



**Universidade Federal da Paraíba**  
**Centro de Energias Alternativas e Renováveis**  
**Departamento de Engenharia Elétrica**

ZARIFF MEIRA GOMES

**PREVISÃO DE CARGA DO SUBSISTEMA SANTA CRUZ II  
UTILIZANDO REDES NEURAIIS ARTIFICIAIS BASEADA NAS  
INFORMAÇÕES DE DEMANDA E ENERGIA**

João Pessoa, Paraíba  
Agosto de 2013

ZARIFF MEIRA GOMES

PREVISÃO DE CARGA PARA A SUBSISTEMA SANTA CRUZ II  
UTILIZANDO REDES NEURAIAS ARTIFICIAIS BASEADA NAS  
INFORMAÇÕES DE DEMANDA E ENERGIA

*Relatório de Estágio Supervisionado submetido ao  
Departamento de Engenharia Elétrica da  
Universidade Federal da Paraíba como parte dos  
requisitos necessários para a obtenção do título de  
Engenheiro Eletricista.*

Orientador:

Professor Juan Moisés Mauricio Villanueva, Dr. Sc.

João Pessoa, Paraíba  
Agosto de 2013

# FOLHA DE ASSINATURA

Aprovado em \_\_\_\_/\_\_\_\_/\_\_\_\_

---

Zariff Meira Gomes  
Aluno

---

Prof. Juan Moisés M. Villanueva  
Professor Orientador

---

Silvino A. de G. Nóbrega Neto  
Supervisor da empresa

---

Rogério Almeida  
Professor Avaliador Interno

# IDENTIFICAÇÃO DO ESTÁGIO

## EMPRESA

NOME: Energisa Paraíba

ENDEREÇO: Rodovia BR-230, km 25

BAIRRO: Cristo Redentor

CIDADE/ESTADO: JOÃO PESSOA - PB

TEL.: 55 (83) 2106-7000

CEP: 58 071-680

## ESTÁGIO

ÁREA DA EMPRESA: ASPO- Assessoria de Planejamento e Orçamento.

DATA DE INÍCIO: 13/06/2013

DATA DE TÉRMINO: 18/09/2013

CARGA HORÁRIA SEMANAL: 20

CARGA HORÁRIA TOTAL: 280H

SUPERVISOR DE ESTÁGIO: Marcelo Cerqueira Jr.

# SUMÁRIO

Folha de assinatura .....	iii
Identificação do estágio .....	iv
Sumário .....	v
1 Introdução .....	6
1.1 Objetivos do estágio .....	7
1.1.1 Objetivo geral.....	8
1.1.2 Objetivos específicos.....	8
1.2 A Empresa.....	9
2 Embasamento Teórico .....	11
2.1 Rede neural artificial .....	11
2.2 RNA aplicado para Previsão .....	16
2.3 Índices de desempenho .....	17
2.3.1 MAPE – Erro percentual absoluto médio.....	18
2.3.2 EPM – Erro percentual máximo.....	18
3 Atividades desenvolvidas.....	19
3.1 Atividade 1 – tratamento dos dados .....	19
3.1.1 Descrição .....	19
3.1.2 Desenvolvimento.....	20
3.1.2.1 Leitura dos dados originais e cálculo das potências máximas de cada dia .....	20
3.1.2.2 Construção das potências máximas semanais .....	21
3.1.2.3 Correção dos dados .....	22
3.2 Atividade 2 – Criação do banco de dados para RNA.....	24
3.2.1 Descrição .....	24
3.2.2 Desenvolvimento.....	25
3.2.2.1 Variáveis de interesse.....	25
3.2.2.2 Padronização das variáveis.....	26
3.3 Atividade 3 – Configuração das RNA e teste .....	29
4 Resultados e discussões .....	30
4.1 Erros e problemas nas medições .....	30
4.2 Treinamento e teste.....	35
5 Conclusão .....	43
Bibliografia .....	44
ANEXO A.....	45

# 1 INTRODUÇÃO

A expansão do uso de equipamentos elétricos e eletrônicos proveniente do aumento da capacidade de consumo da sociedade e do baixo custo dos mesmos têm provocado um aumento no consumo de energia elétrica. Além disso, o setor industrial, cada vez mais automatizado e crescente, também tem exigido um aumento na quantidade de energia gerada e uma eficiência na transmissão da mesma. Assim, além da necessidade de aumentar a capacidade de geração de energia, o sistema elétrico de transmissão e distribuição deve estar em constante modificação e adaptação para acompanhar tal crescimento garantindo a continuidade do fornecimento de energia bem como a qualidade da mesma.

Um importante mecanismo utilizado para adaptar o sistema elétrico para as novas condições de consumo é a previsão de carga. A previsão é essencial no planejamento estratégico de ampliação do sistema de distribuição. Através dela é possível alocar recursos e planejar obras de infraestrutura, adaptação e ampliação dos diversos subsistemas do sistema de distribuição e transmissão. Como por exemplo, deve-se planejar a curto, médio e longo prazo a quantidade de energia que uma subestação pode fornecer bem como a capacidade de fornecimento de determinados alimentadores para que nenhum dispositivo ou equipamento seja sobrecarregado diminuindo assim seu desgaste e a possibilidade de que venham a falhar.

Neste cenário, este trabalho propôs uma metodologia para prever carga utilizando Redes Neurais Artificiais. Os métodos utilizados pelas concessionárias de energia hoje, não são muito eficientes e muitas vezes não fornecem dados precisos essenciais para o planejamento da empresa. O método escolhido vem a aumentar a eficiência da previsão de carga da concessionária Energisa Paraíba contribuindo para seu melhor planejamento.

Redes Neurais têm sido utilizadas para previsão nas mais diversas áreas, dentre elas, bolsas de valores, meteorologia, dentre outros. O método tem sido amplamente utilizado por ter altos índices de confiabilidade e flexibilidade. Redes neurais aprendem comportamentos não lineares e pode levar em consideração os mais diversos fatores para previsão, como, por exemplo, o aumento do PIB, do crescimento populacional, da

alteração no índice de qualidade de vida de determinada população, dentre outros. Desta forma, diversos fatores podem ser levados em consideração aumentando a confiabilidade dos dados de previsão. Para a aplicação das RNAs (Redes Neurais Artificiais) é necessário um banco de dados passados e, para uma boa eficiência de previsão, esse banco de dados precisa ser consistente e confiável.

Portanto, para a Energisa Paraíba a previsão de carga é algo essencial para o bom funcionamento da empresa e o aumento na eficiência dos seus gastos, podendo assim continuar a garantir o bom fornecimento de energia no estado da Paraíba.

## 1.1 OBJETIVOS DO ESTÁGIO

O objetivo principal deste trabalho consiste em desenvolver uma metodologia para a previsão de carga para a Energisa Paraíba, a concessionária de energia elétrica da Paraíba.

Os pontos de previsão visados pela empresa foram os das subestações de Cuité, Picuí e Pedra Lavrada bem como a Subestação de Santa Cruz II que alimenta as subestações citadas. A previsão também deveria ser aplicada nos onze alimentadores provenientes das subestações principais, conforme Figura 1. A previsão tem como objetivo prever a demanda vistos os valores de demanda, energia e taxa de crescimento catalogados em períodos remotos. Para isso uma análise e seleção e tratamento de dados teve de ser realizada. Toda a implementação em software foi feita utilizando o toolbox de redes neurais do MATLAB.

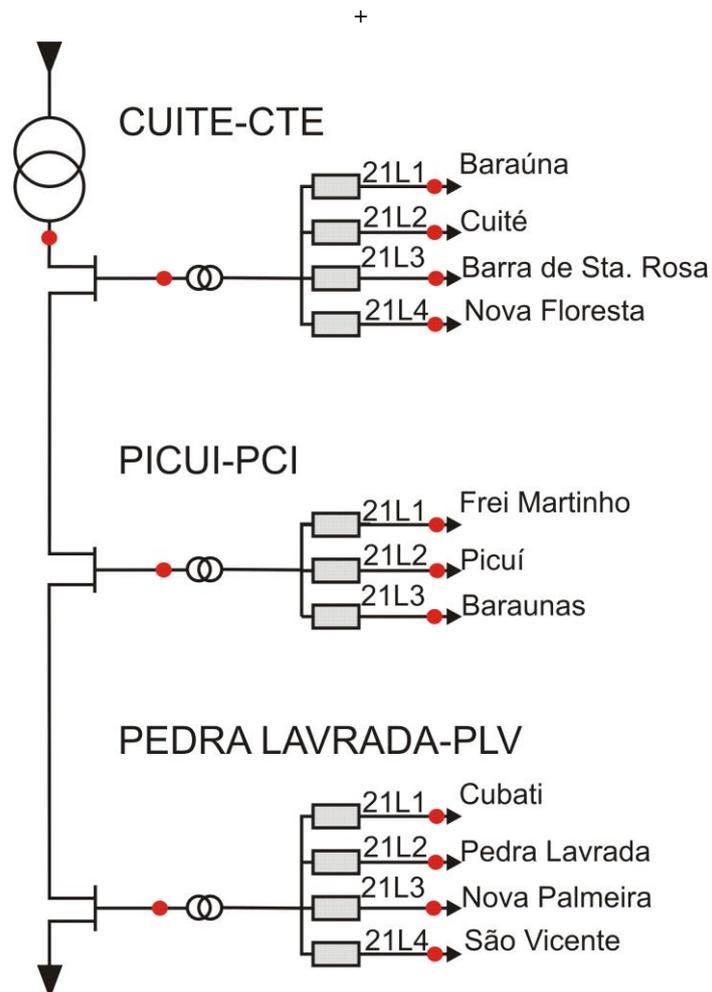


Figura 1. Diagrama das subestações analisadas.

### 1.1.1 OBJETIVO GERAL

Avaliar o desempenho do uso de RNAs para previsão de carga para a Energisa Paraíba.

### 1.1.2 OBJETIVOS ESPECÍFICOS

São os objetivos parciais do trabalho:

- Tratamento de dados iniciais
- Análise dos dados e detecção de erros na obtenção dos dados para a rede
- Configuração das topologias das RNAs
- Treinamento e testes de RNAs.

## 1.2 A EMPRESA

A Sociedade Anônima de Eletrificação da Paraíba agora é Energisa. Daqui para frente, todas as empresas do Sistema Cataguazes-Leopoldina – Saelpa, Celb, Energipe, Cenf, Companhia Força e Luz Cataguazes-Leopoldina e CAT-LEO Cise – pertencem ao Grupo Energisa.

O novo nome e identidade visual reforçarão o compromisso da empresa de contribuir para o desenvolvimento econômico e social do Estado, procurando não apenas suprir o mercado com energia elétrica de qualidade, mas também proporcionar maior satisfação aos seus clientes.

Em novembro de 2000, quando foi privatizada e passou a integrar o Sistema Cataguazes-Leopoldina, a Saelpa, agora Energisa, vem realizando expressivos investimentos para garantir aos paraibanos energia elétrica de boa qualidade e atendimento com excelência. Somente entre os anos de 2003 e 2005 a empresa investiu R\$ 173 milhões e lançou mão de todos os recursos e ferramentas disponíveis, para promover modernização em suas condições físicas, operacionais e humanas.

No triênio 2007-2009, a concessionária investiu mais de R\$ 300 milhões concentrados nas áreas de Transmissão, Distribuição, Programa Luz para Todos e infraestrutura de apoio, ficando em grande parte direcionada para o interior do Estado. Esses investimentos são 30% superiores aos realizados no último triênio (2004-2007).

Após todo esse avanço, a empresa paraibana tornou-se mais moderna e passou a registrar alto nível de evolução em seus principais indicadores de desempenho, também em decorrência da implantação de um plano interno de gestão estratégica.

Nos últimos sete anos, a concessionária tem realizado ampla reformulação de seus processos operacionais, incorporando novas tecnologias para alcançar maior produtividade, qualidade e segurança. Esse último ponto foi alvo de programa específico intitulado “Segurança Máxima, Prioridade Zero”, cujas ações educacionais e de conscientização têm resultado em drástica redução nos índices de acidente da Empresa.

A automação do sistema elétrico também tem sido objeto de investimentos consideráveis, tendo em vista reduzir tempo e frequência das interrupções de energia, assim como, garantir maior segurança na operação do sistema. Em 2006, a automação do sistema de transmissão foi concluída.

## **Compromisso**

A responsabilidade em relação à vida social, cultural e artística da Paraíba também tem recebido merecida atenção da empresa. Desde sua privatização, a concessionária vem marcando presença no Estado como empresa cidadã, incentivando a produção e disseminação da cultura através da sua Usina Cultural. A empresa de energia elétrica da Paraíba também desenvolve programas sociais e apoiam pessoas, instituições e projetos nas áreas de cultura, esporte, saúde e educação. Além disso, é parceria em eventos e ações promovidos por instituições e entidades paraibanas.

## **História**

A Sociedade Anônima de Eletrificação da Paraíba foi criada em 15 de dezembro de 1964, a partir da fusão da Companhia Distribuidora de Eletricidade do Brejo Paraibano (Codebro) e da Sociedade de Economia Mista Eletro Cariri S/A (Eletrocariri). Desde que foi leiloadada e passou a integrar o Sistema Cataguazes-Leopoldina, a empresa avançou consideravelmente e, atualmente, está presente em 96% da Paraíba, atendendo um universo de, aproximadamente, 977 mil consumidores, distribuídos em 216 municípios, numa área de 54.595km<sup>2</sup>. Em março de 2007, o Sistema Cataguazes-Leopoldina transforma-se no Grupo Energisa e segue a essência “Energisa: Luz, Imaginação, Realização”, um exercício diário de criatividade para melhor atender aos consumidores. A Saelpa, bem como as demais distribuidoras, passa a chamar-se Energisa.

