

CAMILLA NAYARA SANTOS MOTA

**PREVISÃO DE CARGAS ELÉTRICAS ATRAVÉS DO
BACKPROPAGATION ESTOCÁSTICO**

Ilha Solteira

2021

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

CAMILLA NAYARA SANTOS MOTA

**PREVISÃO DE CARGAS ELÉTRICAS ATRAVÉS DO
BACKPROPAGATION ESTOCÁSTICO**

Dissertação submetida à Universidade Estadual Paulista - UNESP, Câmpus de Ilha Solteira, para a obtenção do título de Mestre em Engenharia Elétrica.

Orientadora: Prof^ª. Dra. Mara Lúcia Martins Lopes

Ilha Solteira

2021


FICHA CATALOGRÁFICA
Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

M917p Mota, Camilla Nayara Santos.
Previsão de cargas elétricas através do backpropagation estocástico /
Camilla Nayara Santos Mota. -- Ilha Solteira: [s.n.], 2021
49 f. : il.

Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de
Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2021

Orientador: Mara Lúcia Martins Lopes
Inclui bibliografia

1. Backpropagation . 2. Estocástico. 3. Previsão de cargas elétricas.


Raiane da Silva Santos

Supervisora Técnica de Seção
Seção Técnica de Referência, Atendimento ao usuário e Documentação
Diretoria Técnica de Biblioteca e Documentação
CRB/8 - 9999



UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Ilha Solteira

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: Previsão de Cargas Elétricas usando Backpropagation Estocástico

AUTORA: CAMILLA NAYARA SANTOS MOTA

ORIENTADORA: MARA LUCIA MARTINS LOPES

Aprovada como parte das exigências para obtenção do Título de Mestra em ENGENHARIA ELÉTRICA, área: Automação pela Comissão Examinadora:

Profª. Drª. MARA LUCIA MARTINS LOPES (Participação Virtual)
Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira - UNESP

Prof. Dr. CARLOS ROBERTO MINUSSI (Participação Virtual)
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira - UNESP

Profa. Dra. THAYS APARECIDA DE ABREU SANTOS (Participação Virtual)
Faculdade de Tecnologia de Americana - FATEC Americana

Ilha Solteira, 03 de maio de 2021

AGRADECIMENTOS

Agradeço a Deus acima de tudo, que me permitiu alcançar esse sonho e me concedeu forças para superar as dificuldades. Em especial, dedico meus agradecimentos:

À minha mãe Márcia Célia e meus avós Vandolina e Lázaro, meus exemplos a serem seguidos, e nunca mediram esforços para que eu chegasse até esta etapa da minha vida, com todo apoio e dedicação;

À minha orientadora Prof^a. Mara Lúcia Martins Lopes, por todo ensinamento, confiança, acolhimento para que eu pudesse continuar com meu trabalho, por sempre me fazer acreditar que eu sou capaz e acima de tudo uma amiga;

Ao Prof. Carlos Roberto Minussi, pelo apoio, e por ter sido fundamental neste projeto, propondo esse tema, permitindo que eu me aventurasse nesse novo aprendizado;

Aos meus amigos e colegas dos laboratórios: SINTEL, LaPSEE, LPC, que sempre me deram suporte e apoio no decorrer do mestrado;

Aos professores da FEIS-UNESP, que colaboraram com minha formação

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, pelo apoio financeiro e pela oportunidade;

E a todos que direta ou indiretamente fizeram parte da minha formação, o meu muito obrigada.

À minha mãe, Márcia Célia

RESUMO

A previsão de cargas elétricas vem se tornando uma atividade fundamental para o funcionamento e operação dos sistemas elétricos de potência, visando fornecer energia elétrica aos consumidores de maneira segura, eficaz e com menor custo de geração. O modelo proposto de sistema previsor de cargas elétricas, fundamentado em uma rede neural Perceptron, via algoritmo *backpropagation* estocástico, visa obter um algoritmo que proporcione a convergência da rede neural de maneira que ela consiga escapar dos mínimos locais. Portanto, propõe-se um sistema previsor de cargas elétricas de natureza computacional que tem como objetivo superar os problemas apresentados pelo algoritmo *backpropagation* convencional. Trata-se de um método inovador, visto que não foi encontrado na literatura artigos que fizessem a abordagem da aplicação de previsão de cargas elétricas através do algoritmo *backpropagation* estocástico proposto. O algoritmo *backpropagation* estocástico consiste na atualização de pesos de maneira randômica. Os resultados obtidos na comparação se baseiam no mesmo banco de dados históricos de uma companhia de setor elétrico brasileiro. O modelo proposto se mostra promissor, eficiente e uma válida ferramenta para previsão de cargas elétricas.

Palavras-chave: *Backpropagation*. Estocástico. Previsão de Cargas Elétricas.

ABSTRACT

The electric load's prediction has become a fundamental activity for the functioning and electrical power systems operation, aiming to provide energy to consumers safely, on effective way and to reduce the engender cost. The proposed model of the electric charge forecasting system, based on a Perceptron neural network, via stochastic backpropagation algorithm, aims to obtain an algorithm that provides the convergence of the neural network in such a way that it manages to escape the the local minimums. Therefore, it is proposed a predictor system of electrical charges of computational nature which aims to overcome the problems presented by the conventional backpropagation algorithm. This is an innovative method, as no article found in the literature that approached the application of forecasting electric charges through the proposed stochastic backpropagation algorithm. The stochastic backpropagation algorithm consists of updating in an affective way, and weights randomly. The results obtained in the comparison are based on the same historical database of a company in the Brazilian electric sector. The proposed model is promising, efficient and a valid tool for predicting electrical charges.

keyword: *Backpropagation*. Stochastic. Electric load prediction.

LISTA DE FIGURAS

Figura 1	Componentes de um neurônio biológico	17
Figura 2	Neurônio artificial	18
Figura 3	Funções de ativação	19
Figura 4	Treinamento de um neurônio situado na última camada	24
Figura 5	Treinamento de um neurônio situado nas demais camadas	25
Figura 6	Algoritmo gradiente descendente no espaço de pesos	25
Figura 7	Pontos de mínimo locais associados à função erro	27
Figura 8	Ilustração gráfica do fluxo da atualização dos pesos da RNA	30
Figura 9	Resultado da previsão de cargas para rede neural BP e BPesto., aplicação 1	35
Figura 10	Resultado da previsão de cargas para rede neural BP e BPesto., aplicação 2	35

LISTA DE TABELAS

Tabela 1	Períodos de treinamento utilizados	33
Tabela 2	Especificação da rede neural referente à aplicação 1	34
Tabela 3	Especificação da rede neural referente à aplicação 2	34
Tabela 4	Resultados comparativos para aplicação 1	36
Tabela 5	Resultados comparativos para aplicação 2	37

LISTA DE ABREVIACOES E SIGLAS

MAPE	Erro Porcentual Absoluto Mdio
RNAs	Redes Neurais Artificiais
RH	Rede Hopfield

LISTA DE SÍMBOLOS

X	Vetor contendo as entradas da rede neural
W	Vetor contendo os pesos dos neurônios
ε^2	erro quadrático da rede neural
ε_i	erro instantâneo de cada neurônio alocado na última camada
d_i	saída desejada do i -ésimo elemento da última camada da rede
y_i	saída do i -ésimo elemento da última camada da rede
ns	número de neurônios da última camada da rede
V_i	vetor contendo os pesos do neurônio i $[w_{0i}, w_{1i}, w_{2i}, \dots, w_{ni}]^T$
$\Delta_i(h)$	gradiente do erro quadrático com relação aos pesos do neurônio i avaliado em h
γ	parâmetro de controle de estabilidade ou taxa de crescimento
h	índice de iteração
λ	constante que determina a inclinação da curva y_i
$smg'(s_i)$	derivada parcial de y_i com relação a s_i
V_{ij}	peso correspondente à interligação entre o i -ésimo e j -ésimo neurônio
η	constante momento
σ_j	derivada da função de ativação sigmóide
$R(j)$	conjunto dos índices dos elementos que se encontram na fileira seguinte à do elemento j e que estão interligados a eles
$Q(w)$	função erro associada a uma rede com pesos de conexão w
m	dimensão do vetor X
$L(h-p)$	valor da carga p horas anterior à hora corrente h
$L(h+1)$	valor da carga elétrica à hora posterior a hora corrente h
t	vetor de tempo referente aos dados históricos
$L(h)$	valor da carga real referente a hora h
$LE(h)$	valor da carga estimada pela rede neural referente à hora h
N	número total de horas
t	vetor de tempo referente aos dados históricos

SUMÁRIO

1	INTRODUÇÃO	12
1.1	ORGANIZAÇÃO DO TEXTO	13
2	PREVISÃO DE CARGAS	14
2.1	CARGAS ELÉTRICAS	14
2.1.1	CLASSIFICAÇÕES	14
2.2	METODOLOGIA PARA PREVISÃO DE CARGA	16
3	REDES NEURAIS ARTIFICIAIS	17
3.1	MODELO DO NEURÔNIO BIOLÓGICO	17
3.2	MODELO NEURAL ARTIFICIAL	18
3.3	ESTRUTURA DA REDE	20
3.4	TREINAMENTO DA REDE	20
3.4.1	ALGORITMO <i>BACKPROPAGATION</i>	21
3.4.2	ALGORITMO <i>BACKPROPAGATION</i> COM MOMENTO	23
3.4.3	PROBLEMAS GERADOS PELO ALGORITMO <i>BACKPROPAGATION</i>	26
4	REDES NEURAIS VIA <i>BACKPROPAGATION</i> ESTOCÁSTICO	27
4.1	<i>BACKPROPAGATION</i> ESTOCÁSTICO	27
4.1.1	GRADIENTE DESCENDENTE ESTOCÁSTICO	28
4.1.2	ATUALIZAÇÃO ESTOCÁSTICA DOS PESOS	29
4.2	PREVISOR DE CARGAS ELÉTRICAS COM ALGORITMO <i>BACKPROPAGATION</i> ESTOCÁSTICO	29
5	APLICAÇÕES E RESULTADOS	32
5.1	SISTEMA PREVISOR DE CARGAS ELÉTRICAS	32
6	CONCLUSÃO E SUGESTÕES PARA TRABALHOS FUTUROS	38
6.1	CONCLUSÃO	38
6.2	SUGESTÕES PARA TRABALHOS FUTUROS	38
	REFERÊNCIAS	40
	APÊNDICE A - BANCO DE DADOS	42
	APÊNDICE B - BANCO DE DADOS	45

1 INTRODUÇÃO

A previsão de cargas elétricas é um requisito fundamental para o setor energético, uma vez que baseada nos seus resultados, decisões importantes são tomadas. Tem-se que a carga elétrica é essencial para uma grande variedade de estudos tais como: planejamento da expansão, fluxo de potência, estabilidade transitória, análise, controle de Segurança do Sistema de Energia Elétrica (O'DONOVAN, 1983). Diversos métodos relacionados à previsão de cargas elétricas se encontram na literatura, muitos por métodos estatísticos como: alisamento exponencial, técnica de regressão linear, filtro de Kalan, ARIMA de Box e Jenkins (TANG et al., 1991).

