operação confiável em sistemas elétricos de potência, principalmente em instalações que dispõem de sistemas de geração distribuída que podem ser dinamicamente integrados a rede. No entanto, equilibrar demanda e geração em tempo real não é uma tarefa fácil, devido a forte influência de fatores meteorológicos e variáveis exógenas na previsão da potência. Neste trabalho, é proposta a utilização de conjuntos de redes neurais artificiais para a previsão de potência consumida em uma instalação de médio porte no horizonte de 15 minutos a frente. Arquiteturas tipo perceptron de múltiplas camadas e rede de função de base radial foram utilizadas e os resultados comparados com modelos ARIMA e Naive. Os erros médio absoluto e médio absoluto percentual foram utilizados para avaliar e comparar o desempenho dos preditores.

Weyll, A. L. C., Simas Filho, E. F., Cruz, F. C. “Previsão de Demanda de Curta Duração Utilizando Modelo NAR de Redes Neurais e Naive.” In: VIII Conferência Nacional em Comunicações, Redes e Segurança da Informação. Salvador, 2018.

Resumo: Estimar a demanda futura dispondo de um histórico de medições

utilizando técnicas eficientes de previsão, é necessário para determinar a utilização de uma rede inteligente. No entanto, propor um método de previsão preciso não é uma tarefa simples devido a variáveis exógenas e meteorológicas. Neste artigo, são aplicadas duas técnicas de previsão, uma baseada em redes neurais autorregressivas não lineares (NAR) do tipo feedforward e outra no modelo de previsão Naive para horizonte de 30 minutos a frente.

Apêndice B

Anexos



GEHP-83

Potência

Stand By [60Hz]	83kVA 66kW
Prime [60Hz]	75kVA 60kW
Stand By [50Hz]	66kVA 53kW
Prime [50Hz]	60kVA 48kW

Motor

Fabricante	Perkins
Modelo	1104A-44TG1
Potência	99 HP [60Hz] 86 HP [50Hz]
Cilindros	4 em linha
Cilindrada Total	4.4L
Compressão	17.25:1
Aspiração	Turbocharged
Combustão	Injeção Direta
Consumo	17.8L/h [60Hz] 14.8L/h [50Hz] à 100% de carga contínua
Sistema de arrefecimento	Refrigerado a água
Filtros	Ar, combustível e óleo.
Sistema elétrico	12V (bateria incluída), alternador e carregador de bateria.
Painel	RPM, horímetro, temperatura da refrigeração, pressão do óleo, partida.
Proteção	Parada do motor por superaquecimento e baixa pressão do óleo.

Alternador

Fabricante	Heimer
Modelo	ATED
Tipo	Síncrono, sem escovas, com ímã permanente, 04 pólos trifásico ou monofásico.
Ligação	Estrela com neutro acessível.
Regulação	Regulador de tensão eletrônico a 2%.
Ventilação	Ventilador montado no eixo.
Isolamento	Classe "H"
Mancais	Mono ou duplo mancal (Disponível sob pedido).

Dimensões

	Comprimento	Largura	Altura	Peso (Kg)
Grupo Aberto	1825mm	705mm	1365mm	1056Kg
Grupo Insonorizado	2600mm	1200mm	1770mm	1688Kg

Painel de Comando e Controle

Equipado com módulos microprocessados para supervisão de rede/gerador bem como proteção do sistema.



Base

Feita em aço com solda MIG com apoios de borracha para o motor e alternador. Possui reservatório de combustível incorporado. A linha Silent possui cabines tratadas contra som: Insonorizada com 75db à 7m ou 85db à 1,5m.

Acessórios Incluídos

Silencioso com conexão flexível e anti-vibratórios. Acompanha todos os manuais técnicos de operação e manutenção com diagramas elétricos.



Gerador Aberto sem insonorização.



Gerador Cabinado com insonorização.