(Texto extraído do site da empresa: <http://www.energisa.com.br/paraiba/Energisa%20Paraiba/Historia/Aempresa.aspx>)

## 2 EMBASAMENTO TEÓRICO

### 2.1 REDE NEURAL ARTIFICIAL

As redes neurais artificiais são técnicas de computação inteligente que se baseiam em simulações do funcionamento do cérebro humano. O cérebro humano é constituído por células especializadas chamadas neurônios que estão interconectadas entre si, formando uma imensa rede neural biológica. Para realizar o processamento da informação, cada neurônio recebe sinais de outros neurônios, combina estes sinais, realiza um processamento interno, e então, envia sinais a um grande número de outros neurônios. A capacidade de aprendizado, e conseqüente, generalização é função do padrão de conexões entre os neurônios.

O interesse na simulação do funcionamento do cérebro está na sua habilidade de resolução de problemas onde não existem regras explícitas, esta capacidade é chamada de aprendizado através de exemplos, ou seja, generalização.

Para simular o funcionamento do cérebro é necessário compreender o funcionamento do neurônio e então construir um modelo matemático que o represente. Um dos primeiros modelos matemáticos para um neurônio biológico foi proposto por McCullough e Pitts [1] em 1943. Na Figura 2, estão ilustrados os neurônios biológico e artificial.

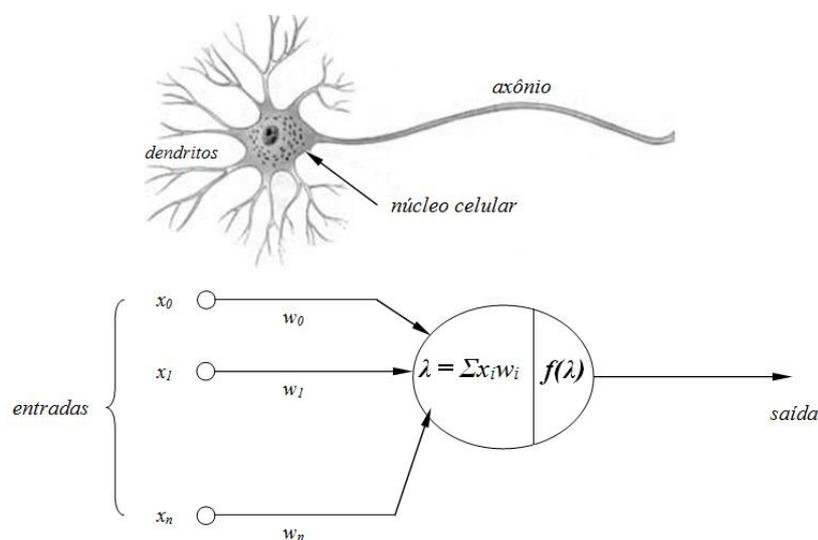


Figura 2. Neurônios biológico e artificial.

No neurônio biológico os dendritos (entrada) são responsáveis pela recepção dos estímulos transmitidos pelos outros neurônios; o núcleo celular tem a função de coletar e combinar informações coletadas de outros neurônios; e o axônio (saída) transmite os estímulos de saída para outras células nervosas.

Na modelagem matemática do neurônio artificial, os sinais de entrada  $x_i$  são captados pelo neurônio. Cada entrada está associada a um peso  $w_i$ . O neurônio combina estes sinais e produz um valor de atividade  $\lambda$ , como soma ponderada das entradas pelos respectivos pesos ( $\lambda = \sum x_i w_i$ ), chamada de saída linear. Uma função de ativação é aplicada sobre esta saída linear resultando no valor de saída do neurônio  $y = f(\lambda)$ . Funções de ativação típicas envolvem comparações e transformações matemáticas e são mostradas na Figura 3. Portanto, a saída  $y$  envolve uma função não-linear, daí a capacidade das redes neurais resolverem problemas complexos reais.

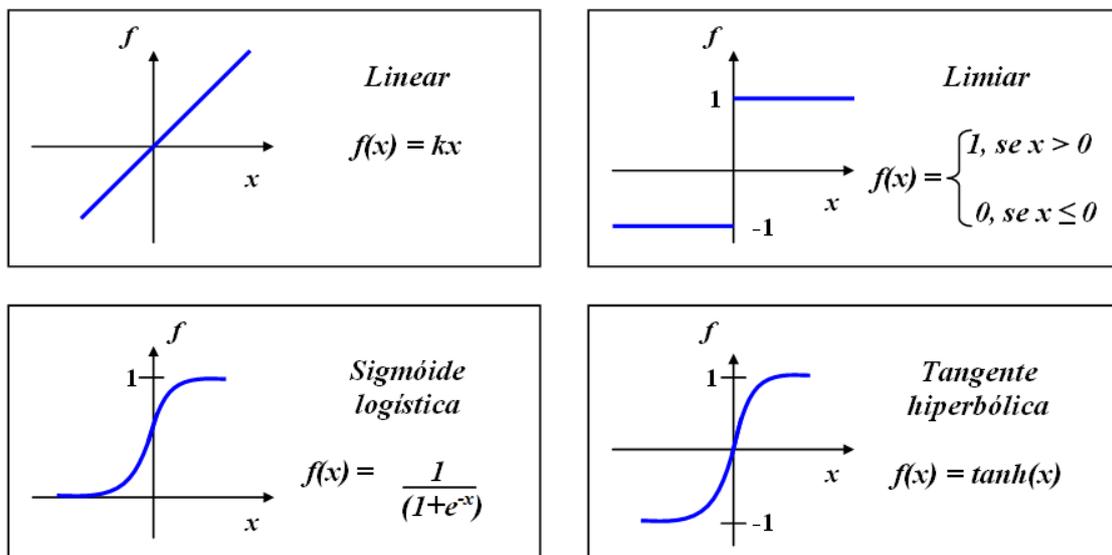


Figura 3. Funções de ativação típicas.

### Classificação dos Modelos de Redes Neurais

Os modelos de redes neurais podem ser classificados em diversos grupos, de acordo com suas características e propriedades [2]. Estes grupos dividem as redes neurais de acordo com os seguintes fatores:

- **Treinamento:** auto aprendizado ou aprendizado supervisionado. O treinamento supervisionado consiste em apresentar à rede neural um

padrão a ser reconhecido juntamente com a resposta que a rede deve fornecer ao deparar-se novamente com o mesmo padrão. No treinamento com auto-aprendizado os padrões são apresentados para a rede, e esta se encarrega de agrupar aqueles que possuem características similares. Este processo é também chamado de clusterização.

- **Regra de Aprendizado:** algoritmo competitivo ou algoritmo adaptativo por correção de erros. As redes neurais que utilizam regras de aprendizado do tipo competitivas caracterizam-se pelas conexões laterais dos neurônios com seus vizinhos, estabelecendo, assim, uma competição entre os neurônios. As redes de Hopfield e Kohonen se enquadram nesta categoria. As redes com aprendizado do tipo correção de erros são baseadas no princípio da adaptação e correção dos pesos de atuação de cada neurônio, até que este produza a saída desejada. A correção de erros está diretamente ligada ao aprendizado do tipo supervisionado.
- **Interconexões dos neurônios:** redes com neurônios sem realimentação ou com realimentação.
- **Organização da Rede:** um nível único ou diversos níveis.
- **Distribuição das Memórias:** localizada ou distribuída. A memória de uma rede neural é dita localizada quando a informação está localizada em um único neurônio, ou seja, um só neurônio é treinado para aprender certo padrão. Se a informação está espalhada entre os diversos neurônios da rede, a memória é classificada como distribuída.
- **Classificação:** separador linear ou separador não linear. As redes neurais que implementam um classificador linear são modelos onde se tem, basicamente, apenas um tipo de padrão associado a cada classe. Desta forma ocorre uma associação linear de padrões. Os classificadores não lineares permitem que tipos bastante distintos sejam associados a uma mesma classe.

### ***Backpropagation***

O *backpropagation* é um algoritmo de aprendizado da rede neural mais utilizado para aplicações relacionadas a sistemas de previsão de series temporais, identificação de sistemas não lineares, reconhecimento de padrões entre outros. Seu aprendizado baseia-se na propagação retrógrada do erro para os níveis anteriores da rede, de acordo com o grau de participação que cada neurônio teve no nível posterior. Antes de descrever as etapas deste algoritmo de aprendizado é necessário alguns conceitos [3]:

- **Regra Delta Generalizada:** Método de aprendizado por minimização do erro. Aplica o método do gradiente decrescente à estrutura de múltiplas camadas.
- **Retropropagação:** Propaga o erro gerado na camada de saída para trás na rede. Utiliza-se da regra do cálculo da derivada do erro em relação aos pesos.

O aprendizado na rede *backpropagation* é supervisionado. A rede produz sua própria saída, comparando-a com a saída desejada. Se houver diferença os pesos são modificados com o objetivo de diminuir esta diferença.

O algoritmo de aprendizado *backpropagation* apresenta duas fases bem delineadas. Na primeira é realizado o treinamento da rede. A segunda fase representa a validação do treinamento, é onde a rede deve reconhecer os padrões que foram treinados.

As etapas do treinamento são:

- Inicialização dos pesos com valores dentro de determinado intervalo;
- Apresentação do vetor de entrada com as respectivas saídas desejadas:  $x_p(x_0, x_1, \dots, x_n)$  ;

Cálculo da saída:

$$y_{p,j} = \sum_{i=0}^{n-1} w_{ij} \theta_{pi} \quad (1)$$

Onde:

$w_{ij}$ - Peso que parte da unidade i para a unidade j.

$\theta_{pi}$ - Saída produzida pela rede para o padrão p na conexão i. Sendo  $\theta_{pi}$  na camada inicial igual a  $x_i$ . (ver Figura 4).

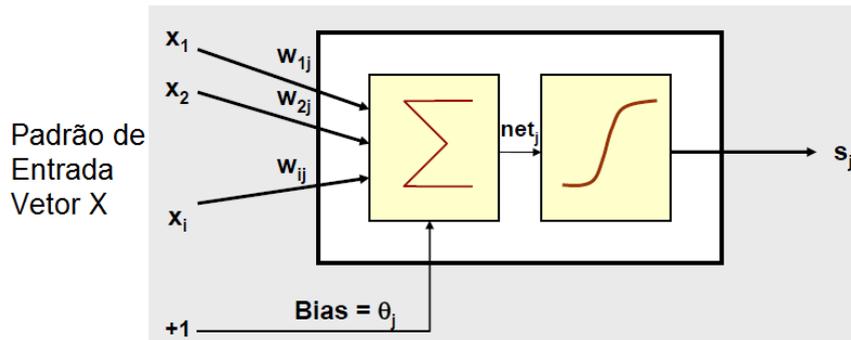


Figura 4. Modelo da propagação.

Adaptação dos Pesos, começando pela camada de saída:

$$w_{ij}(t + 1) = w_{ij}(t) + \alpha \delta_{pj} \theta_{pj} \quad (2)$$

Onde:

$w_{ij}(t)$  - Peso que parte da unidade  $i$  para a unidade  $j$  no tempo  $t$ .

$\alpha$ - Taxa de aprendizado

$\delta_{pj}$  - Erro para o padrão p na unidade j.

Na unidade de saída o erro é calculado por:

$$\delta_{pj} = (t_{pj} - \theta_{pj}) \theta_{pj} (1 - \theta_{pj}) \quad (3)$$

Nas unidades da camada escondida, é calculado por:

$$\delta_{pj} = \theta_{pj} (1 - \theta_{pj}) \sum_k \delta_{pk} w_{kj} \quad (4)$$

Uma observação importante é que valores altos para taxa de aprendizado implicam em grandes modificações nos pesos. O valor ideal de  $\alpha$  depende do problema. Este método de aprendizado foi o escolhido e utilizado neste trabalho.

## 2.2 RNA APLICADO PARA PREVISÃO

Para realizar a previsão, os métodos baseados em RNA geralmente, não utilizam o conhecimento das relações funcionais entre as variáveis temporais e as de carga. Na verdade, as RNA sintetizam o mapeamento entre as variáveis de entrada e de saída, a partir da extração do conhecimento de um conjunto de treinamento (base de dados), previamente tratado e analisado, apresentado durante a fase de aprendizagem da rede.

A base de dados é utilizada nas etapas de treinamento, validação e teste da RNA. Ela deve conter as informações necessárias e suficientes para o aprendizado da RNA. Em problemas de previsão de carga uma base de dados típica podem possuir dados relativos à carga tais como: valores da carga em um dado instante, valores de temperatura, índices econômicos, etc.

De um modo geral, observa-se que redes neurais aplicada a problemas de previsão de carga oferecem bons resultados devido a fatores sazonais, econômicos e culturais. Podendo também, se fazer uma associação com outras redes neurais ou fazer uso de outras técnicas heurísticas associadas. Dentre as diversas arquiteturas de RNA utilizadas em estudos de previsão de carga, as mais difundidas são as redes do tipo *Multilayer Perceptron* (MLP). O MLP é constituído por três ou mais camadas (uma camada de entrada e uma de saída com uma ou mais camadas intermediárias). A Figura 5 ilustra o diagrama de uma rede MLP, completamente conectada, que introduz o processamento temporal através da formatação dos dados de entrada.