Fatores externos ao sistema e a não linearidade, podem influenciar na modelagem da carga, tornando difícil o modelamento como: condições meteorológicas (variações de temperatura, nebulosidade, velocidade do vento, estações do ano), hábito de consumo, dias da semana, e dias atípicos (feriados, jogos da copa do mundo, finais de novela, etc.), também denominadas de variáveis exógenas. Tais fatores servem como entrada no algoritmo de previsão escolhido, todos os métodos, os quais apresentados, têm conseguido executar a previsão de carga (GUIRELLI, 2006).

Há mais de vinte anos, pesquisadores estudam previsão de cargas utilizando as técnicas de inteligência artificial, método que tem como vantagem uma melhor resposta a não linearidades complexas, e são capazes de processar grandes quantidades de dados e cargas, além de não dependerem de complexos modelos matemáticos. Entre essas técnicas tem-se a lógica nebulosa (fuzzy), redes neurais, sistemas especialistas, etc. As Redes Neurais Artificiais (RNA's) têm se apresentado como um dos métodos mais eficientes para a obtenção da previsão de cargas elétricas.

Redes Neurais Artificiais são modelos computacionais inspirados no sistema nervoso de seres vivos, possuindo capacidade de aquisição e manutenção do conhecimento, baseado em informações. A primeira publicação relacionada à neurocomputação surgiu em 1943, através do artigo elaborado por McCulloch e Pitts. Os autores realizaram o primeiro modelamento matemático inspirando no neurônio biológico, sucedendo a primeira concepção de neurônio artificial. Diversos pesquisadores continuaram o trabalho de desenvolvimento através desse modelo, porém com resultados poucos significativos, passando por um período em que pouquíssimas pesquisas eram desenvolvidas. Somente após os anos 70, com a proposição por Hopfield (1982) (WASSERMAN, 1993) de redes recorrentes baseadas em funções de energia, fez com que as áreas de redes neurais artificiais retomassem o destaque. A retomada definitiva das pesquisas se deve a diversos fatores, tais como o desenvolvimento de computadores com maior capacidade

de armazenamento, criação de algoritmos de otimização, destacando o algoritmo denominado *backpropagation* (WERBOS, 1994), esse método foi desenvolvido independentemente por pesquisadores em três ocasiões: 1974, 1982 e 1986 .

O algoritmo *backpropagation*, denominado de "propagação reversa", trata-se de um treinamento supervisionado, o qual considera o conjunto de padrões de entrada, que fornecem as saídas desejadas através de ajuste de pesos da rede neural. Esse algoritmo é considerado um dos melhores em relação à precisão, mas com algumas limitações como velocidade e qualidade de convergência, e a sua lentidão é atribuída pela superfície da função erro, enquanto a qualidade da convergência é dependente da presença de vários mínimos locais nessa mesma superfície. Esse problema se torna mais evidente a medida que a complexidade e tamanho da rede aumenta.

Este trabalho tem como objetivo desenvolver uma metodologia para previsão de cargas elétricas. Neste sentido, utiliza-se como ferramenta para realizar essa previsão as redes neurais, via emprego do algoritmo *backpropagation*, no qual foi introduzido o método estocástico, visando a melhoria do treinamento, melhorando a sua convergência e a generalização, com objetivo de escapar dos mínimos locais. Consequentemente tornando o sistema previsor, mais eficiente e competitivo em comparação aos métodos *backpropagation* convencionais.

1.1 ORGANIZAÇÃO DO TEXTO

Este texto está fragmentado em cinco capítulos, da seguinte forma: No capítulo 2 aborda-se a teoria da previsão de cargas elétricas. No capítulo 3 são descritas as redes neurais, especialmente no estudo ao algoritmo *backpropagation* convencional e o *backpropagation* com o termo momento. No capítulo 4 versa-se sobre o desenvolvimento do sistema previsor de cargas elétricas, via emprego do algoritmo *backpropagation*, no qual foi introduzido o método estocástico. No capítulo 5 é apresentada uma aplicação do algoritmo *backpropagation* estocástico no campo de previsão de cargas elétricas. E, por último, no capítulo 6 são denotadas as conclusões e as sugestões para trabalhos futuros.

2 PREVISÃO DE CARGAS

Neste capítulo, serão tratados assuntos relevantes para obtenção do sistema previsor de cargas elétricas, nos quais, as suas principais definições e seus métodos utilizados. É essencial entender o comportamento da carga e os fatores que influenciam na previsão de cargas.

2.1 CARGAS ELÉTRICAS

As cargas elétricas são compostas considerando-se o consumo de energia elétrica de vários aparelhos e dispositivos elétricos, que juntos apresentam tendência que podem ser previstas estatisticamente. Entretanto, essas tendências são influenciadas por fatores que terão efeito sobre a curva de carga. Esses fatores como condições metodológicas, sazonalidade como dia da semana e estações do ano, e também alguns fatores aleatórios que trazem problemas para a previsão de cargas, pois afetam a carga de maneira inesperada, exemplo são os feriados, eventos tais como jogos da copa do mundo, finais de novela, etc (GUIRELLI, 2006). O comportamento do consumo em um sistema elétrico é dependente de diversos hábitos dos consumidores.

A metodologia proposta na pesquisa, do sistema previsor de cargas elétricas, precisa estabelecer previsões com certo grau de precisão, para tal, como os outros métodos de previsão, necessitam de duas condições fundamentais (TANG et al., 1991):

- Informações sobre o passado quantificadas em forma de dados;
- Assumir que o comportamento ocorrido no passado de certa forma irá se repetir no futuro.

2.1.1 CLASSIFICAÇÕES

Os métodos relacionados à previsão de cargas elétricas se encontram na literatura, muitos por métodos matemáticos como: alisamento exponencial, técnica de regressão linear, filtro de Kalan, ARIMA de Box e Jenkins (TANG et al., 1991). Esses métodos podem ser classificados em três classes (O'DONOVAN, 1983):

1. Métodos Intuitivos: são métodos que não empregam modelos matemáticos para descrever o comportamento da carga;
2. Métodos Autônomos: baseados em extrapolação de observações passadas das cargas, essa técnica constitui uma análise da evolução da carga no tempo, de acordo com deter-

minados padrões de comportamento, e podem ser classificadas em horizontal, sazonal e tendenciosa;

3. Métodos Causais: a carga exhibe uma relação de causa e efeito, que irão descrever o seu comportamento. Faz o uso de variáveis como: índices sócioeconômicos, crescimento populacional, etc.

A escolha do modelo adequado é importante para que possa ter um comportamento de carga e sua evolução, e por meio dele pode-se dividir a série temporal em duas classes (O'DONOVAN, 1983):

1. Estacionária: se os dados da carga possuírem flutuações em torno de uma média constante no tempo;
2. Não Estacionária: se a série temporal apresentar o padrão tendencioso e/ou sazonal.

De acordo com Othman et al. (2009) a carga elétrica pode ser prevista em vários períodos, sendo eles:

- Longo prazo: realizada em um longo período que pode variar entre 10 a 20 anos, e esse tipo de previsão é realizada em operações de planejamento de sistema de potência;
- Médio prazo: engloba um período de poucas semanas ou anual, é utilizada para planejamento de produção a médio prazo;
- Curto prazo: é realizada no intervalo de tempo de poucas horas, um dia ou uma semana, ocorrendo no planejamento e operações econômicas e de segurança diárias dos sistemas de potência;
- Curtíssimo prazo: abrange um período muito curto, entre segundos e minutos, é empregada no planejamento de operações "on-line" e controle.

Segundo O'Donovan (1983), são encontradas variáveis e fatores que influenciam no comportamento da carga elétrica, dentre eles tem-se:

- Fatores climáticos: umidade do ar, nível de luminosidade, velocidade do vento e as temperaturas;
- Fatores cíclicos ou temporais: são os fatores que se repetem como: dias, semanas, meses, ano, feriados;
- Fatores atípicos ou aleatórios: são problemáticos para a previsão, pois afetam a carga de maneira totalmente fora dos padrões. Sendo eles: finais de novela, jogos da copa do mundo, etc.

2.2 METODOLOGIA PARA PREVISÃO DE CARGA

Os métodos para previsão de cargas que são apresentados na literatura especializada baseiam-se em procedimentos estatísticos e estocásticos e necessitam de uma modelagem prévia de carga para posteriormente serem aplicados. Dessa maneira as novas metodologias como: redes neurais artificiais, lógica nebulosa (fuzzy), sistemas híbridos, entre outros (HAYKIN, 2004), vem trazendo significantes resultados. Neste trabalho, será abordada a previsão de cargas elétricas empregando as redes neurais artificiais, com previsão de curto prazo (previsão diárias), para prever 24 horas subsequentes. O comportamento do sistema, é aprendido por meio de um processo de treinamento, via algoritmo *backpropagation* estocástico.