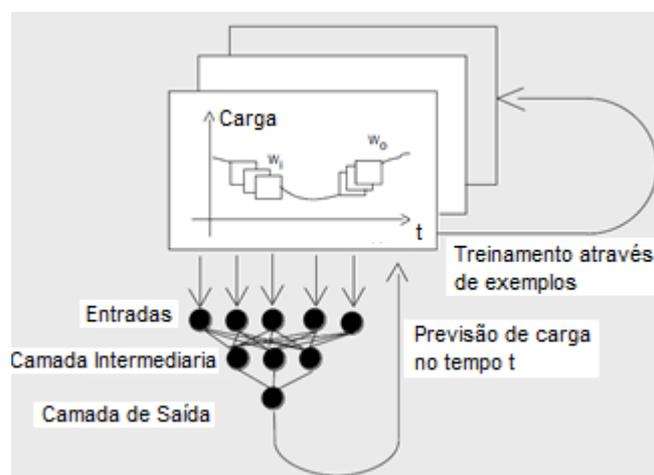


Figura 5. Esquema do MLP

Um artifício empregado para o processamento temporal é a utilização de janelas temporais, em que a entrada da rede é formada por trechos das sequências temporais dos dados como se fossem padrões estatísticos. Ou seja, a vantagem do uso das redes neurais é a capacidade da rede em se instruir somente através das relações existentes entre os padrões de entrada e de saída [4]. Normalmente, os padrões da janela de entrada são dados de cargas passadas. A saída é composta por valores da carga futura (um passo à frente). Este princípio é mostrado na Figura 6.

Além disso, as redes neurais possuem a capacidade de efetuar aproximações de funções contínuas com uma precisão desejada. Assim, podem ser vistas como métodos multivariados.

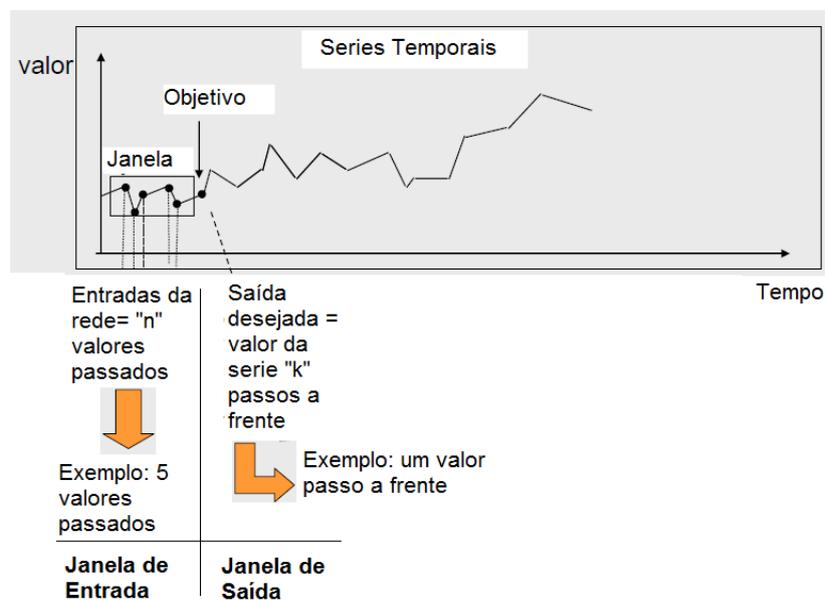


Figura 6. Padronização das janelas de entrada e saída.

## 2.3 ÍNDICES DE DESEMPENHO

Em problemas de previsão de séries temporais, uma importante tarefa é a de quantificar a qualidade da predição obtida, ou seja, comprovar a eficácia da solução descrita. Isso permite, comparar diversos algoritmos e diversas estruturas de modelos utilizando índices de desempenho. Além disso, possibilita comprovar a eficácia da configuração da rede neural adotada. Neste trabalho, utilizaram-se dois índices de avaliação utilizados em problemas de previsão demanda.

### 2.3.1 MAPE – ERRO PERCENTUAL ABSOLUTO MÉDIO

O erro percentual absoluto médio é a média de todos os erros absolutos percentuais, fornecendo uma indicação do tamanho médio do erro, expresso como uma porcentagem do valor observado, independentemente do erro ser positivo ou negativo [5].

Em [6], o MAPE é considerado como uma das medidas de erro mais usadas para se avaliar os métodos de previsão. O erro percentual absoluto médio pode ser calculado mediante a utilização da equação:

$$MAPE = \sum_{i=1}^n \left| \frac{Demanda_{esperada} - Demanda_{obtida}}{Demanda_{esperada}} \right| \times 100/n \quad (5)$$

### 2.3.2 EPM – ERRO PERCENTUAL MÁXIMO

O erro percentual máximo calcula qual foi o maior erro entre a saída da rede neural e os dados de saída de RNA. Este erro pode ser calculado da seguinte forma:

$$EPM = \text{máx} \left( \frac{Demanda_{esperada} - Demanda_{obtida}}{Demanda_{esperada}} \right) \times 100 \quad (6)$$

## 3 ATIVIDADES DESENVOLVIDAS

Como produto final do trabalho foi desenvolvido um software em Matlab para previsão de carga à médio e longo prazo. Tal software recebe dados das grandezas elétricas medidas nos alimentadores e subestações das diversas localidades do estado, todos fornecidos pela Energisa Paraíba.

Os dados fornecidos foram recebidos em formato do Microsoft Office Excel e tiveram de ser tratados antes de serem utilizados para a previsão com as redes neurais artificiais. Desta necessidade foi programada e realizada a Atividade 1, conforme descrita em seguida.

Após o tratamento prévio dos dados, diversos bancos de dados para treinamento das redes neurais tiveram que ser construídos, pois as RNAs podem ser configuradas para diversas topologias conforme será descrito na Atividade 2.

Por fim, na Atividade 3 foram treinadas as redes neurais e coletadas as de melhor desempenho.

Atividade 1 – Recepção dos dados, seleção das variáveis de interesse, criação do banco de dados de interesse e aplicação de algoritmos de correção dos dados coletados.

Atividade 2 – Criação do banco de dados para treinamento e teste das Redes Neurais Artificiais a partir dos dados corrigidos na Atividade 1.

Atividade 3 – Configuração da Rede Neural Artificial, algoritmo de análise automática dos resultados e coleta dos mesmos.

### 3.1 ATIVIDADE 1 – TRATAMENTO DOS DADOS

#### 3.1.1 DESCRIÇÃO

Nesta primeira atividade foram realizadas as seguintes tarefas:

- Revisão e análise dos arquivos originais (em Excel) para sua interpretação e extração de dados.
- Geração de arquivos utilizando uma linguagem de programação MATLAB®, para realizar o processo de leitura de dados.

- Geração de arquivos utilizando a linguagem de programação MATLAB®, para a geração de um banco de dados das potências máximas diária, semanal e mensal.
- Implementação de um algoritmo para a correção dos dados espúrios baseado nas propriedades estatísticas dos dados.
- Representação gráfica dos resultados por meio de figuras para cada alimentador e linhas dos cenários de análise: CTE (Cuité), PLV (Pedra Lavrada) e PCI (Picuí).

### 3.1.2 DESENVOLVIMENTO

#### 3.1.2.1 LEITURA DOS DADOS ORIGINAIS E CÁLCULO DAS POTÊNCIAS MÁXIMAS DE CADA DIA

A função “matrizS” foi desenvolvida para realizar a leitura dos arquivos em Excel fornecidos pela Energisa que possuem os valores de corrente, potência aparente, ativa e reativa, tensão, etc. Tais arquivos possuem leituras das grandezas citadas a cada quinze minutos. A função “matrizS” lê os arquivos do Excel e fornece como saída uma matriz “S” constituída das potências máximas de cada dia do ano. Além disso, a função fornece o dia da semana em que ocorreu o máximo, o mês correspondente àquele dia, o ano e a hora do dia em que esse máximo ocorreu. A coluna correspondente ao dia da semana é formada por números que vão de 1 (um) até 7 (sete) sendo o número 1 (um) correspondente ao Domingo. (Ver Figura 7).

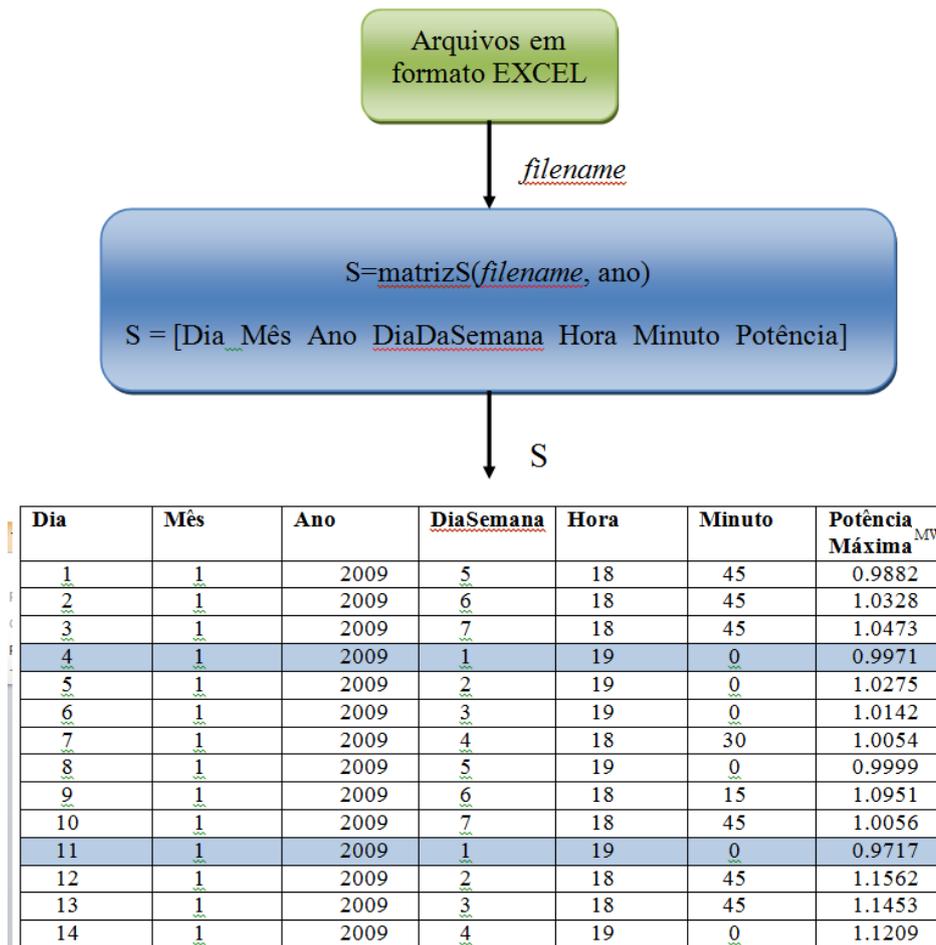
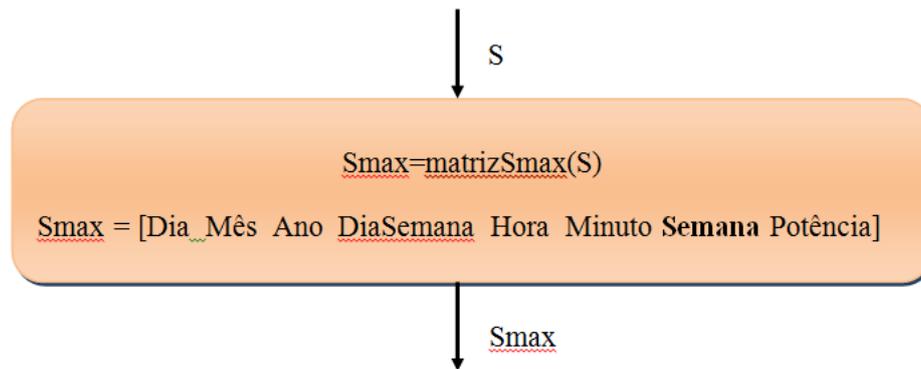


Figura 7. Fluxo de dados da função matrizS

### 3.1.2.2 CONSTRUÇÃO DAS POTÊNCIAS MÁXIMAS SEMANAIS

Uma segunda função “matrizSmax” foi desenvolvida para, a partir da matriz “S”, fornecida pela função “matrizS”, calcular o valor máximo da potência de cada semana do ano como também fornecer a data e hora em que a mesma ocorreu. A função “matrizSmax” retorna a matriz “Smax”. Os domingos (dia 1 da coluna DiaSemana) são responsáveis por duas referências: a de início da semana (primeiro dia da semana) e a do mês ao qual essa semana pertence (se o domingo pertence ao mês de Janeiro, por exemplo, então toda a semana pertencerá ao mês Janeiro). (Ver Figura 8).



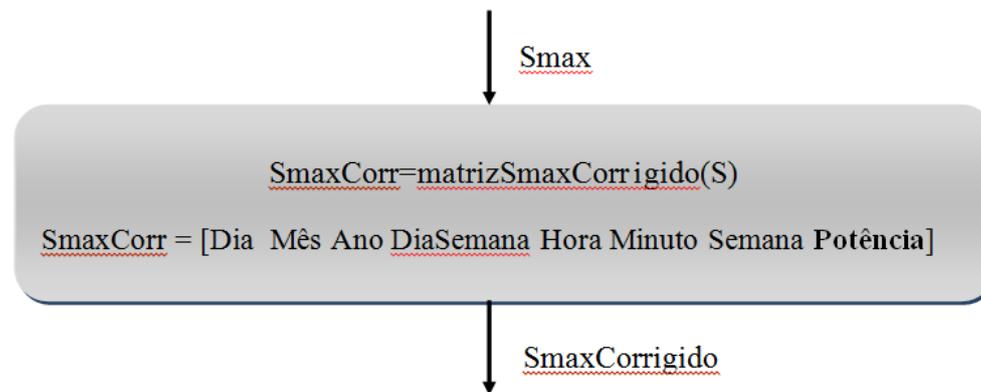
MW

Dia	Mês	Ano	DiaSemana	Hora	Min	Semana	Potência
9	1	2009	6	18	15	1	1.0951
12	1	2009	2	18	45	2	1.1562
22	1	2009	5	18	45	3	1.1094
27	1	2009	3	19	0	4	1.1575
7	2	2009	7	18	45	1	0.9975
14	2	2009	7	18	15	2	1.0500
19	2	2009	5	18	30	3	0.9829
28	2	2009	7	18	0	4	1.0557
6	3	2009	6	18	30	1	1.1083
11	3	2009	4	18	30	2	1.1378
21	3	2009	7	18	30	3	1.1179
25	3	2009	4	18	15	4	1.1215
2	3	2009	5	17	45	5	1.0204
11	4	2009	7	18	15	1	1.1273
16	4	2009	5	17	45	2	1.0784
21	4	2009	3	18	15	3	1.1354
28	4	2009	3	8	45	4	1.5778
5	5	2009	3	17	45	1	1.1115
15	5	2009	6	18	0	2	1.1347
15	5	2009	6	18	0	3	1.1347

Figura 8. Fluxo de dados da função "MatrizSmax"

### 3.1.2.3 CORREÇÃO DOS DADOS

Uma terceira função “matrizSmaxCorr” foi desenvolvida para a correção de dados anômalos. O algoritmo implementado tem como objetivo diminuir os picos das leituras tornando os dados mais suaves. A correção aplicada não deve interferir no objetivo final deste trabalho, pois se acredita que tais picos correspondem a erros de medição ou a eventos isolados que não correspondem ao funcionamento normal do sistema de fornecimento de energia. Portanto, as potências são avaliadas para sua correção por meio do algoritmo de MLE (*MaximumLikelihoodEstimation*) que utiliza as informações estatísticas das vizinhanças para corrigir a potência máxima em análise. (Ver Figura 9).



Dia	Mês	Ano	<u>DiaSemana</u>	Hora	Min	<b>Semana</b>	Potência
9	1	2009	6	18	15	1	1.0951
12	1	2009	2	18	45	2	1.1568
22	1	2009	5	18	45	3	1.1094
27	1	2009	3	19	0	4	1.1038
7	2	2009	7	18	45	1	0.9975
14	2	2009	7	18	15	2	1.0529
19	2	2009	5	18	30	3	0.9829
28	2	2009	7	18	0	4	1.0557
6	3	2009	6	18	30	1	1.1083
11	3	2009	4	18	30	2	1.1378
21	3	2009	7	18	30	3	1.1179
25	3	2009	4	18	15	4	1.1244
2	3	2009	5	17	45	5	1.0204
11	4	2009	7	18	15	1	1.1313
16	4	2009	5	17	45	2	1.0784
21	4	2009	3	18	15	3	1.1354
28	4	2009	3	8	45	4	1.3563
5	5	2009	3	17	45	1	1.1115
15	5	2009	6	18	0	2	1.1347
15	5	2009	6	18	0	3	1.1347

Figura 9. Fluxo de dados da função “matrizSmaxCorrigido”

Na Figura 10, observa-se a comparação entre os dados das potências máximas semanais originais e corrigidos por meio do algoritmo MLE dos dados de um dos alimentadores. O algoritmo visa diminuir os picos de valores de potência baseando-se nos valores anteriores e um respectivo desvio padrão. Na Tabela 1 é mostrado como foram corrigidos os dados. Cada potência examinada era comparada com a potência anterior e a posterior, desta forma, caso ela estivesse maior do que um desvio padrão estabelecido, ela deveria ser amenizada para passar a seguir um desvio padrão aceitável. (Ver ANEXOS A para mais detalhes sobre o algoritmo).

Tabela 1. Algoritmo MLE

Potência Máxima da Semana	$P_{1max}$	$P_{2max}$	$P_{3max}$
Média das máximas e desvio padrão da Semana	$P_1, \sigma_1$	$P_2, \sigma_2$	$P_3, \sigma_3$
Determinação dos valores de fusão		$P_{2MLE}, \sigma_{2MLE}$	

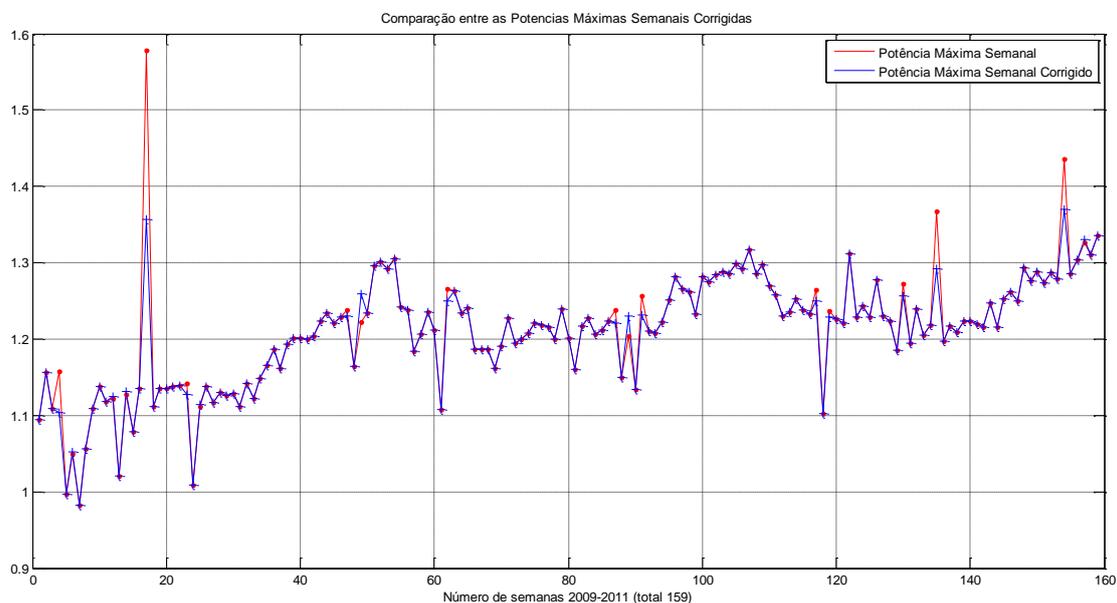


Figura 10. Comparação entre os dados corrigidos e os originais.

## 3.2 ATIVIDADE 2 – CRIAÇÃO DO BANCO DE DADOS PARA RNA

### 3.2.1 DESCRIÇÃO

Nesta atividade foram desenvolvidas as seguintes tarefas:

- Seleção das variáveis de interesse.
- Geração dos padrões de entrada e saída para treinamento das RNAs.
- Criação das matrizes de entrada e saída para treinamento e teste das RNAs.
- Cálculo da taxa de crescimento de energia.

### 3.2.2 DESENVOLVIMENTO

#### 3.2.2.1 VARIÁVEIS DE INTERESSE

De posse dos máximos semanais corrigidos, foi construído o banco de dados de treinamento das Redes Neurais. Este banco deve possuir uma estrutura normalmente utilizada para previsão conforme será descrita em seguida. A princípio foram selecionados os dados de interesse da matriz “SmaxCorrigido” que serão fornecidos na entrada da rede neural (ver Figura 11) dos anos de 2009 a 2012.

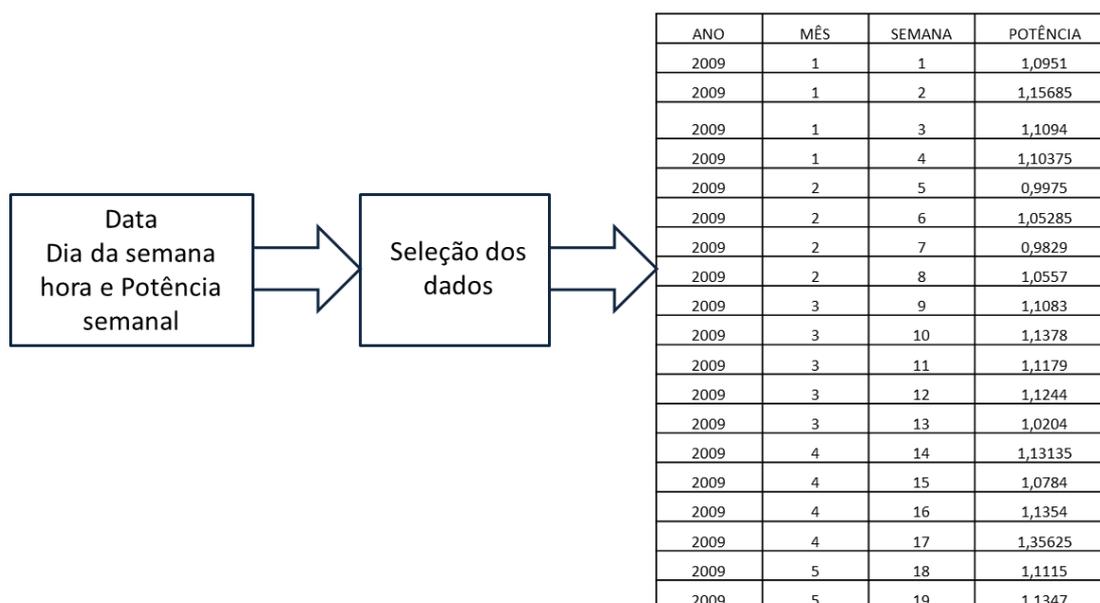


Figura 11. Seleção de dados para formação do banco de dados.

O ano, mês, semana e potência foram selecionados da matriz “SmaxCorrigido” e serão utilizados na geração de padrões de previsão. Além dessas variáveis, foram criados arquivos no Excel com as “Energias” mensais a partir dos dados de energias fornecidos pela empresa. Os dados originais possuem a energia consumida em cada mês desde 2008 a 2012. A taxa de crescimento anual do consumo de energia foi calculada pela função “calc\_taxa” e também foi uma variável de interesse a ser aplicada nas RNAs. Todas essas grandezas foram padronizadas para serem aplicadas à RNA em seu treinamento.

### 3.2.2.2 PADRONIZAÇÃO DAS VARIÁVEIS

As RNAs possuem diversas aplicações como, por exemplo: classificação, reconhecimento de padrões, previsão, etc. Para cada tipo de aplicação, as RNAs são treinadas por bancos de dados com formatação apropriada. No caso de previsão são aplicados dados passados na sua entrada e o dado futuro na sua saída de forma sequencial para que ela aprenda a prever. Como pode ser observado na Figura 12, pode-se arranjar os dados recebidos da concessionária de diversas formas. Como por exemplo, agrupar as 24 primeiras semanas e as 4 seguintes para formar, respectivamente, os dados de entrada e saída da rede neural. Fazendo isto de forma sequencial a RNA desenvolve a capacidade de prever valores futuros (4 semanas) diante da apresentação de valores passados (24 semanas) em sua entrada.

Dados Passados	Previsão
12 semanas	1 mês
24 semanas	
48 semanas	
12 semanas	3 meses
24 semanas	
48 semanas	
24 semanas	6 meses
48 semanas	
72 semanas	

Figura 12. Padrões utilizados para gerar o banco de dados

De posse das grandezas de interesse e da quantidade de dados passados e futuros a serem aplicados foi montado o banco de dados de entrada para treinamento conforme padrão apresentado na tabela da Figura 13. Como pode ser observado, a matriz possui, em cada coluna (que será uma entrada da RNA), um padrão com 24 valores de potência, 24 valores de energia, 4 valores de taxa de crescimento, 4 valores de semanas a prever e 4 valores correspondentes ao ano das semanas a prever. Totalizando 60 entradas. Segue a descrição de cada campo.

- **Demandas** – São os valores das demandas (potências máximas semanais) das últimas 24 semanas, é importante observar que a segunda coluna da matriz de entrada é a primeira deslocada de apenas um único valor, ou seja, para a primeira coluna foram selecionados os dados das primeiras 24 semanas do ano e para a

segunda foram pegos os dados da segunda semana do ano até a semana 25 e assim sucessivamente.

- **Energias** – São os valores de energia de cada semana seguindo a mesma lógica dos valores de Demanda. Para este campo é importante ressaltar que, como os valores de energia foram fornecidos mensalmente e a coluna é construída com valores semanais, foi necessário repetir os valores do mês para todas as suas semanas.
- **Taxa de crescimento de energia** – Esses valores foram calculados pela função “calc\_taxa” e acrescentados à matriz de entrada. Como pode ser observado, os valores foram repetidos neste trecho. Isso se deve ao fato de esses valores de taxa de crescimento serem correspondentes às taxas anuais, que, para semanas do mesmo ano, são iguais logicamente.
- **Semanas a prever** – Esse campo corresponde as semanas que serão previstas. Para a ilustração da Figura 13 são 25, 26, 27 e 28 na primeira coluna porque as semanas correspondentes às demandas anteriores são de 1 a 24 do corrente ano.
- **Ano das semanas a prever** – Esse campo apenas referência as semanas a serem previstas com seu respectivo ano. Este campo é necessário porque o campo “Semanas a prever” se repete para cada ano (2009 a 2012) e, assim, é necessário fazer uma distinção para que a rede neural entenda que a cada ano, apesar de o valor da semana ser igual, apresenta um valor diferente na saída.

Em cada ciclo de treinamento é apresentada à rede neural uma coluna da tabela da Figura 13 e é necessário mostrar uma coluna correspondente à saída, ou seja, é preciso mostrar à rede o que ela deveria estar prevendo, isso apenas no processo de treinamento já citado.

Para a saída, ou seja, o que a rede deve prever, a variável de interesse para o trabalho é a demanda. Assim, em posse de tais dados de entrada, a rede neural deverá prever apenas os valores de demanda das semanas a prever.

Foi construída, portanto, a matriz correspondente às saídas dada as entradas apresentadas na Figura 13. Ou seja, os valores de demanda das quatro semanas seguintes conforme Figura 14.