3 REDES NEURAIS ARTIFICIAIS


Neste capítulo, serão abordados os conceitos sobre as redes neurais artificiais, essas redes apresentam performances boas ou melhores que as demais técnicas disponíveis para previsão de cargas elétricas estabelecidas na literatura. Recentemente, estudos baseados em redes neurais vem sendo apresentados, e tem como vantagem uma melhor resposta a não linearidade tornando-se uma ferramenta principal para essa previsão por duas razões: o fato das redes neurais poderem aproximar numericamente qualquer função desejada e outro por não dependerem dos demais modelos.

Deve-se destacar que, a dificuldade dos métodos de previsão de cargas convencionais é a necessidade de desenvolver a modelagem prévia da carga para aplicação posterior. Dessa forma, o propósito desta pesquisa é desenvolver um sistema predictor de cargas elétricas, fundamentado em uma rede neural. Consequentemente serão denotados: a estrutura da rede neural *feedforward*, suas formas de treinamento dando ênfase no algoritmo *backpropagation* convencional e no *backpropagation* com momento.

3.1 MODELO DO NEURÔNIO BIOLÓGICO

As Redes Neurais Artificiais são técnicas computacionais baseadas em neurônios biológicos, e do próprio cérebro humano (GUIRELLI, 2006). O funcionamento e o comportamento humano no raciocínio, depende dos neurônios, sendo mostrado na figura 1 vários componentes desse.

Figura 1 - Componentes de um neurônio biológico




Fonte: Filho e Carvalho (1997)

Os neurônios no cérebro humano recebem informações, impulsos nervosos, via terminais de entrada chamados: *dendritos* e remetem atividades elétricas através dos terminais de saídas o *axônio* (FILHO; CARVALHO, 1997). Os neurônios são interligados por meio das *sinapses*, que funcionam como válvulas, sendo capazes de controlar a transmissão de impulsos, e por meio dessa capacidade de conectividade é atribuída a inteligência.

3.2 MODELO NEURAL ARTIFICIAL

Os modelos de neurônios artificiais utilizados nas redes neurais são não-lineares, fornecem saídas contínuas, coletam os sinais existentes em suas entradas e agregam de acordo com a função operacional, produzindo uma resposta, levando em consideração a função de ativação (SILVA et al., 2010).

Figura 2 - Neurônio artificial



Fonte:Silva et al. (2010)

O neurônio artificial, mostrado na figura 2, possui um processo de treinamento da seguinte forma (SILVA et al., 2010):

- 1 O conjunto de entrada ($X_1, X_2, \dots, X_n$), são sinais advindos do meio externo, esses são usualmente normalizados, visando incrementar a eficiência computacional dos algoritmos de aprendizagem;
- 2 Os pesos sinápticos ($W_1, W_2, \dots, W_n$), são valores que servirão para ponderar cada uma das variáveis de entrada;
- 3 O combinador linear (Σ) agrega todos os sinais de entrada que foram ponderados pelos respectivos pesos sinápticos, a fim de produzir um valor de potencial de ativação;

- 4 O limiar de ativação, conhecido também como "*bias*" é uma variável específica, que após o resultado produzido pelo combinador linear for maior que o valor do "*bias*" o neurônio é ativado em direção a saída;


A saída do i-ésimo neurônio é, então, dada por (WIDROW; LEHR, 1990):

$$S_i = \sum_j^n W_{i,j} X_j \quad (1)$$

- 5 A função de ativação(g), tem como objetivo limitar a saída do neurônio dentro de um intervalo de valores. Essa função pode ser dividida em dois grupos: funções diferenciáveis e funções totalmente diferenciáveis.

A função de ativação, tem como objetivo ativar os neurônios artificiais. Sendo as mais conhecidas e utilizadas, apresentadas na figura 3.

Figura 3 - Funções de ativação



Fonte:Elaboração da própria autora

De acordo com os autores Fine (2006), Simpson (1989), Widrow e Lehr (1990), as funções são denominadas da seguinte forma: sigmoidais podem ser empregadas para sistemas contínuos ou binários, tipo relé são apropriadas para sistemas binários e a função sigmoidal (*threshold*) é a mais utilizada, por ser contínua, e mostrar uma derivada simples e ser a única a ter uma similaridade com o neurônio biológico.

3.3 ESTRUTURA DA REDE

As estruturas das redes neurais artificiais foram desenvolvidas com base no modelo de um neurônio e do próprio cérebro humano. Esses modelos foram inspirados com fundamento da análise da geração e propagação de impulsos elétricos pela membrana celular dos neurônios (HODGKIN; HUXLEY, 1952)

As redes neurais artificiais podem ser classificadas em dois tipos quanto a sua estrutura:

- Redes Recorrentes (ou *feedback*) - contém laços de realimentação, produzindo saídas levando em consideração os valores das saídas anteriores e elas possuem memória ao longo prazo nos neurônios internos. Nesta classe de redes neurais, encontra-se a de Hopfield (KROSE; SMAGT, 1996).
- Redes Não Recorrentes (ou *feedforward*) - não abrange laços de realimentação, cada camada de neurônio recebe sinais somente das camadas anteriores. Elas não possuem memórias, e sua saída é determinada em função dos dados de entrada e dos valores dos pesos (HAYKIN, 2004).

3.4 TREINAMENTO DA REDE

Um dos ressaltos das redes neurais artificiais está na capacidade de aprender. Para tanto deve ser treinada, através de um processo iterativo de ajustes aplicados aos seus pesos, esse processo de treinamento consiste da aplicação de passos ordenados, o que é denominado de algoritmo de aprendizagem. Quanto ao tipo de aprendizado, pode ser classificado em dois grupos, sendo eles:

- Treinamento Supervisionado - A rede é treinada através da combinação dos padrões de entrada e saída, fornecidos pares de treinamento, sendo eles, o vetor de entrada é adicionado à rede e a saída correspondente é calculada e comparada com a saída desejada. Os pesos são alternados por um algoritmo na tentativa de minimizar o erro. Esses algoritmos de treinamento, são responsáveis pela aprendizagem da rede, contendo informações de erros e desempenho (HAYKIN, 2004).
- Treinamento Não Supervisionado - A rede é treinada usando apenas o vetor de entrada, para o ajuste dos pesos. Portanto é um procedimento de treinamento auto-organizável, os dados são apresentados e descobre suas propriedades coletivas, assim dizendo, extrai propriedades estatísticas do conjunto de treinamento e agrupa vetores similares em classes (HAYKIN, 2004).

3.4.1 ALGORITMO BACKPROPAGATION

Neste trabalho será abordado o algoritmo de *backpropagation*, denominada de "propagação reversa", é uma técnica que adapta os pesos da rede em direção oposta à direção do gradiente descendente, tendo como objetivo minimizar o erro quadrático da rede neural. A soma do erro quadrático instantâneo de cada neurônio da última camada (saída da rede), é dada pela equação (2) (WIDROW; LEHR, 1990):

$$\epsilon^2 = \sum_{i=1}^{ns} \epsilon_i^2 \quad (2)$$

sendo:

$$\epsilon = d_i - y_i$$

d_i : saída desejada do i-ésimo elemento da última camada da rede;

y_i : saída do i-ésimo elemento da última camada da rede;

ns : número de neurônios da última camada da rede.

Tendo em consideração o neurônio de índice i da rede e o método gradiente descendente, o ajuste do peso pode ser obtido pela equação(3) (SIMPSON, 1989)(WIDROW; LEHR, 1990) :

$$V_i(h+1) = V_i(h) - \theta_i(h) \quad (3)$$

sendo:

$$\theta_i(h) = \gamma[\Delta_i(h)]$$

γ : parâmetro de controle da estabilidade ou taxa de treinamento;

h : representa o índice de iteração;

$\Delta_i(h)$: gradiente do erro quadrático com relação aos pesos do neurônio i avaliado em h ;

V_i : vetor contendo os pesos dos neurônios i

$$= [w_{0i}, w_{1i}, w_{2i}, \dots, w_{ni}]^T.$$

Na equação (3) é adotada na direção contrária do gradiente do erro quadrático, visando minimizar a função objetivo do erro quadrático. E pode ser expresso por (KROSE; SMAGT, 1996):

$$\Delta_i(h) = \frac{\partial \epsilon_1^2}{\partial V_i(h)} = 2\epsilon_i \frac{\partial \epsilon_1^2}{\partial V_i(h)} \quad (4)$$

A função de ativação adotada é a função sigmóide definida por (SIMPSON, 1989)(FINE, 2006)(WIDROW; LEHR, 1990):

$$y_i = \frac{1 - \exp^{-\lambda s_i}}{1 + \exp^{-\lambda s_i}} \quad (5)$$

ou

$$y_i = \frac{1}{1 + \exp^{-\lambda s_i}} \quad (6)$$

sendo:

λ : constante real que determina a inclinação da curva y_i

Diferenciando a equação (2) com relação ao vetor V_i :

$$\frac{\partial \varepsilon_i}{\partial V_i} = - \frac{\partial y_i}{\partial V_i(h)} = \frac{\partial y_i}{\partial s_i} \frac{\partial s_i}{\partial V_i} \quad (7)$$

Dessa equação (7), obtém-se:

$$\frac{\partial \varepsilon_i}{\partial V_i} = -sgm'(s_i) \frac{\partial s_i}{\partial V_i(h)} \quad (8)$$

Sendo:

$-sgm'(s_i) = \frac{\partial y_i}{\partial s_i}$, derivada parcial de y_i com relação a s_i .

Observa-se:

$$\frac{\partial s_i}{\partial V_i} = X_i \quad (9)$$

sendo:

X_i Δ i-ésimo vetor padrão.

$= [x_0i, x_1i, w_2i, \dots, x_ni]^T$.