	Entrada 1	Entrada 2	Entrada 3	Entrada 4	Entrada 5	...	
Demanda 1-24	1,0951	1,15685	1,1094	1,10375	0,9975		
	1,15685	1,1094	1,10375	0,9975	1,05285		
	1,1094	1,10375	0,9975	1,05285	0,9829		
	1,10375	0,9975	1,05285	0,9829	1,0557		
	0,9975	1,05285	0,9829	1,0557	1,1083		
	1,05285	0,9829	1,0557	1,1083	1,1378		
	0,9829	1,0557	1,1083	1,1378	1,1179		
	1,0557	1,1083	1,1378	1,1179	1,1244	...	
	1,1083	1,1378	1,1179	1,1244	1,0204		
	1,1378	1,1179	1,1244	1,0204	1,13135		
	1,1179	1,1244	1,0204	1,13135	1,0784		
	1,1244	1,0204	1,13135	1,0784	1,1354		
	1,0204	1,13135	1,0784	1,1354	1,35625		
	1,13135	1,0784	1,1354	1,35625	1,1115		
⋮	⋮	⋮	⋮	⋮			
Energias 1-24	489,54	489,54	489,54	489,54	423,59		
	489,54	489,54	489,54	423,59	423,59		
	489,54	489,54	423,59	423,59	423,59		
	489,54	423,59	423,59	423,59	423,59		
	423,59	423,59	423,59	423,59	481,57		
	423,59	423,59	423,59	481,57	481,57		
	423,59	423,59	481,57	481,57	481,57	...	
	423,59	481,57	481,57	481,57	481,57		
	481,57	481,57	481,57	481,57	481,57		
	481,57	481,57	481,57	481,57	462,25		
	481,57	481,57	481,57	462,25	462,25		
	⋮	⋮	⋮	⋮	⋮		
	Taxa anual cresc. Energia	0,08525	0,08525	0,08525	0,08525	0,08525	
		0,08525	0,08525	0,08525	0,08525	0,08525	
0,08525		0,08525	0,08525	0,08525	0,08525	...	
0,08525		0,08525	0,08525	0,08525	0,08525		
Semanas a prever	25	26	27	28	29		
	26	27	28	29	30		
	27	28	29	30	31	...	
	28	29	30	31	32		
Anos das semanas a prever	2009	2009	2009	2009	2009		
	2009	2009	2009	2009	2009		
	2009	2009	2009	2009	2009	...	
	2009	2009	2009	2009	2009		

Figura 13. Matriz com o padrão de entrada para as RNAs

	Saída 1	Saída 2	Saída 3	Saída 4	Saída 5	...
Demandas	1,1383	1,1169	1,1297	1,1257	1,1292	
	1,1169	1,1297	1,1257	1,1292	1,1121	
	1,1297	1,1257	1,1292	1,1121	1,142	...
	1,1257	1,1292	1,1121	1,142	1,1219	

Figura 14. Matriz com dados de saída da rede neural para treinamento.

### 3.3 ATIVIDADE 3 – CONFIGURAÇÃO DAS RNA E TESTE

A cada ciclo de treinamento, foi apresentada à rede neural a primeira coluna de cada uma das matrizes da Figura 13 e da Figura 14, em seguida a segunda coluna e assim sucessivamente. Totalizando, para os anos de 2009 a 2012 cerca de 120 (70% do total) colunas de entrada e saída. Outras 51 (30% do total) colunas foram guardadas para testes, ou seja, após a etapa de treinamento, foram apresentadas à rede neural 51 entradas e foram coletadas as saídas que ela previu. A partir disso e das 51 colunas de saídas não apresentadas à rede neural foi avaliado o desempenho da rede treinada.

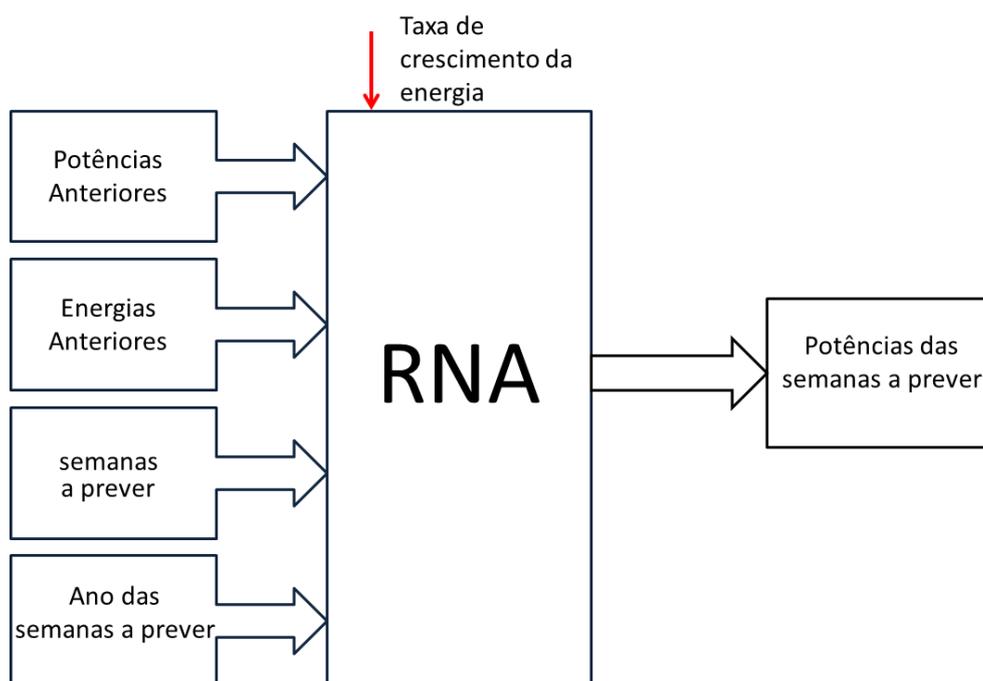


Figura 15. Rede neural artificial com suas entradas e saídas.

Para a etapa de treinamento, diversos computadores foram configurados em paralelo para que o maior número possível de topologias de redes pudessem ser testadas. Foram treinadas redes neurais com 2 e 3 camadas de neurônios, sendo esta última configuração a que apresentou melhores resultados. Todas as redes com três camadas foram treinadas com neurônios variando de 1 a 150 em cada uma das camadas.

Após o treinamento da rede, a mesma era submetida às entradas de testes. A saída era comparada às saídas reais (que ela deveria estar prevendo corretamente) e um índice de qualidade era gerado. Caso ele satisfizesse condições mínimas exigidas, a rede neural era automaticamente gravada para uso futuro.

## 4 RESULTADOS E DISCUSSÕES

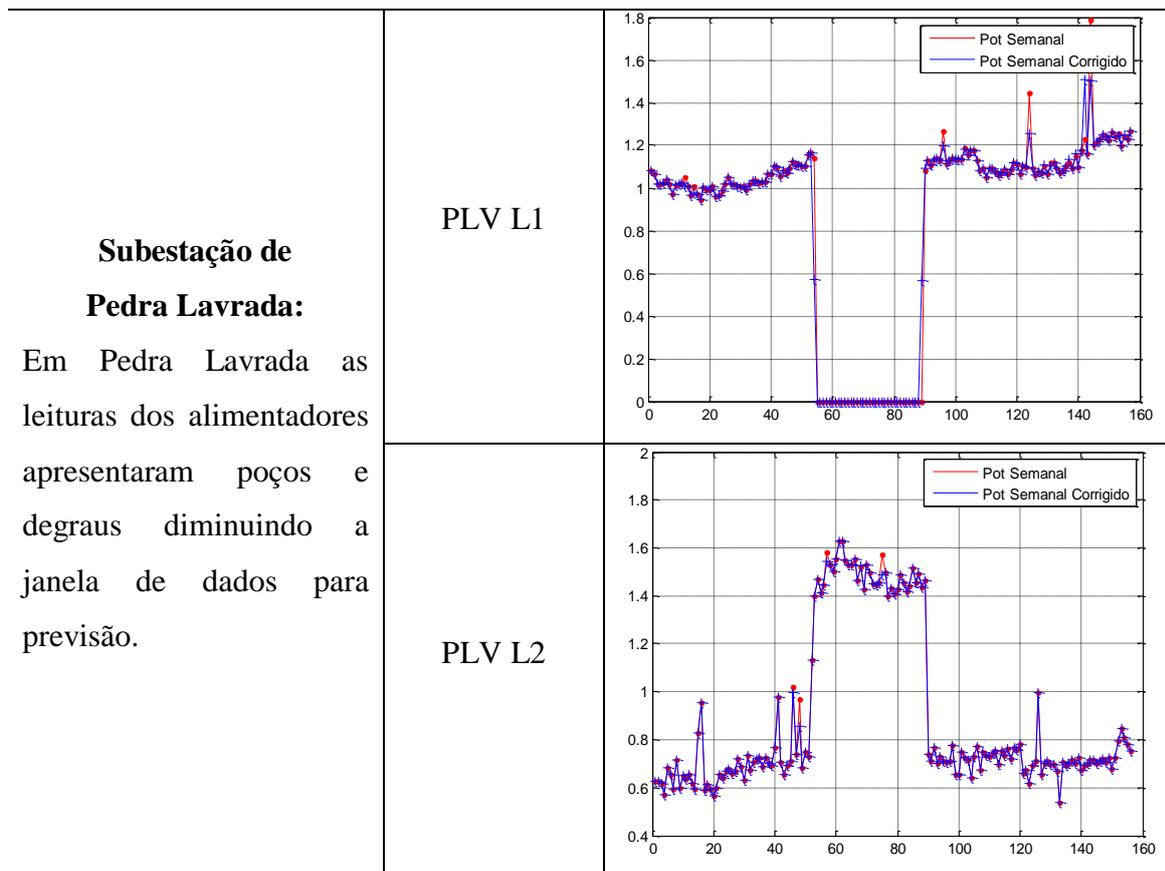
### 4.1 ERROS E PROBLEMAS NAS MEDIÇÕES

Na Atividade 1, foram detectados diversos problemas que tornaram complexa a realização da previsão de demanda ou diminuiram substancialmente a quantidade de dados a serem utilizados pelas redes neurais ou até mesmo utilizando outros métodos estatísticos. Tais problemas foram resultado de falhas de medição pelo equipamento ou falha do sistema de aquisição de dados. Ademais, outros problemas como medições nulas, constantes, vales e offset na curva de potências tornaram o comportamento esdrúxulo e imprevisível. Seguem nas figuras da Tabela 2 os problemas mais comuns encontrados nos dados recebidos.

Tabela 2. Problemas comuns de medição

Problema	Alimentador	Gráfico ( <i>semana</i> × <i>MW</i> )
<p><b>Subestação de Cuité:</b> Degraus e vales podem ser observados. Essas transferências de carga ou problemas de medições aumentam a dificuldade de aprendizado da rede e diminuem a confiabilidade da previsão</p>	CTE L1	
	CTE L2	

	CTE L3	
<p><b>Subestação de Picuí:</b> Em Picuí são observados diversos valores constantes ao longo da medição. Para esses locais, a previsão torna-se impossível pois não há o que aprender. Tais erros podem ser devido ao sistema de aquisição que incluem os sensores.</p>	PCI L1	
	PCI L2	
	PCI L3	



Desta maneira os alimentadores CTE L1, CTE L2, CTE L3, PCI L1, PCI L2, PCI L3, PLV L1 e PLV L2 foram descartados para a implementação dos sistemas de previsão. Por tanto, o treinamento e teste foram realizados nos seguintes pontos de medição:

- CTE-L4 – Nova Floresta (Figura 16)
- PLV-L3 – Nova Palmeira (Figura 18)
- Subestação CTE (Figura 17)
- Subestação PLV (Figura 19)
- Subestação Santa Cruz II (69/13.8 kV) (Figura 20)