Substituindo a equação (9) na equação (8), tem-se:

$$\frac{\partial \varepsilon_i}{\partial V_i} = -sgm'(s_i)X_i \quad (10)$$

Substituindo a equação (10) na equação (4), resulta em:

$$\Delta_i(h) = -2\varepsilon_i \text{sgm}'(s_i)X_i \quad (11)$$

Empregando o gradiente estimado no método do gradiente descendente, adquire-se (WIDROW; LEHR, 1990):

$$V_i(h+1) = V_i(h) + 2\gamma \varepsilon_i \text{sgm}'(s_i)X_i \quad (12)$$

A derivada parcial da função sigmoide, dada pela equação (5), pode ser expressa por:

$$\frac{\partial y_i}{\partial s_i} = \frac{2\lambda \exp^{-\lambda s_i}}{(1 + \exp^{-\lambda s_i})^2} = \frac{1}{2}\lambda \frac{(1 + \exp^{-\lambda s_i})^2}{(1 + \exp^{-\lambda s_i})^2} - \frac{(1 - \exp^{-\lambda s_i})^2}{(1 + \exp^{-\lambda s_i})^2} = 0.5\lambda(1 - y_i^2) \quad (13)$$

A função sigmoide, dada pela equação (6), possui a sua derivada expressa como:

$$\frac{\partial y_i}{\partial s_i} = \frac{\partial}{\partial s_i} \frac{1}{1 + \exp^{-\lambda s_i}} = \lambda y_i(1 - y_i) \quad (14)$$

Os pesos da rede são iniciados randomicamente no intervalo (0,1) e o treinamento da rede neural via algoritmo *backpropagation* pode ser realizado de duas formas:

- *Procedimento 1*: Fundamenta-se em ajustar os pesos da rede, todas as camadas, fazendo-se com que haja convergência para cada padrão, até que se complete o conjunto de entrada. Esse processo deverá ser repetido até a total convergência da rede, cujo o erro quadrático seja inferior a uma tolerância preestabelecida para os padrões;
- *Procedimento 2*: Este procedimento é igual ao primeiro apresentado, porém se faz apenas uma iteração por padrão por vez.

3.4.2 ALGORITMO BACKPROPAGATION COM MOMENTO

O algoritmo *backpropagation* é considerado um referencial em termos de precisão, porém tem uma convergência bastante lenta. Diversas variações do método têm sido proposto na literatura, com o objetivo de tornar esse processo de convergência mais eficiente. Entre eles tem-se o método de inserção de termo de *momentum* (WIDROW; LEHR, 1990).

O método determinístico baseado no gradiente descendente, requer que uma imensidão de passos sejam tomados e seu processo de aprendizagem exige que a mudança nos pesos seja proporcional a $\partial \varepsilon_i / \partial V(i)$. Uma maneira de evitar as oscilações para γ grande, é aplicar uma variação no peso dependente da variação do peso passado acrescentado com termo momento.

Esse processo denomina-se *backpropagation* com momento (KROSE; SMAGT, 1996).

Dessa forma, a adaptação de pesos consiste em (WIDROW; LEHR, 1990):

$$V_{ij}(h+1) = V_{ij}(h) - \Delta V_{ij}(h) \quad (15)$$

sendo:

$$\Delta V_{ij}(h) = 2\gamma(1-\eta)\beta_i x_i + \eta \Delta V_{ij}(h-1) \quad (16)$$

V_{ij} : peso correspondente à interligação entre i-ésimo e j-ésimo neurônio;

γ : taxa de treinamento;

η : constante momento ($0 \leq \eta < 1$).


Na figura 4 o elemento j se encontra na última camada, obtendo:

$$\beta_j = \sigma_j \varepsilon_j \quad (17)$$

sendo:

σ_j = derivada da função de ativação sigmoide pelas equações (13) ou (14), com relação a s_j . E na figura 4 a função de ativação é dada pela equação (14).

Figura 4 - Treinamento de um neurônio situado na última camada



Fonte: (WIDROW; LEHR, 1990)


Já na Figura 5 o elemento j encontra-se nas demais camadas, tem-se:

$$\beta_i = \sigma_j \sum_{k \in R_j} W_{jk} \beta_k \quad (18)$$

sendo:

$R(j)$ = conjunto dos índices dos elementos que se encontram na fileira seguinte à do elemento j e que estão interligados a ele.


Figura 5 - Treinamento de um neurônio situado nas demais camadas



Fonte: (WIDROW; LEHR, 1990)

O termo momento utilizado no algoritmo *backpropagation* possibilita movimentos na mesma direção, ganhando assim velocidade e capacidade de escapar dos mínimos locais (KROSE; SMAGT, 1996). A figura 6 apresenta o significado desse método:

Figura 6 - Algoritmo gradiente descendente no espaço de pesos



Fonte: (KROSE; SMAGT, 1996)

Sendo:

a : taxa de treinamento pequena;

b : taxa de treinamento grande;

c : taxa de treinamento grande, mas com o termo momento já adicionado.

3.4.3 PROBLEMAS GERADOS PELO ALGORITMO *BACKPROPAGATION*

O algoritmo de aprendizagem *backpropagation*, no qual tem a técnica de adaptação dos seus pesos da rede baseado no método gradiente descendente de uma função de erro, possui algumas limitações na velocidade de convergência por conta dos mínimos locais na topologia da superfície de erro (SALVETTI et al., 1994). Por consequência, tem alguns problemas como: lentidão no processo de convergência e não convergência, podendo ser causados por:

- **Paralisia da rede:** No decorrer do treinamento da rede, os pesos podem ser ajustados assumindo valores muito altos, e isso provoca uma paralisia na rede. Quando uma entrada na camada intermediária ou de saída alcançar valores elevados, seja eles positivos ou negativos, em decorrência da função ativação sigmoideal, terá uma ativação próxima de zero ou um. Dessa maneira, os ajustes de peso estarão próximos a zero, e a rede pode entrar em paralisia (KROSE; SMAGT, 1996).
- **Mínimos locais:** O treinamento da rede será concluído quando houver convergência para um mínimo global. No entanto, por consequência do gradiente descendente, existem vários mínimos locais e acaba convergindo para esse mínimo local. Quanto mais complexa a rede neural, com mais camadas, vai haver um aumento da dimensão do espaço do erro (KROSE; SMAGT, 1996).

4 REDES NEURAIS VIA *BACKPROPAGATION* ESTOCÁSTICO


A metodologia proposta no trabalho é apresentada neste capítulo, sistema predictor de cargas elétricas a curto prazo, por meio das redes neurais artificiais, via algoritmo *backpropagation* estocástico, de modo que a atualização dos pesos na rede acontece de forma randômica, visando a melhor convergência da rede.

4.1 *BACKPROPAGATION* ESTOCÁSTICO

No algoritmo de aprendizagem *backpropagation* empregado para treinar redes neurais multicamadas, em virtude da superfície de erro produzida pela rede ser não linear, existe uma possibilidade em que no processo de aprendizado direcione a matriz de pesos da rede para um ponto mínimo local, em vista que o objetivo da convergência é direcionar para o mínimo global.

Algumas situações envolvendo os pontos mínimos locais são exemplificado na figura 7 que mostra algumas situações envolvendo os pontos mínimos locais. A propensão da convergência para um ponto mínimo local fica condicionada principalmente por causa da posição espacial em que a matriz W foi iniciada, considerando-se que o algoritmo *backpropagation* é baseado no método de gradiente descendente.

Figura 7 - Pontos de mínimo locais associados à função erro



Fonte: (SILVA et al., 2010)

Levando em consideração essas deficiências do *backpropagation* convencional, contendo alguns problemas que comprometem o seu desempenho, provocando lentidão no processo de convergência e não convergência, este trabalho tem como propósito tornar esse processo de convergência mais eficiente com algoritmo *backpropagation* estocástico.

Um processo estocástico é determinado como uma coleção de variáveis aleatórias $X(t)$, que representa o estado do sistema no parâmetro, geralmente o tempo t . Deste modo, esse processo é frequentemente utilizado para estudar a evolução de fenômenos, ou sistemas que são observados ao longo do sistema. Diversos algoritmo de aprendizado já são baseados no método estocástico que seleciona probabilisticamente suas ações de ajustes, levando-se em conta um conjunto finito de possíveis situações, as quais são passíveis de se gerar resultados satisfatório. Na literatura dissemina-se várias pesquisas focadas na utilização do método estocástico no algoritmo *backpropagation*, as quais vão ser apresentadas a seguir.

4.1.1 GRADIENTE DESCENDENTE ESTOCÁSTICO

Um dos métodos utilizado no algoritmo *backpropagation*, encontrado na literatura, é o do gradiente descendente, visando minimizar o erro quadrático da rede neural. Os pesquisadores Amari (1993) e Ernst (2014), propuseram uma nova abordagem deste método, denominado gradiente descendente estocástico, uma ideia que se iniciou nos anos 1960.

A regra de aprendizagem do gradiente descendente, é dada pela equação (19) (ERNST, 2014):

$$w := w - \eta \Delta Q(w) \quad (19)$$

sendo:

η : taxa de aprendizado;

$Q(w)$: função erro associada a uma rede com pesos de conexão w .

A descida de gradiente estocástica, elimina a expectativa da atualização total da rede e calcula o gradiente dos parâmetros usando apenas um ou alguns exemplos do treinamento, tomando o como base o conjunto de treinamento em pares (x, t) . A regra de aprendizagem de cada etapa se torna:

$$w := w - \eta \Delta Q(w; x, t) \quad (20)$$

O treinamento da rede é baseado em um conjunto de pares de dados (x, t) , sendo x entradas alimentadas da rede na camada entrada, e t as saídas esperadas. O algoritmo *backpropagation*

prossegue iterando sobre o conjunto de pares de observação (x, t) (ERNST, 2014). Reduzindo assim a variação na atualização de parâmetros, podendo levar a uma convergência mais estável.

No método convencional de gradiente descendente, calcula-se o gradiente de erro com base no conjunto de treinamento completo, quanto maior esse conjunto mais lento o algoritmo atualiza o peso e mais tempo pode demorar até convergir para o mínimo global. Já no novo método de gradiente descendente estocástico, não acumula a atualização de pesos, o termo estocástico vem do fato de que o gradiente baseado em uma única amostra de treinamento é uma aproximação estocástica do gradiente do erro verdadeiro, por causa da sua natureza estocástica, o caminho para o erro global mínimo não é direto.

4.1.2 ATUALIZAÇÃO ESTOCÁSTICA DOS PESOS

Em 1994, o pesquisador Salvetti et al. (1994), propôs um método de atualização estocástica do peso no algoritmo *backpropagation* em redes neurais *feedforward*, a fim de melhorar a probabilidade de convergência e a sua velocidade (evitando ficar preso nos mínimos locais). No campo estocástico de atualização de peso, número de constante de peso é selecionado e atualizado aleatoriamente, nem todos têm a mesma influência no erro da rede, contrastando com o clássico de ordenada, no qual todos os pesos são atualizados (KOŠČAK et al., 2010).

Segundo Salvetti et al. (1994), os fatores aleatórios, quando projetados para operar o *backpropagation* podem melhorar a qualidade e convergência, sendo assim os pesos são selecionados randomicamente para serem atualizados.

4.2 PREVISOR DE CARGAS ELÉTRICAS COM ALGORITMO BACKPROPAGATION ESTOCÁSTICO


O proposto previsor de cargas elétricas a curto prazo, por meio das redes neurais artificiais, via algoritmo *backpropagation* estocástico, distingue das pesquisas apresentadas nos artigos citados, em vista que não foi encontrado na literatura estudos com objetivo de prever cargas.

Partindo do princípio estatístico que não é necessário a atualização de todos os pesos da rede e tendo consideração que nem todos tem a mesma interferência no erro, pode-se, então, atualizar e escolher os pesos randomicamente como é mostrado na figura 8, sem nenhuma penalidade na complexidade da implementação e com resultados positivos, e melhor convergência.

A ilustração gráfica do fluxo da atualização de pesos em uma rede neural é apresentada na figura 8, demonstrado-se como é executada a escolha aleatória dos pesos da rede em uma determinada camada. Deve-se destacar que o processo dessa atualização têm os seguintes passos, primeiramente a retropropagação do erro, que já é utilizado no método convencional do *backpropagation*. Posteriormente é selecionado de maneira randômica a posição dos pesos da

matriz (WA) a serem atualizados, gerando uma nova matriz peso (W), fazendo assim a cada iteração até a sua convergência.

Figura 8 - Ilustração gráfica do fluxo da atualização dos pesos da RNA



Fonte: Elaboração da própria autora

Com esse detalhe apresentado na figura 8, diferencia-se do algoritmo *backpropagation* convencional que trabalha de maneira ordenada e todos são atualizados. Esse processo convencional de atualização pode ocasionar lentidão e até a não convergência da rede, dependendo da sua complexidade.

O processo iterativo estocástico de ajuste dos pesos, consiste em um treinamento de passos não ordenados, denominado de algoritmo *backpropagation* estocástico. Em uma rede supervisionada, na qual o seu treinamento é realizado por meio de combinações dos padrões de entrada e saída. O vetor de entrada é extraído do banco de dados de uma companhia energética, e sua saída correspondente é calculada e compara com a saída desejada. Os pesos são gerados de forma randômica, consequentemente as atualizações dos mesmos também serão, na tentativa de um melhor resultado.

O método estocástico apresentado no trabalho não tem uma porcentagem estipulada ou

determinada da atualização dos pesos, tendo em vista que cada rede neural têm seus parâmetros a serem analisados e de forma estatística, pode-se encontrar o melhor valor.

A programação do previsor de cargas elétricas, foi elaborada em linguagem FORTRAN e processada em um microcomputador, com processador Corei7-7ª Geração, memória 8GB, disco rígido 1TB, com modelo inspirion 15/5000 Dell e também utilizado o software Matlab para a elaboração de gráficos. Tem-se que o tempo de processamento gerado pela programação refere-se somente à execução do algoritmo, excluindo as operações de leitura/saída dados.

5 APLICAÇÕES E RESULTADOS

Neste capítulo, serão apresentados os principais resultados usando o modelo proposto, via algoritmo *backpropagation* estocástico, visando resolver os problemas da previsão de carga a curto prazo (24 horas subsequentes). Dessa maneira, será utilizado o método de comparação entre: algoritmo *backpropagation* convencional e o *backpropagation* estocástico, com propósito de testar a eficiência da metodologia estocástica. Para a fase de treinamento da rede neural, serão empregados os dados históricos de uma companhia do setor elétrico brasileiro.

5.1 SISTEMA PREVISOR DE CARGAS ELÉTRICAS

Na elaboração do trabalho foram analisadas características importantes para o previsor de carga elétrica. Com o problema a ser apresentado, a função não-linear adotada é a função de ativação sigmóide definida pela equação (6), sendo que suas saídas terão valores compreendidos entre 0 e +1.

A previsão de carga a curto prazo, é realizada da seguinte forma: os dados históricos são empregados entre intervalos preestabelecidos, referindo-se ao dia da semana (domingo a segunda) e a hora do dia codificados em binário. A entrada da rede, para uma determinada hora(h) é definida como sendo valores da carga, retirado dos dados históricos em quatro instantes (o valor corrente, uma, duas e três horas anteriores) e os dados referentes ao mês. Já a saída da rede equivale o valor da carga referente à hora ($h + 1$) (LOPES, 2005)

A estratégia até preencher todo o intervalo de tempo da série temporal, denota-se o conjunto que constitui a entrada/saída da rede. Este esquema pode ser modificado tendo em vista melhores resultados. Desse modo, o vetor de entrada e saída, são definidos da seguinte forma (LOPES et al., 2000):

$$X(h) = [t^T L(h-3)L(h-2)L(h-1)L(h)]^T, X \in R^m \quad (21)$$

$$Y(h) = [L(h+1)], Y \in R^1 \quad (22)$$

sendo:

m : dimensão do vetor X ;

$L(h-p)$: valor da carga p horas anterior à hora corrente h ;

$L(h+1)$: valor da carga elétrica à hora posterior a hora corrente h ;

t : vetor de tempo referente aos dados históricos.

O previsor de cargas elétricas proposto neste trabalho, é fundamentado em uma rede neural Perceptron, via algoritmo *backpropagation* estocástico. Tem-se uma técnica de atualização de pesos da rede baseados no método estocástico, no qual nem todos os pesos são atualizados de maneira ordenada, no caso apresentado foram atualizados 67 por cento dos pesos de cada iteração, de forma aleatória.

Os dados empregados neste trabalho, são os dados históricos de uma companhia do setor elétrico brasileiro, do qual contêm valores das cargas horárias do ano de 1998, estando eles relacionados os fatores atípicos. Considerados duas aplicações, com os bancos de dados, respectivamente, dados históricos 21 (Apêndice A), 42 (Apêndice B). De maneira geral, utiliza-se vetores padrão com dimensão de tamanho 12 (dados dias da semana e horas codificadas na representação binária, mais carga horária e valores considerando-se três horas anteriores), com 3 camadas. Os períodos adotados são descritos na Tabela 1

Tabela 1 - Períodos de treinamento utilizados

Aplicação	Período	Número de Vetores	Dia Previsto
1	21 dias - 08/07 a 28/07	504	29/07
2	42 dias - 17/06 a 28/07	1008	29/07

Fonte: Elaboração da própria autora.

Importante ressaltar que a representação binária na programação é dada por (-1,+1), produzindo uma convergência mais rápida comparada com a convencional (0,+1), visto que o componente "0" de entrada na rede não proporciona modificação nos pesos.

A análise dos resultados das duas redes neurais, sendo elas *backpropagation* convencional e a *backpropagation* estocástico, redes 1 e 2, respectivamente. Elaboradas com os mesmos parâmetros da rede (número de camadas, número de neurônios por camadas, tolerância, taxa de treinamento, momento e inclinação da função sigmóide), diferenciadas apenas a aleatoriedade estocástica, que é feita de maneira randômica dos pesos a serem atualizados no decorrer da rede.

Tabela 2 - Especificação da rede neural referente à aplicação 1

Aplicação	Valor	
	BP Convencional Rede Neural 1	BP Estocástico Rede Neural 2
Número de vetores	504	504
Número de camadas	3	3
Número de neurônios por camada	12-30-1	12-30-1
Tolerância	0,05	0,05
Taxa de Treinamento γ^*	4,5	4,5
Termo momento η	0,9	0,9
Inclinação da função sigmoide λ	0,3	0,3
Taxa de porcentagem atualização dos pesos	100%	67%

Fonte: Elaboração da própria autora.

Tabela 3 - Especificação da rede neural referente à aplicação 2


Aplicação	Valor	
	BP Convencional Rede Neural 1	BP Estocástico Rede Neural 2
Número de vetores	1008	1008
Número de camadas	3	3
Número de neurônios por camada	12-30-1	12-30-1
Tolerância	0,05	0,05
Taxa de Treinamento γ^*	5,5	5,5
Termo momento η	0,9	0,9
Inclinação da função sigmoide λ	0,3	0,3
Taxa de porcentagem atualização dos pesos	100%	67%

Fonte: Elaboração da própria autora.

Nas tabelas 2 e 3 são apresentados os principais parâmetros referentes as redes neurais utilizadas e seu treinamento: *backpropagation* convencional (BP) e o *backpropagation* estocástico


(BPesto), respectivamente. Nas figuras 9 e 10, são apresentados os resultados da previsão de carga desses treinamentos, referente ao dia 29 de julho de 1998:

Figura 9 - Resultado da previsão de cargas para rede neural BP e BPesto., aplicação 1



Fonte: Elaboração da própria autora.

Figura 10 - Resultado da previsão de cargas para rede neural BP e BPesto., aplicação 2



Fonte: Elaboração da própria autora.