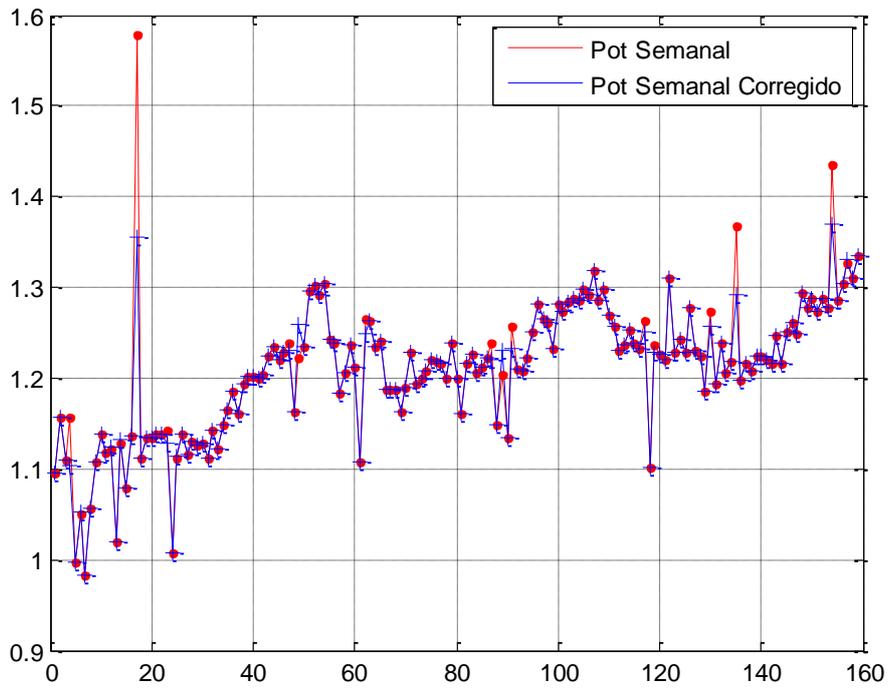


Figura 16. Potencias máximas semanais do alimentador de Nova Floresta

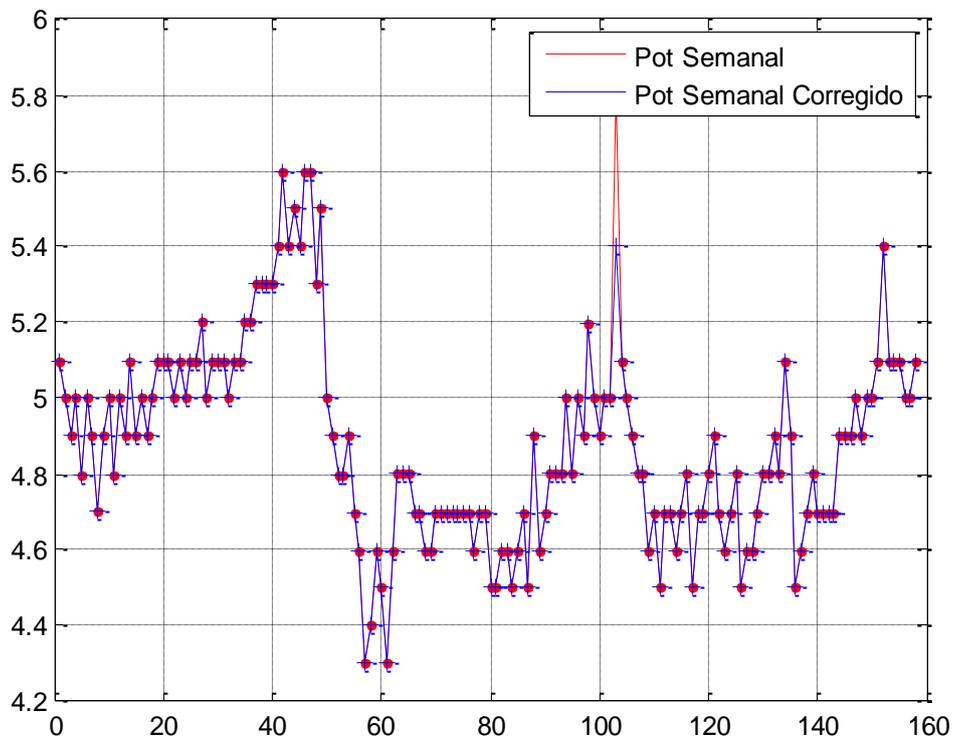


Figura 17. Potencias máximas semanais da Subestação de Cuité

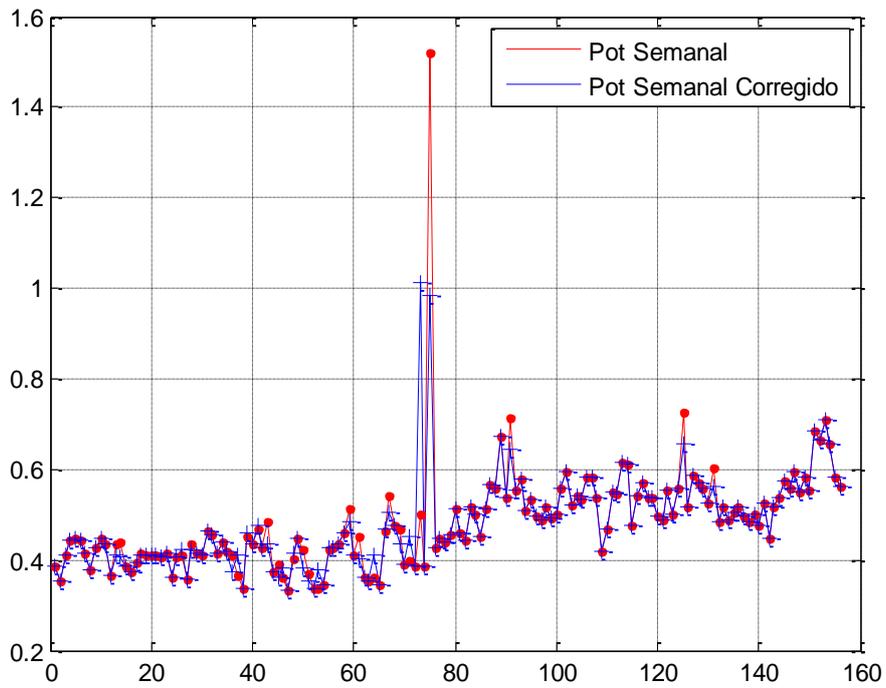


Figura 18. Potencias máximas semanais do alimentador de Nova Palmeira

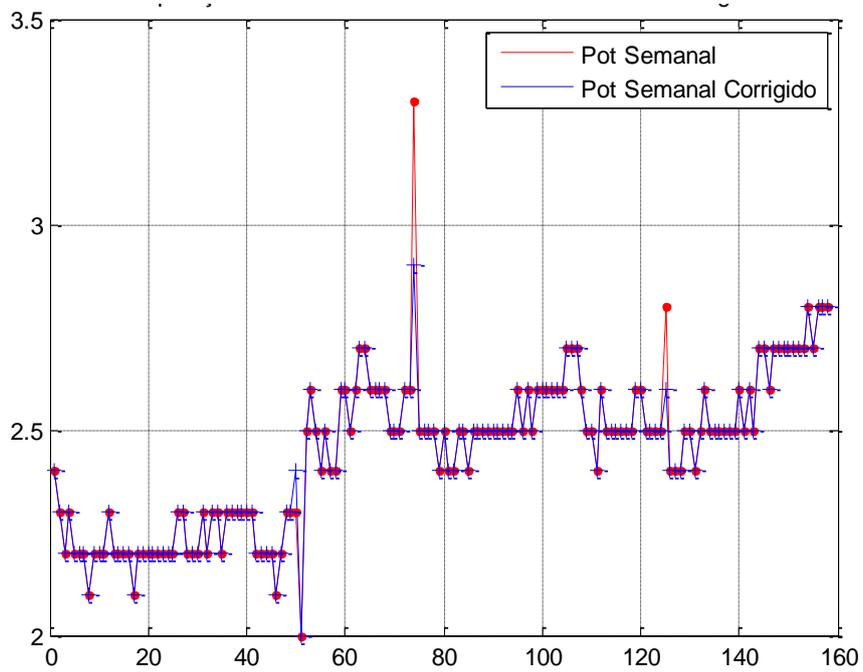


Figura 19. Potencias máximas semanais da Subestação de Pedra Lavrada

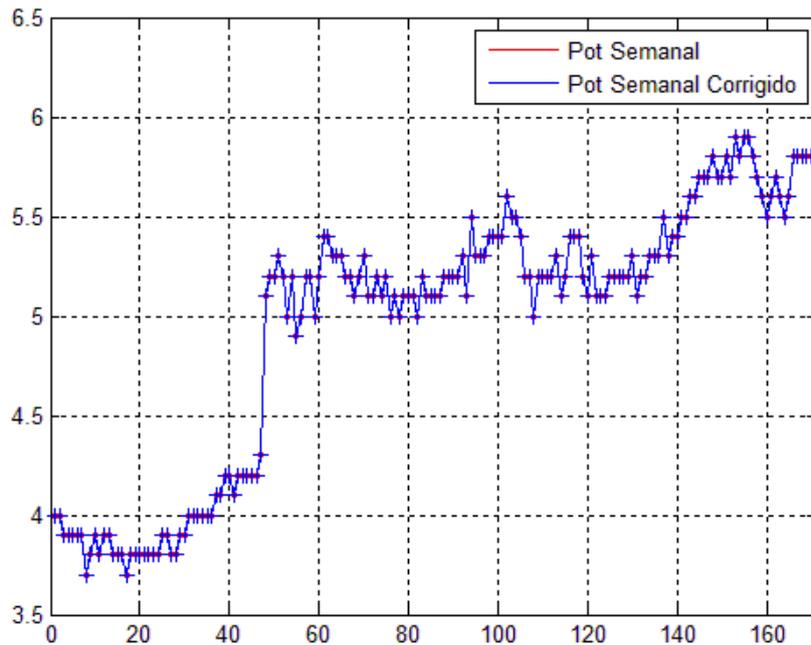


Figura 20. Potencias máximas semanais da Subestação de Santa Cruz II

## 4.2 TREINAMENTO E TESTE

Para este trabalho foram treinadas e testados o alimentador L3 de Pedra Lavrada, os alimentador L4 de Cuité, a Subestação de Pedra Lavrada, a subestação de Cuité e a Subestação de Santa Cruz II de 69/13.8 kV.

Na parte do treinamento foram escolhidas três camadas de neurônios, cada uma com uma quantidade variando de 1 a 150. Com isso, para cada rede, foram feitos 150<sup>3</sup> testes (3.375.000). Para os primeiros casos de testes, grande esforço computacional foi requerido pois não se tinha ideia do comportamento dos dados. A partir das primeiras experiências foi possível perceber que os melhores resultados surgiam quando a primeira camada de neurônios ficava entre um e vinte. Assim, nos outros casos, mais máquinas eram colocadas para processar esses valores obtendo resultados com baixos índices de distorção em menor tempo.

A Figura 21 mostra um dos resultados do treinamento para o alimentador L4 de Cuité. A configuração da rede ficou com 1 (um) neurônio na primeira camada, 112 (cento e doze) na segunda e 25 (vinte e cinco) na terceira. Na figura é possível observar três curvas, a curva em azul corresponde aos dados de potência máxima semanal

fornecidos pela Energisa, ou seja, dados reais que ocorreram naquela localidade. Em vermelho estão as saídas da rede neural ao ser submetida às mesmas entradas que em seu treinamento (70% dos dados totais). E, finalmente, em verde estão as saídas da rede neural após ser submetida a entradas inéditas (que não foram usadas em seu treinamento – os outros 30% dos dados). A curva em verde representa a real capacidade de previsão da rede e deveria seguir a parte em azul que a sobrepõe.

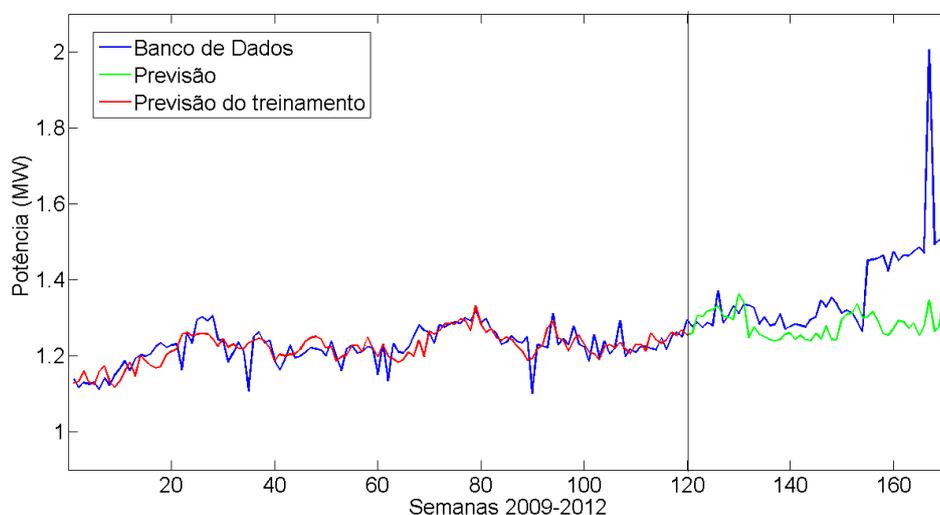


Figura 21. Previsão de carga para CTEL4

Na Figura 22 é mostrada com mais detalhes a curva de previsão em vermelho (a mesma verde da Figura 21) e a curva real de demanda em azul. Pode-se perceber neste caso que a rede neural conseguiu aprender bem o treinamento e ignorou picos e vales espúrios de medição. Na parte de previsão mesmo, pode-se perceber que para aproximadamente trinta e cinco semanas de previsão, a rede conseguiu prever a carga com erro máximo inferior a 5%, após isso a rede se perde devido à uma inconstância nos dados reais. O degrau é considerado um problema de medição ou uma operação anormal do sistema.

De forma análoga foram analisados os resultados para a subestação de Pedra Lavrada, alimentador L3 de Pedra Lavrada, a subestação de Cuité e a subestação de Santa Cruz II.

Na Figura 23 e Figura 23 é mostrado o desempenho da rede neural na previsão de carga para a subestação de Cuité. Pode-se perceber que apesar de os dados reais apresentarem irregularidades como picos e vales, a rede neural conseguiu aprender as tendências periódicas e fechou o ano de previsão com um erro percentual máximo

médio de 1,5%. É possível perceber também que a rede não conseguiu aprender bem o início do treinamento mas obteve um bom desempenho principalmente entre as semanas 120 (cento e vinte) e 150 (cento e cinquenta).