É importante ressaltar que a taxa de porcentagem de atualização de pesos operadas na aplicação 1 e 2 no treinamento *backpropagation* estocástico, teve um processo computacional por depuração até que chegasse em um melhor resultado. Nota-se que as diferenças das aplicações 1 e 2 são os parâmetros.

Para uma análise de precisão, define-se o erro porcentual absoluto médio, apresentado na equação *MAPE* (23) e o erro máximo da previsão diária, mostrado na equação (24), comparando os valores reais da carga com os valores estimados através das redes neurais da seguinte maneira:

$$MAPE = \frac{1}{N} \left\{ \sum_{i=1}^N \frac{(|L(h) - LE(h)|)}{L(h)} \right\} \times 100 \quad (23)$$

$$Erro_maximo(\%) = \max \left\{ \frac{(|L(h) - LE(h)|)}{L(h)} \right\} \times 100 \quad (24)$$

sendo:

$L(h)$: valor da carga real referente a hora h ;

$LE(h)$: valor da carga estimada pela rede neural referente à hora h ;

N : número total de horas.

Tabela 4 - Resultados comparativos para aplicação 1

Item	BP Convencional	BP Estocástico
	Rede Neural 1	Rede Neural 2
Número ciclos	162	1068
Tempo de processamento (s)	1,76	95
Erro médio(%)	3,75	3,22
Erro máximo(%)	9,8	6,73

Fonte: Elaboração da própria autora.

Tabela 5 - Resultados comparativos para aplicação 2

Item	BP Convencional	BP Estocástico
	Rede Neural 1	Rede Neural 2
Número ciclos	171	1768
Tempo de processamento (s)	2,11	240
Erro médio(%)	2,16	2
Erro máximo(%)	8,1	5,35

Fonte: Elaboração da própria autora.

As tabelas 4 e 5 apresentam os resultados comparativos em termos de número de ciclos, tempo de processamento, erro médio e o erro máximo. Observa-se que os erros gerados pelo método proposto no trabalho, o do *backpropagation* estocástico é menor comparado aos resultados do *backpropagation* convencional, dessa maneira torna-se mais eficiente para um sistema previsor de cargas elétricas, por mais que apresente mais ciclos é considerado mais confiável.

6 CONCLUSÃO E SUGESTÕES PARA TRABALHOS FUTUROS

Neste capítulo serão abordadas as conclusões finais pertinentes sobre o previsor de cargas elétricas desenvolvido, empregando o uso das redes neurais e do algoritmo *backpropagation* estocástico. E por fim, serão apresentadas algumas sugestões para trabalhos futuros.

6.1 CONCLUSÃO

Este trabalho teve como objetivo desenvolver uma metodologia para previsão de cargas elétricas a curto prazo, utilizando como ferramenta as redes neurais artificiais, com treinamento baseado no algoritmo *backpropagation* estocástico. Foram analisados e executados vários testes, com a base de dados históricos de uma companhia do setor elétrico brasileiro.

Dessa forma, os resultados obtidos serviram como parâmetros para analisar a eficiência do algoritmo proposto e que poderia ser melhorado. Por meio de depuração, foi encontrado uma porcentagem de atualização dos pesos, que proporcionou melhores e mais eficientes resultados do que o algoritmo *backpropagation* convencional.

Os resultados de previsão de carga a curto prazo, considerando as 24 horas subsequentes, obtidos pelo método proposto, mostraram uma leve melhora em relação aos resultados obtidos pelo algoritmo *backpropagation* convencional. Uma observação importante neste sentido, uma vez que, existe uma melhora no treinamento estocástico no qual mostra que não são necessários a adaptação de todos os neurônios da rede, mas apenas alguns que foram selecionados aleatoriamente. Desta forma, tem-se que associando o procedimento estocástico com a identificação dos neurônios que devem ser atualizados possa gerar um modelo mais robustos que obtenha bons resultados. Podendo concluir, que o algoritmo *backpropagation* estocástico tornou-se mais eficiente para um sistema previsor de cargas elétricas, tornando-o mais confiável.

O sistema previsor de cargas elétricas apresentado neste trabalho é de suma importância no contexto da literatura. Tendo potencial para aplicações em outros problemas mais complexos, com parâmetros diferentes e número de maiores de variáveis e informações. Conseguindo também abranger outras áreas e solucionar outros problemas.

6.2 SUGESTÕES PARA TRABALHOS FUTUROS

De acordo com os resultados obtidos, podem ser feitas algumas sugestões para trabalhos futuros, como:

- Estudo e aperfeiçoamento dos resultados obtidos, acrescentando uma subrotina na programação do algoritmo para encontrar de maneira estocástica o melhor balanceamento de atualização dos pesos;
- Desenvolver estratégias eficientes para uma melhoria neste algoritmo;
- Comparação dos resultados apresentados, com outros tipos de treinamento de rede a fim de analisar sua eficiência;
- Aplicar esse método apresentado para previsões de médio e longo prazo.

REFERÊNCIAS

- AMARI, S.-i. Backpropagation and stochastic gradient descent method. *Neurocomputing*, Amsterdam, v. 5, n. 4-5, p. 185–196, 1993.
- ERNST, O. K. Stochastic gradient descent learning and the backpropagation algorithm. *University of California, San Diego, La Jolla, CA, Tech. Rep*, 2014.
- FILHO, E. M.; CARVALHO, A. Tutorial introdutório sobre redes neurais artificiais. *Departamento de Ciências de Computação e Estatística–USP*, 1997.
- FINE, T. L. *Feedforward neural network methodology*. [S.l.]: Springer Science & Business Media, 2006.
- GUIRELLI, C. R. *Previsão da carga de curto prazo de áreas elétricas através de técnicas de inteligência artificial*. 2006. 115 f. Tese (Doutorado) — Universidade de São Paulo, São Paulo, 2006.
- HAYKIN. A comprehensive foundation. *Neural networks*, New York, v. 2, n. 2004, p. 41, 2004.
- HODGKIN, A. L.; HUXLEY, A. F. A quantitative description of membrane current and its application to conduction and excitation in nerve. *The Journal of physiology*, Wiley-Backwell, v. 117, n. 4, p.500, 1952.
- KOŠŤÁK, J.; JAKŠA, R.; SINČÁK, P. Stochastic weight update in the backpropagation algorithm on feed-forward neural networks. In: *The 2010 International Joint Conference on Neural Networks (IJCNN)*, 2010, Barcelona. *Anais [...]* IEEE, 2010. p. 1–4.
- KROSE, B.; SMAGT, P. van der. An introduction to neural networks. In: KROSE, B.; SMAGT, P. [S.l.], 1996.
- LOPES, M. *Desenvolvimento de um sistema previsor de cargas elétricas via redes neurais*. 2005. 149 f. Tese (Doutorado) — Programa de Pós-graduação em Engenharia Elétrica, Ilha Solteira, 2005.
- LOPES, M. L. M; MINUSSI, C. R.; LOTUFO, A. D. P. A fast electric load forecasting using neural networks. In: *Proceeding of the 43rd IEEE Midwest Symposium on Circuits and Systems (Cat.No.CH37144)*, 2., 2000, Lansing. *Anais [...]* IEEE, 2000. p. 1–5.
- O'DONOVAN, T. M. Short term forecasting: An introduction to the box-jenkins approach. In: *John Wiley & Sons, inc., 605 Third Ave*, 1983, New York. *Anais [...]*, 1983. p. 256.

- OTHMAN, M, et al. The application of box-jenkins models in short term load forecasting. *International Journal of Power, Energy and Artificial Intelligence*, Roorkee, v. 2, n. 1, p. 104-110, 2009.
- SALVETTI, A.; WILAMOWSKI, B. M.; DAGLI, C. Introducing stochastic process within the backpropagation algorithm for improved convergence. In: ANNIE. [S.l.], 1994.
- SILVA, I. d.; SPATTI, D. H.; FLAUZINO, R. A. Redes neurais artificiais para engenharia e ciências aplicadas. São Paulo, v. 23, n. 5, p. 33–111, 2010.
- SIMPSON, P. K. *Artificial neural systems: foundations, paradigms, applications, and implementations*. [S.l.]: Elsevier Science Inc., 1989.
- TANG, Z.; ALMEIDA, C. D.; FISHWICK, P. A. Time series forecasting using neural networks vs. box-jenkins methodology. *Simulation*, San Diego, v.57, n. 5, p. 303-310, 1991.
- WASSERMAN, P. D. Advanced methods in neural computing. [S.l.]: John Wiley & Sons, Inc., 1993.
- WERBOS, P. J. *The roots of backpropagation: from ordered derivatives to neural networks and political forecasting*. [S.l.]: John Wiley & Sons, 1994. v. 1.
- WIDROW, B.; LEHR, M. A. 30 years of adaptive neural networks: perceptron, madaline, and backpropagation. *Proceedings of the IEEE*, New York, v. 78, n. 9, p. 1415–1442, 1990.

APÊNDICE A - BANCO DE DADOS

Hora	Dias								
	08/07	09/07	10/07	11/07	12/07	13/07	14/07	15/07	16/07
01	2588.5	2615.6	2580.1	2612.3	2442.1	2300.0	2459.6	2469.9	2554.7
02	2450.4	2477.3	2478.4	2467.2	2325.6	2194.3	2303.6	2377.2	2416.5
03	2396.6	2428.2	2423.2	2386.5	2277.4	2157.0	2273.3	2311.9	2348.4
04	2343.9	2402.0	2376.6	2325.7	2227.3	2114.7	2232.2	2279.2	2303.9
05	2364.3	2423.1	2384.1	2329.0	2195.4	2164.1	2257.4	2284.4	2336.2
06	2442.7	2508.9	2464.8	2344.4	2211.2	2227.5	2388.6	2406.0	2412.9
07	2663.8	2727.4	2746.5	2381.4	2189.7	2462.5	2550.0	2559.2	2592.6
08	2792.0	2892.1	2844.8	2413.2	2183.4	2682.2	2667.2	2702.2	2764.5
09	3027.1	3152.7	3009.1	2598.8	2265.7	2892.8	2854.6	2928.1	2950.7
10	3176.8	3250.1	3154.1	2708.8	2367.6	3047.1	2969.6	3038.5	3077.6
11	3250.9	3332.2	3216.9	2733.6	2400.8	3125.4	3034.7	3071.7	3159.6
12	3366.2	3347.4	3221.7	2716.7	2382.6	3072.7	3063.4	3170.4	3169.0
13	3351.0	3334.5	3192.6	2721.5	2394.8	3093.6	3031.3	3121.7	3143.6
14	3349.0	3359.5	3179.5	2710.2	2373.6	3110.2	3056.9	3123.0	3154.7
15	3429.4	3284.7	3210.8	2689.6	2336.6	3087.8	3085.0	3145.8	3211.6
16	3447.8	3295.4	3239.7	2719.7	2304.6	3113.4	3052.9	3178.8	3206.5
17	3400.9	3403.6	3161.7	2728.7	2111.4	3195.1	3099.0	3204.7	3270.3
18	3531.4	3569.2	3300.4	3014.4	2383.6	3345.3	3313.8	3349.5	3390.2
19	3803.1	3715.9	3594.8	3376.2	2932.4	3553.4	3567.3	3654.3	3682.3
20	3589.6	3512.6	3461.3	3316.3	3006.1	3401.8	3424.2	3457.8	3502.2
21	3503.7	3438.2	3349.8	3254.3	2964.0	3305.5	3322.1	3389.9	3415.7
22	3524.5	3449.0	3341.2	3157.4	2862.2	3304.7	3325.2	3392.1	3414.0
23	3223.4	3175.5	3149.8	2967.2	2705.5	3027.5	3045.1	3153.1	3149.3
24	2934.4	2822.2	2893.2	2713.0	2496.2	2728.5	2736.0	2830.2	2885.9

Fonte: Elaboração da própria autora.

Hora	Dias								
	17/07	18/07	19/07	20/07	21/07	22/07	23/07	24/07	25/07
01	2552.2	2666.6	2626.6	2371.0	2578.7	2572.2	2613.1	2603.5	2600.7
02	2419.8	2505.7	2504.2	2357.8	2421.4	2437.3	2468.9	2465.3	2466.2
03	2353.3	2434.4	2388.4	2256.4	2411.1	2388.4	2417.1	2420.4	2348.4
04	2347.0	2373.2	2337.7	2246.7	2368.5	2368.2	2380.1	2367.5	2361.1
05	2350.2	2391.2	2345.0	2254.1	2398.2	2403.1	2410.0	2398.0	2356.3
06	2446.1	2400.1	2323.3	2353.1	2468.3	2498.5	2502.2	2502.9	2379.3
07	2646.9	2395.7	2279.2	2530.4	2625.1	2639.7	2648.3	2674.3	2363.1
08	2777.2	2427.0	2255.9	2763.2	2812.2	2814.0	2831.5	3016.2	2442.3
09	3022.9	2693.0	2313.7	2990.9	3029.8	3086.8	3098.6	3145.1	2558.9
10	3143.3	2730.2	2336.1	3157.4	3211.7	3248.7	3146.3	3259.3	2677.9
11	3192.1	2758.2	2358.1	3232.1	3262.5	3264.9	3211.9	3303.6	2747.8
12	3224.8	2741.8	2415.9	3236.2	3280.3	3248.9	3289.8	3290.4	2748.7
13	3198.3	2759.3	2438.9	3165.7	3388.8	3232.8	3290.5	3259.9	2747.8
14	3246.8	2781.9	2392.0	3213.1	3412.8	3257.3	3324.9	3326.3	2726.7
15	3254.5	2745.7	2360.9	3262.1	3435.4	3262.6	3314.1	3336.1	2673.6
16	3237.8	2673.4	2339.1	3279.7	3464.0	3289.2	3311.7	3273.6	2675.9
17	3260.9	2699.0	2429.6	3365.7	3374.4	3334.2	3336.2	3301.3	2637.6
18	3380.8	3017.3	2871.9	3466.5	3489.9	3379.2	3447.2	3434.4	2979.3
19	3667.5	3451.0	3247.6	3643.4	3757.2	3626.6	3586.4	3567.5	3409.3
20	3498.2	3423.9	3182.6	3510.0	3613.3	3446.9	3448.9	3421.4	3310.8
21	3431.6	3339.0	3161.7	3472.1	3514.7	3420.4	3418.0	3338.2	3250.2
22	3374.8	3227.0	3110.8	3446.0	3427.0	3385.6	3352.8	3322.9	3216.9
23	3205.5	3095.2	2960.6	3182.9	3200.5	3181.7	3188.6	3113.6	2977.2
24	2961.9	2879.4	2754.4	2910.5	2856.1	2898.1	2910.8	2860.1	2766.9

Fonte: Elaboração da própria autora.

Hora	Dias		
	26/07	27/07	28/07
01	2537.5	2461.2	2615.5
02	2400.4	2355.1	2471.1
03	2329.4	2284.3	2382.8
04	2280.4	2237.1	2381.3
05	2240.8	2263.8	2406.4
06	2260.1	2359.8	2491.7
07	2177.9	2508.7	2623.7
08	2185.1	2705.8	2775.3
09	2286.8	2980.2	3041.2
10	2328.5	3151.7	3168.7
11	2367.9	3242.9	3249.9
12	2381.5	3269.0	3269.0
13	2421.9	3271.9	3237.5
14	2387.7	3340.5	3325.6
15	2367.9	3340.0	3336.7
16	2312.2	3292.7	3353.4
17	2396.5	3330.2	3347.0
18	2717.2	3390.5	3382.0
19	3218.9	3655.2	3667.4
20	3176.4	3490.9	3508.6
21	3134.5	3411.8	3421.2
22	3053.9	3395.3	3425.7
23	2939.6	3206.3	3210.5
24	2704.0	2882.2	2941.4

Fonte: Elaboração da própria autora.

APÊNDICE B - BANCO DE DADOS

Hora	Dias								
	17/06	18/06	19/06	20/06	21/06	22/06	23/06	24/06	25/06
01	2541.6	2605.6	2620.4	2630.9	2438.8	2264.9	2440.4	2513.4	2588.8
02	2399.8	2450.1	2462.3	2474.6	2317.7	2163.3	2305.7	2366.2	2387.1
03	2366.2	2388.2	2435.1	2383.2	2259.9	2110.3	2267.7	2312.1	2348.3
04	2329.3	2396.3	2371.6	2342.9	2187.3	2094.4	2231.9	2299.9	2370.6
05	2364.7	2388.5	2394.3	2359.2	2187.7	2137.5	2271.2	2301.7	2396.9
06	2492.1	2478.5	2508.8	2386.0	2183.2	2237.1	2356.4	2408.1	2488.5
07	2729.8	2731.3	2718.5	2439.4	2166.3	2489.3	2595.7	2605.6	2722.4
08	2831.8	2835.3	2832.5	2488.8	2133.3	2689.7	2728.0	2789.7	2889.2
09	3027.0	3024.5	3082.8	2656.7	2205.1	2896.1 2	948.4	3034.	8 3063.8
10	3141.9	3168.4	3251.1	2788.7	2339.3	3057.1	3099.4	3122.5	3225.2
11	3194.8	3238.7	3381.0	2837.9	2410.8	3154.5	3150.5	3206.2	3280.0
12	3258.8	3247.0	3381.6	2831.1	2439.7	3201.8	3153.1	3253.4	3304.3
13	3256.6	3178.5	3363.6	2790.8	2451.0	3149.5	3148.4	3255.7	3291.9
14	3236.5	3174.7	3374.1	2809.1	2455.9	3140.3	3092.7	3285.5	3283.4
15	3265.1	3207.4	3379.2	2796.3	2433.5	3132.3	2922.4	3296.2	3243.9
16	3263.4	3211.7	3376.1	2751.1	2420.0	3129.3	2791.6	3309.6	3225.5
17	3331.3	3287.9	3364.4	2792.7	2471.1	3176.7	2479.9	3332.5	3224.5
18	3606.7	3538.4	3602.9	3181.5	2914.5	3348.6	2698.6	3598.5	3389.4
19	3718.4	3695.9	3730.3	3328.9	3136.1	3513.0	3272.8	3741.8	3556.8
20	3517.3	3519.3	3536.5	3240.2	3038.5	3383.2	3223.3	3540.6	3463.2
21	3434.1	3472.8	3488.4	3165.1	2971.4	3345.0	3194.2	3446.0	3320.6
22	3414.3	3393.9	3360.0	3028.3	2889.9	3230.9	3246.8	3434.9	3252.7
23	3222.0	3193.6	3242.5	2873.0	2726.3	3024.5	3052.5	3207.6	3024.0
24	2880.7	2917.0	2941.9	2694.1	2516.7	2671.9	2793.5	2878.8	2756.6

Fonte: Elaboração da própria autora.