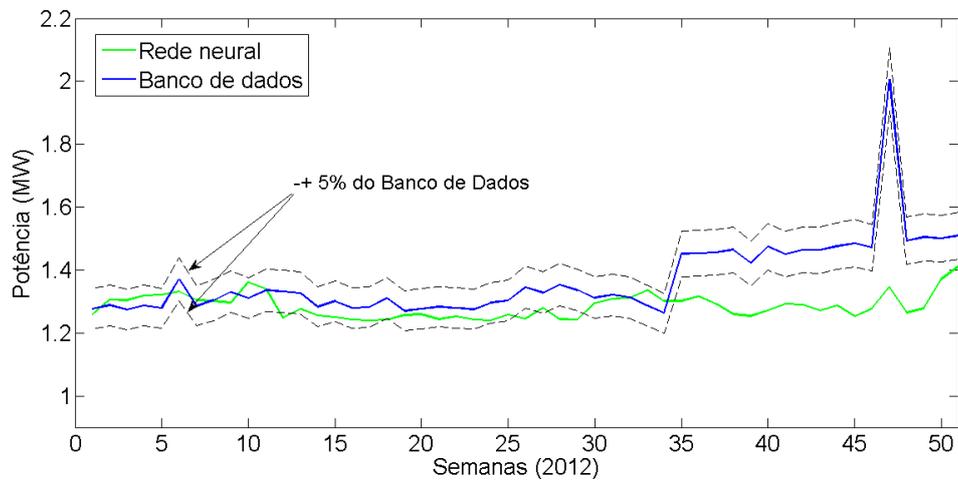


Figura 22. Previsão da rede neural para CTEL4

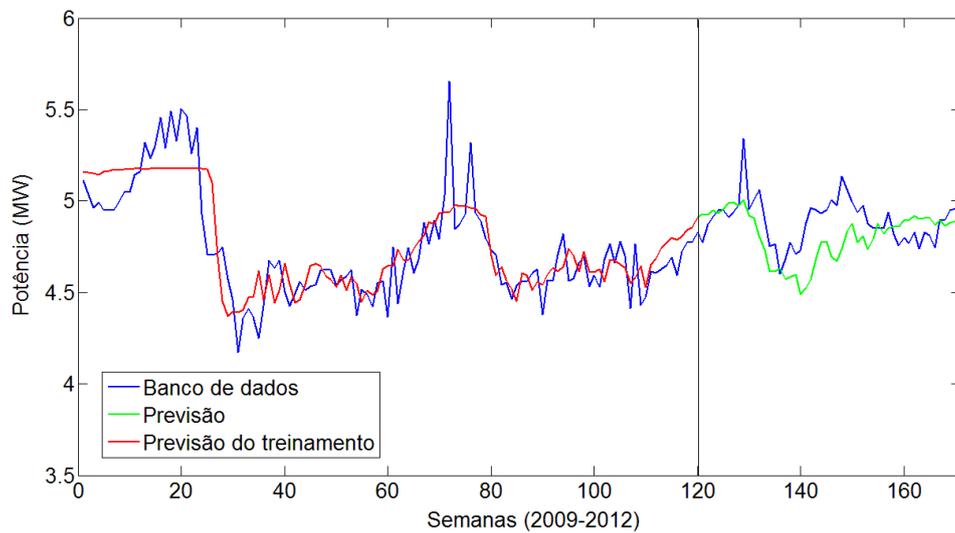


Figura 23. Previsão para a subestação de Cuité

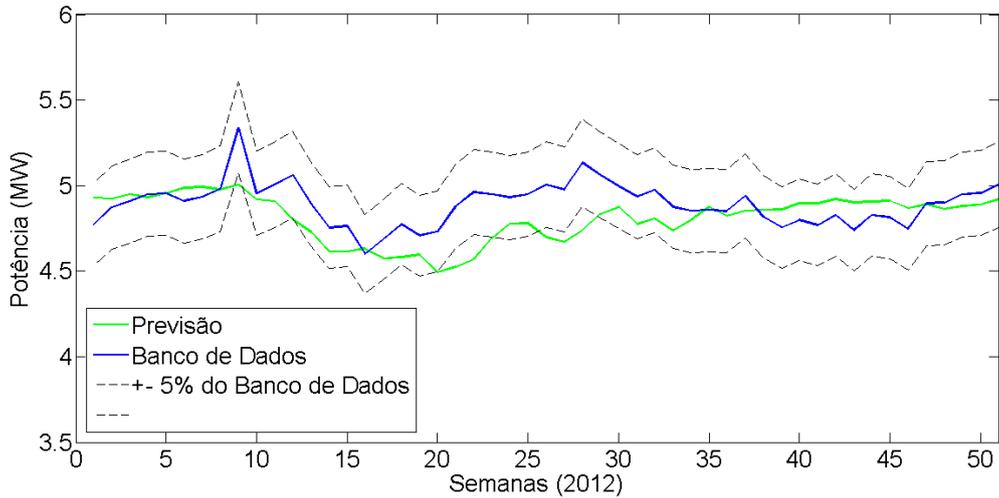


Figura 24. Previsão de carga para a subestação de Cuité

Na Figura 25 é apresentado o resultado da previsão do alimentador L3 da subestação de Pedra Lavrada que alimenta a cidade de Nova Palmeira. Pode-se observar através da Figura 25 e da Figura 26 que a rede neural do alimentador L3 de Pedra Lavrada conseguiu seguir a tendência de crescimento da demanda, entretanto, com margem de erro aproximadamente de 10%. Na fase de treinamento é possível observar que a rede não acompanhou bem as variações reais, mas, aprendeu a tendência de crescimento (ver Figura 25).

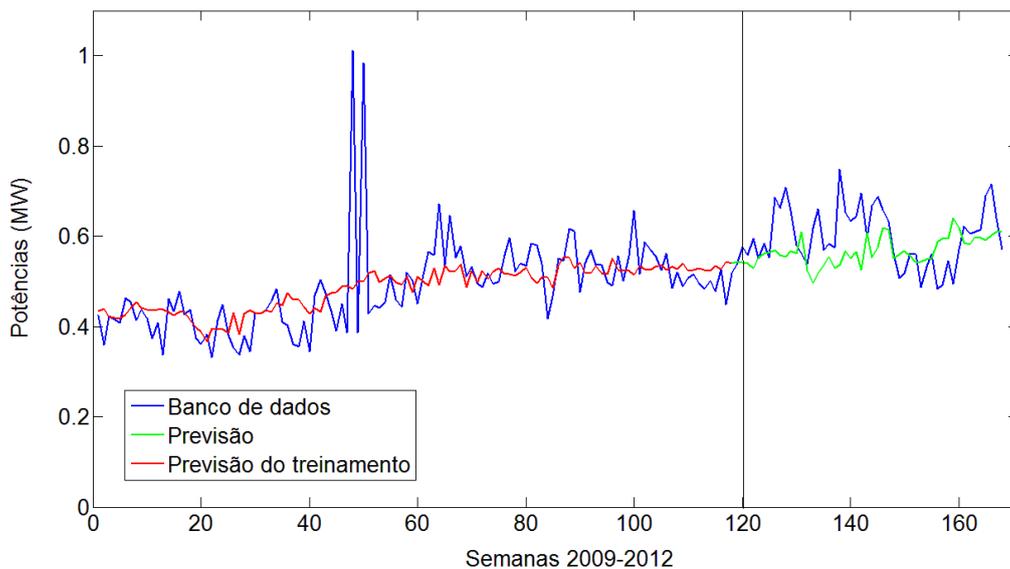


Figura 25. Previsão de carga para PLVL3

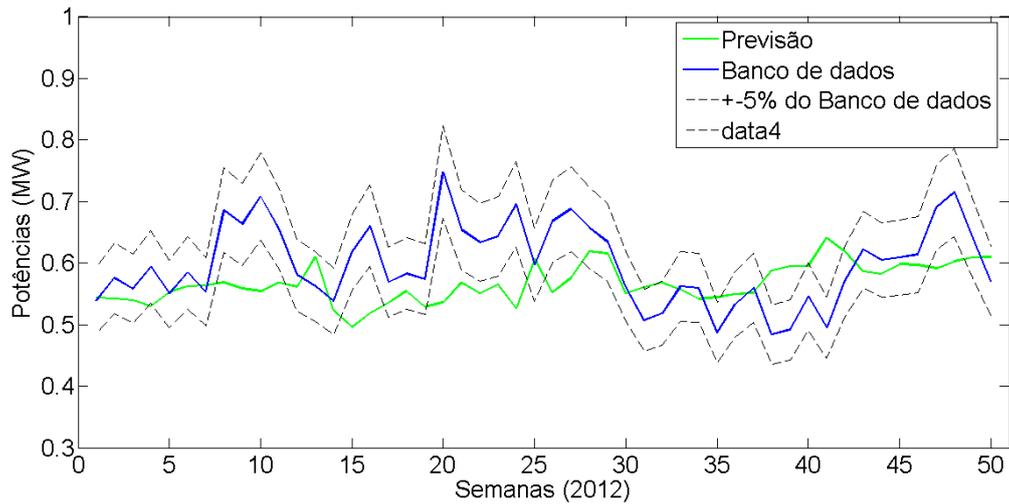


Figura 26. Previsão da rede neural para PLVL3.

A Figura 27 mostra os resultados do treinamento com os dados da subestação de Pedra Lavrada. Para esta subestação, foi obtido um MAPE de 9%. Apesar de os dados não estarem em condições ideais, apresentando diversos patamares em sua curva de medição, a rede neural conseguiu aprender a tendência de crescimento e sua previsão conseguiu alcançar índices de erro menores do que 5% como pode ser observado na Figura 27 e na Figura 28.

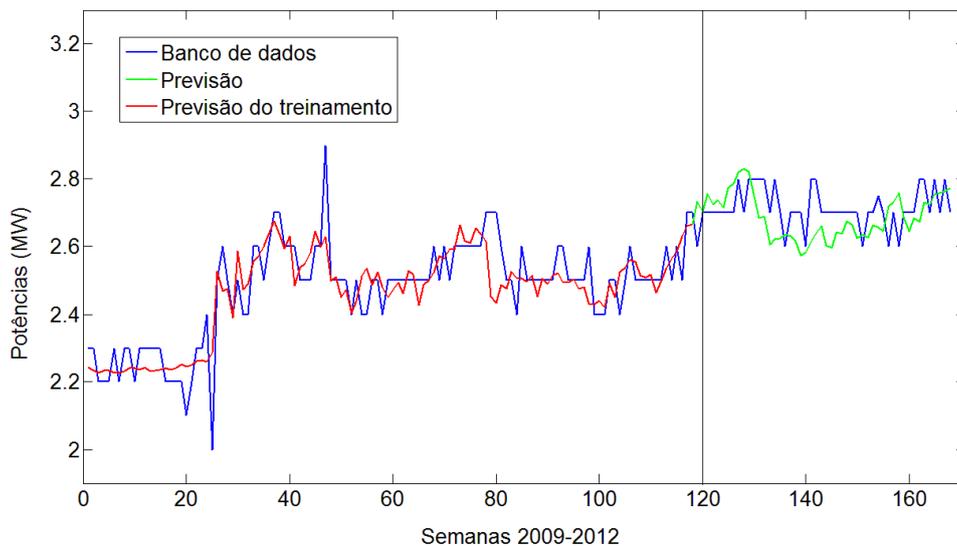


Figura 27. Previsão para a subestação de Pedra Lavrada

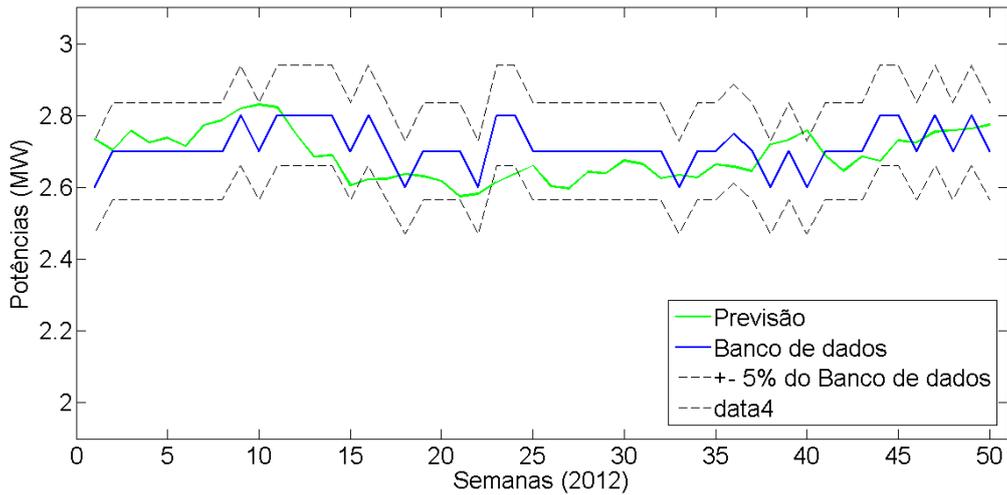


Figura 28. Previsão de carga para a Subestação de Pedra Lavrada

Para a Subestação de Santa Cruz II foi obtido um MAPE de 2.91% e conforme Figura 29 e Figura 30 pode-se observar que o comportamento da previsão para um período de um ano seguiu a tendência de crescimento e se estabelece dentro de um intervalo de aproximadamente 5% no máximo do valor que deveria seguir, apesar de os dados apresentarem comportamento duvidoso (patamares e picos constantes).