Hora	Dias								
	26/06	27/06	28/06	29/06	30/06	01/07	02/07	03/07	04/07
01	2499.3	2581.7	2478.0	2435.4	2574.6	2515.5	2575.1	2665.7	2613.8
02	2367.6	2405.1	2357.3	2302.6	2396.7	2345.4	2460.9	2511.6	2487.7
03	2315.8	2340.9	2274.0	2284.2	2287.3	2350.6	2364.7	2440.8	2406.7
04	2300.6	2324.8	2236.9	2254.8	2241.1	2318.9	2350.6	2423.3	2368.4
05	2347.5	2290.9	2189.7	2282.5	2286.7	2334.9	2360.7	2425.9	2335.7
06	2427.4	2317.4	2169.7	2390.2	2384.3	2429.0	2440.6	2501.6	2381.4
07	2668.1	2321.5	2158.8	2626.8	2580.4	2616.4	2684.7	2639.8	2446.1
08	2772.6	2393.1	2144.0	2797.7	2720.7	2778.1	2781.7	2805.6	2455.9
09	2956.4	2581.4	2283.0	2949.1	2912.5	2969.1	3000.7	3016.2	2598.0
10	3105.4	2697.9	2313.3	3124.0	3068.9	3090.0	3146.7	3163.4	2731.0
11	3199.6	2738.4	2377.6	3194.4	3147.3	3201.8	3212.6	3259.2	2763.4
12	3151.1	2734.6	2412.3	3258.4	3190.5	3261.9	3330.7	3239.3	2803.0
13	3173.2	2717.7	2441.8	3264.7	3161.8	3240.2	3333.4	3205.6	2822.3
14	3192.1	2660.9	2432.4	3264.4	3156.0	3241.3	3345.3	3163.2	2767.3
15	3205.3	2616.2	2409.1	3256.2	3205.8	3251.9	3330.7	3010.5	2745.7
16	3190.0	2536.7	2351.9	3249.0	3202.9	3237.9	3348.6	2830.4	2737.2
17	3163.1	2307.6	2401.3	3271.8	3228.6	3301.4	3387.1	2538.7	2738.0
18	3432.1	2658.7	2858.7	3476.3	3432.2	3450.8	3552.1	2718.5	3127.4
19	3558.3	3289.2	3232.5	3673.1	3610.7	3706.5	3712.3	3298.9	3487.4
20	3400.8	3255.3	3158.5	3528.9	3484.1	3518.5	3534.1	3262.8	3376.2
21	3364.0	3152.4	3100.9	3384.9	3450.6	3444.3	3503.0	3229.2	3286.3
22	3305.8	3075.3	3006.2	3335.7	3339.9	3413.9	3425.1	3261.7	3181.8
23	3097.5	2938.9	2903.1	3147.3	3160.4	3191.3	3212.3	3160.4	2964.1
24	2852.0	2723.6	2672.9	2841.6	2839.5	2899.1	2947.6	2884.8	2765.7

Fonte: Elaboração da própria autora.

Hora	Dias								
	05/07	06/07	07/07	08/07	09/07	10/07	11/07	12/07	13/07
01	2582.3	2480.3	2619.2	2588.5	2615.6	2580.1	2612.3	2442.1	2300.0
02	2418.9	2354.9	2488.9	2450.4	2477.3	2478.4	2467.2	2325.6	2194.3
03	2342.3	2293.1	2402.9	2396.6	2428.2	2423.2	2386.5	2277.4	2157.0
04	2302.8	2260.5	2335.2	2343.9	2402.0	2376.6	2325.7	2227.3	2114.7
05	2262.5	2282.8	2414.7	2364.3	2423.1	2384.1	2329.0	2195.4	2164.1
06	2241.5	2410.4	2490.1	2442.7	2508.9	2464.8	2344.4	2211.2	2227.5
07	2231.7	2628.4	2714.7	2663.8	2727.4	2746.5	2381.4	2189.7	2462.5
08	2181.8	2786.3	2841.6	2792.0	2892.1	2844.8	2413.2	2183.4	2682.2
09	2293.2	2976.2	3083.9	3027.1	3152.7	3009.1	2598.8	2265.7	2892.8
10	2337.7	3153.4	3171.5	3176.8	3250.1	3154.1	2708.8	2367.6	3047.1
11	2348.7	3279.4	3215.2	3250.9	3332.2	3216.9	2733.6	2400.8	3125.4
12	2402.7	3294.9	3206.1	3366.2	3347.4	3221.7	2716.7	2382.6	3072.7
13	2392.4	3289.0	3183.6	3351.0	3334.5	3192.6	2721.5	2394.8	3093.6
14	2388.4	3314.5	3133.8	3349.0	3359.5	3179.5	2710.2	2373.6	3110.2
15	2351.6	3331.5	2968.2	3429.4	3284.7	3210.8	2689.6	2336.6	3087.8
16	2339.7	3339.7	2805.8	3447.8	3295.4	3239.7	2719.7	2304.6	3113.4
17	2412.4	3333.2	2549.6	3400.9	3403.6	3161.7	2728.7	2111.4	3195.1
18	2884.9	3476.5	2671.6	3531.4	3569.2	3300.4	3014.4	2383.6	3345.3
19	3261.2	3699.0	3062.1	3803.1	3715.9	3594.8	3376.2	2932.4	3553.4
20	3174.8	3489.7	3192.9	3589.6	3512.6	3461.3	3316.3	3006.1	3401.8
21	3152.7	3415.0	3248.9	3503.7	3438.2	3349.8	3254.3	2964.0	3305.5
22	3045.2	3519.4	3296.7	3524.5	3449.0	3341.2	3157.4	2862.2	3304.7
23	2908.2	3180.2	3160.0	3223.4	3175.5	3149.8	2967.2	2705.5	3027.5
24	2699.8	2898.	7 2854.0	2934.4	2822.2	2893.2	2713.0	2496.2	2728.5

Fonte: Elaboração da própria autora.

Hora	Dias								
	14/07	15/07	16/07	17/07	18/07	19/07	20/07	21/07	22/07
01	2459.6	2469.9	2554.7	2552.2	2666.6	2626.6	2371.0	2578.7	2572.2
02	2303.6	2377.2	2416.5	2419.8	2505.7	2504.2	2357.8	2421.4	2437.3
03	2273.3	2311.9	2348.4	2353.3	2434.4	2388.4	2256.4	2411.1	2388.4
04	2232.2	2279.2	2303.9	2347.0	2373.2	2337.7	2246.7	2368.5	2368.2
05	2257.4	2284.4	2336.2	2350.2	2391.2	2345.0	2254.1	2398.2	2403.1
06	2388.6	2406.0	2412.9	2446.1	2400.1	2323.3	2353.1	2468.3	2498.5
07	2550.0	2559.2	2592.6	2646.9	2395.7	2279.2	2530.4	2625.1	2639.7
08	2667.2	2702.2	2764.5	2777.2	2427.0	2255.9	2763.2	2812.2	2814.0
09	2854.6	2928.1	2950.7	3022.9	2693.0	2313.7	2990.9	3029.8	3086.8
10	2969.6	3038.5	3077.6	3143.3	2730.2	2336.1	3157.4	3211.7	3248.7
11	3034.7	3071.7	3159.6	3192.1	2758.2	2358.1	3232.1	3262.5	3264.9
12	3063.4	3170.4	3169.	3224.8	2741.8	2415.9	3236.2	3280.3	3248.90
13	3031.3	3121.7	3143.6	3198.3	2759.3	2438.9	3165.7	3388.8	3232.8
14	3056.9	3123.0	3154.7	3246.8	2781.9	2392.0	3213.1	3412.8	3257.3
15	3085.0	3145.8	3211.6	3254.5	2745.7	2360.9	3262.1	3435.4	3262.6
16	3052.9	3178.8	3206.5	3237.8	2673.4	2339.1	3279.7	3464.0	3289.2
17	3099.0	3204.7	3270.3	3260.9	2699.0	2429.6	3365.7	3374.4	3334.2
18	3313.8	3349.5	3390.2	3380.8	3017.3	2871.9	3466.5	3489.9	3379.2
19	3567.3	3654.3	3682.3	3667.5	3451.0	3247.6	3643.4	3757.2	3626.6
20	3424.2	3457.8	3502.2	3498.2	3423.9	3182.6	3510.0	3613.3	3446.9
21	3322.1	3389.9	3415.7	3431.6	3339.0	3161.7	3472.1	3514.7	3420.4
22	3325.2	3392.1	3414.0	3374.8	3227.0	3110.8	3446.0	3427.0	3385.6
23	3045.1	3153.1	3149.3	3205.5	3095.2	2960.6	3182.9	3200.5	3181.7
24	2736.0	2830.2	2885.9	2961.9	2879.4	2754.4	2910.5	2856.1	2898.1

Fonte: Elaboração da própria autora.

Hora	Dias					
	23/07	24/07	25/07	26/07	27/07	28/07
01	2613.1	2603.5	2600.7	2537.5	2461.2	2615.5
02	2468.9	2465.3	2466.2	2400.4	2355.1	2471.1
03	2417.1	2420.4	2348.4	2329.4	2284.3	2382.8
04	2380.1	2367.5	2361.1	2280.4	2237.1	2381.3
05	2410.0	2398.0	2356.3	2240.8	2263.8	2406.4
06	2502.2	2502.9	2379.3	2260.1	2359.8	2491.7
07	2648.3	2674.3	2363.1	2177.9	2508.7	2623.7
08	2831.5	3016.2	2442.3	2185.1	2705.8	2775.3
09	3098.6	3145.1	2558.9	2286.8	2980.2	3041.2
10	3146.3	3259.3	2677.9	2328.5	3151.7	3168.7
11	3211.9	3303.6	2747.8	2367.9	3242.9	3249.9
12	3289.8	3290.4	2748.7	2381.5	3269.0	3269.0
13	3290.5	3259.9	2747.8	2421.9	3271.9	3237.5
14	3324.9	3326.3	2726.7	2387.7	3340.5	3325.6
15	3314.1	3336.1	2673.6	2367.9	3340.0	3336.7
16	3311.7	3273.6	2675.9	2312.2	3292.7	3353.4
17	3336.2	3301.3	2637.6	2396.5	3330.2	3347.0
18	3447.2	3434.4	2979.3	2717.2	3390.5	3382.0
19	3586.4	3567.5	3409.3	3218.9	3655.2	3667.4
20	3448.9	3421.4	3310.8	3176.4	3490.9	3508.6
21	3418.0	3338.2	3250.2	3134.5	3411.8	3421.2
22	3352.8	3322.9	3216.9	3053.9	3395.3	3425.7
23	3188.6	3113.6	2977.2	2939.6	3206.3	3210.5
24	2910.8	2860.1	2766.9	2704.0	2882.2	2941.4

Fonte: Elaboração da própria autora.