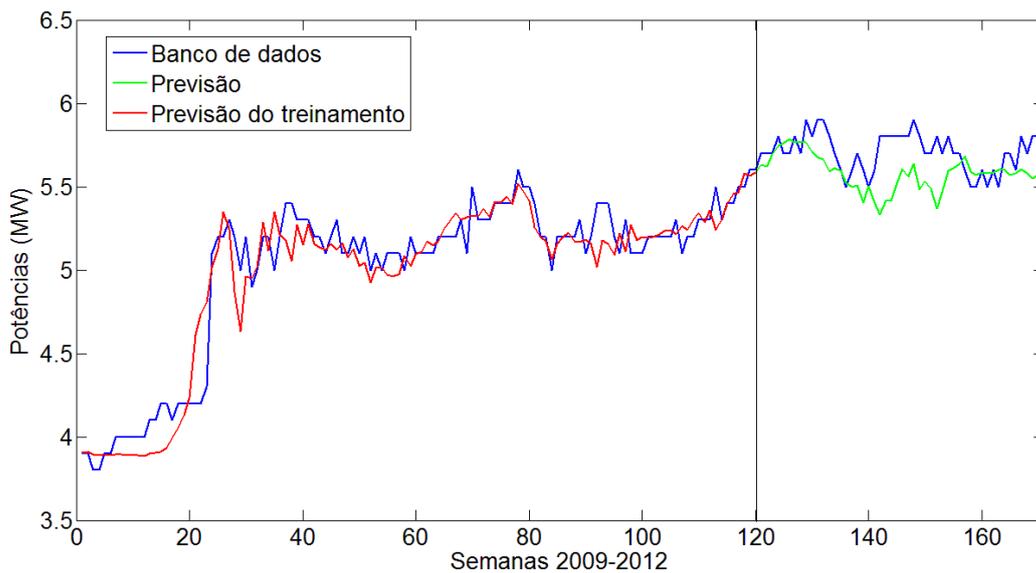


Figura 29. Previsão para a subestação de Santa Cruz II

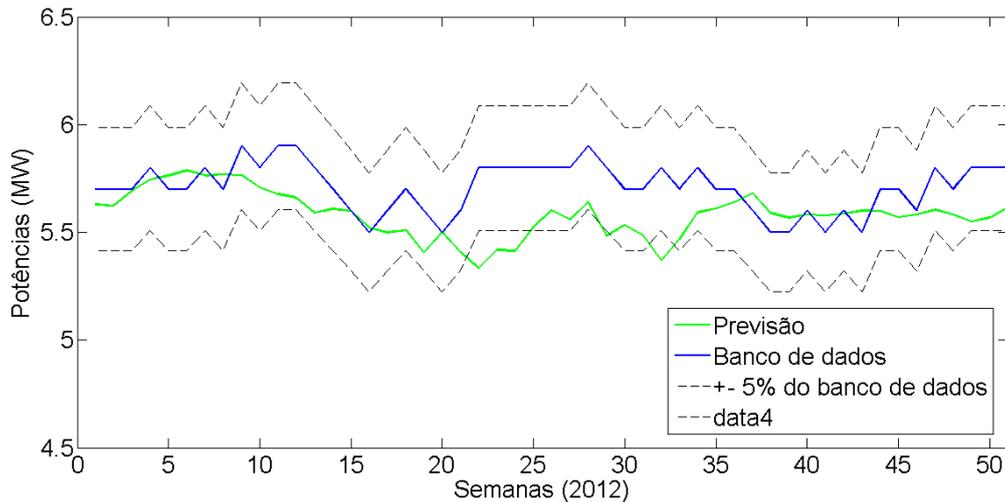


Figura 30. Previsão de carga para a Subestação de Santa Cruz II apenas em 2012

Finalmente, os resultados dos sistemas de previsão foram consolidados na Tabela 3. Nesta tabela se analisa o desempenho das redes neurais artificiais encontradas de acordo com os índices de avaliação MAPE e ERRO MÁXIMO PERCENTUAL. Pode-se observar que o melhor resultado obtido foi da Subestação de Cuité que, apesar de os dados possuírem certa anormalidade, eles também apresentaram uma sazonalidade e uma periodicidade que foi absorvida pela rede neural e a mesma foi regular durante toda a previsão. Diferentemente de outros casos em que a rede neural previu bem nas primeiras semanas, mas perdeu desempenho conforme o tempo. Outro comportamento comum, como é o caso de PLVL3 da Figura 25 em que as variações na carga não foram percebidas pela rede neural, entretanto ela conseguiu prever o aumento médio de demanda, por isso seu MAPE foi baixo, mas seu ERRO MÁXIMO PERCENTUAL foi relativamente alto. Um dos desempenhos mais baixos foi encontrado para o alimentador CTEL4 em que os dados apresentaram um degrau nas últimas semanas o que fez aumentar os índices de avaliação. Para os outros casos foram obtidos baixos índices o que representam um bom treinamento e bons dados.

Os resultados obtidos, de maneira geral, apresentam bons desempenhos, já que foram utilizadas para estas simulações apenas vinte e quatro entradas de potência e suas correspondentes vinte e quatro entradas de energia na entrada da rede neural, como saída foram aplicadas quatro semanas. Esses valores foram escolhidos com base na quantidade de dados disponibilizados, um banco de dados com um maior número de anos permitiria melhorar o desempenho do sistema de previsão.

Por fim, com o objetivo de aumentar a eficiência das redes neurais, tem-se pensado para trabalhos futuro, uma maior variação nos parâmetros de configuração da rede. Há diversos fatores de aprendizado que podem ser alterados, mas para isso, é preciso adotar um novo sistema de software, como por exemplo, linguagem C de programação e utilização de Clusters para agilizar o processo de treinamento.

*Tabela 3. Resumo dos resultados apresentados*

	<b>Número de semanas para treinamento</b>	<b>Número de semanas para teste</b>	<b>Topologia da RNA</b>	<b>MAPE (%)</b>	<b>Erro Máximo (%)</b>
Subestação CUI-CTE	120 (70%)	51 (30%)	3 camadas 125-2-1	1.5%	6.6%
CTE-L1 CTE-L2 CTL-L3	×	×	×	×	×
CTE-L4	120 (70%)	51 (30%)	3 camadas 112-61-25	6.5%	32%
Subestação PICUI-PCI	×	×	×	×	×
PCI-L1 PCI-L2 PCI-L3	×	×	×	×	×
Subestação PEDRA LAVRADA-PLV	120 (70%)	51 (30%)	3 camadas 24-7-1	2.59%	6.6%
PLV-L1 PLV-L2 PLV-L4	×	×	×	×	×
PLV-L3	120 (70%)	51 (30%)	3 camadas 113-9-75	9.8%	29%
Subestação SANTA CRUZ II	120 (70%)	51 (30%)	3 camadas 95-17-1	2.91%	9.65%

## 5 CONCLUSÃO

A realização do estágio supervisionado foi de extrema valia para complementar minha formação profissional. O contato com engenheiros mais experientes e que tratam problemas reais diretamente me proporcionou uma visão diferente sobre a utilidade e função do engenheiro eletricitista na sociedade. A aplicação dos conhecimentos adquiridos em sala de aula foram diretamente aplicados em um problema real, isto também me fez adquirir uma nova visão sobre o que aprendi na universidade. A partir de agora os conteúdos que tenho em mente vão me servir para pensar em soluções ou até mesmo procurar problemas que podem ser solucionados.

Para este trabalho foram aplicados os conhecimentos de Redes Neurais Artificiais e pôde-se constatar a utilidade de tal método para a previsão de carga. Através desta previsão a empresa consegue planejar melhor a compra e manutenção de equipamentos para garantir o fornecimento de energia e planejar de forma eficiente os seus gastos.

Através do estágio, descobri que existem diversos problemas técnicos que, muitas vezes possuem soluções simples, entretanto, quando se está na academia, não temos acesso aos problemas cotidianos de profissionais da engenharia e assim, essas questões são desconhecidas. Isto se deve ao fato de que no curso não temos um contato grande com empresas e profissionais atuantes no mercado. Entretanto, quanto a parte técnica, para este trabalho, não houve grandes problemas, apenas despertou a curiosidade de conhecer mais sobre a operação prática do sistema de transmissão.

O relatório possui várias ideias para trabalhos futuros, inclusive que se estabeleçam projetos a longo prazo para que se tenha mais tempo de se dedicar aos problemas individuais dos pontos de medição. Este estágio serviu para desvendar os problemas que terão que ser enfrentados por quem dará continuidade ao projeto bem como novas frentes de ataque e para mostrar que os métodos utilizados são de excelente eficácia e confiabilidade.

O estágio me fez despertar essa vontade: descobrir os problemas técnicos reais de hoje para tentar achar as soluções nos conhecimentos que adquiri na graduação.

# BIBLIOGRAFIA

- [1] HAYMAN, S. TheMcCulloch-Pitts model. 1999. IJCNN '99. International Joint Conference on volume 6, Date: Jul 1999, Pages: 4438 - 4439 vol.6.
- [2] OSORIO, F. S. Um Estudo sobre Reconhecimento Visual de Caracteres Através de Redes Neurais. Porto Alegre: CPGCC, 1991. Dissertação de Mestrado.
- [3] FERNANDES, L. G. Utilização de Redes Neurais na Análise e Previsão de Séries Temporais. Porto Alegre: CPGCC, 1995. Dissertação de Mestrado.
- [4] LOPES, MLM. Desenvolvimento de redes neurais para previsão de cargas elétricas de sistemas de energia elétrica. 2005. 149 f. 2005. Tese de Doutorado. Tese (Doutorado em Engenharia Elétrica)– Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira.
- [5] LOPES, R.D. Previsão de Autopeças: Estudo de Caso em uma Concessionária de Veículos. Dissertação de Mestrado. UFSC, 2002.
- [6] LEWIS, C. D. Demand Forecasting and Inventory Control. New York: Wiley, 1997.

# ANEXO A

## ALGORITMO Maximum Likelihood Estimation (MLE)

O algoritmo de estimação de máxima probabilidade consiste em analisar a função de probabilidade (*likelihoodfunction*) de um conjunto de amostras redundantes quantitativas e estimar os parâmetros que maximizem esta função. Este algoritmo está baseado na combinação da evidência contida no sinal com o conhecimento *a priori* da distribuição de densidade de probabilidade do processo. O estimador de máxima probabilidade toma como entrada o conjunto de observações das múltiplas fontes de informação e, usando um modelo probabilístico do processo (e.g., Gaussiano), estima os parâmetros desconhecidos. A exatidão da estimação depende da informação disponível e da eficiência do estimador.

Para este propósito, considera-se um conjunto de amostras de tamanho  $n$ , definidas por  $x_1, \dots, x_n$ , com funções de densidade de probabilidade independentes. A função de probabilidade (*likelihoodfunction*) do conjunto é dado por:

$$K = f_1(\bar{x})f_2(\bar{x})\dots f_n(\bar{x}) \quad (1)$$

em que  $f_1, \dots, f_n$  são as funções de densidade de probabilidade e  $\bar{x}$  é o melhor valor estimado que maximiza  $K$ .

Considera-se que as funções de densidade de probabilidade têm uma distribuição normal com parâmetros conhecidos, dada por:

$$f(x) = \frac{1}{u\sqrt{2\pi}} e^{-[(x-\bar{x})^2/2u^2]} \quad (2)$$

em que  $u$  é o desvio padrão de  $x$ .

Substituindo (2) em (1), tem-se:

$$K = \prod_{i=1}^n \frac{1}{u_i \sqrt{2\pi}} e^{-\left[\frac{(\bar{x}-x_i)^2}{2u_i^2}\right]} \quad (3)$$

Tomando o logaritmo de (3):

$$\ln K = \ln\left[\frac{1}{\sqrt{2\pi}^n \prod_{i=1}^n u_i}\right] - \sum_{i=1}^n \frac{(\bar{x} - x_i)^2}{2u_i^2} \quad (4)$$

O valor de  $\bar{x}$  que maximiza (4) é conhecido como a estimaco de mxima probabilidade, e pode ser calculado por:

$$\frac{\partial \ln K}{\partial \bar{x}} = 0 \quad (5)$$

Resolvendo (5) para  $\bar{x}$ , tem-se:

$$\bar{x} = \frac{1}{\Gamma u_1^2} x_1 + \frac{1}{\Gamma u_2^2} x_2 + \dots + \frac{1}{\Gamma u_n^2} x_n \quad (6)$$

$$\text{com } \Gamma = \left( \frac{1}{u_1^2} + \frac{1}{u_2^2} + \dots + \frac{1}{u_n^2} \right).$$

A equaco (6) define um procedimento de fuso de dados para estimar o valor de fuso  $x_F = \bar{x}$ , a partir dos  $n$  valores medidos  $x_1, x_2, \dots, x_n$ , levando em consideraco os valores dos desvios padro  $u_1, u_2, \dots, u_n$  de cada medida, respectivamente.

Considerando-se o resultado de fuso  $x_F$  utilizando a tcnica de estimaco de mxima probabilidade (Eq. 6),  realizada a anlise da propagao de incertezas associadas s grandezas medidas  $x_1, x_2, \dots, x_n$ , para determinar a incerteza final do processo de fuso  $u_{x_F}$ .

$$x_F = \frac{1}{\Gamma u_{x_1}^2} x_1 + \frac{1}{\Gamma u_{x_2}^2} x_2 + \dots + \frac{1}{\Gamma u_{x_n}^2} x_n \quad \text{com } \Gamma = \left( \frac{1}{u_{x_1}^2} + \frac{1}{u_{x_2}^2} + \dots + \frac{1}{u_{x_n}^2} \right) \quad (7)$$

$$u_{x_F}^2 = \left( \frac{\partial x_F}{\partial x_1} u_{x_1} \right)^2 + \left( \frac{\partial x_F}{\partial x_2} u_{x_2} \right)^2 + \dots + \left( \frac{\partial x_F}{\partial x_n} u_{x_n} \right)^2 \quad (8)$$

$$u_{x_F}^2 = \left( \frac{1}{\Gamma u_{x_1}^2} u_{x_1} \right)^2 + \left( \frac{1}{\Gamma u_{x_2}^2} u_{x_2} \right)^2 + \dots + \left( \frac{1}{\Gamma u_{x_n}^2} u_{x_n} \right)^2 \quad (9)$$

$$u_{x_F}^2 = \frac{1}{\Gamma^2} \left( \frac{1}{u_{x_1}^2} + \frac{1}{u_{x_2}^2} + \dots + \frac{1}{u_{x_n}^2} \right) \quad (10)$$

$$u_{x_F}^2 = \frac{1}{\Gamma} = \frac{1}{u_{x_1}^2} + \frac{1}{u_{x_2}^2} + \dots + \frac{1}{u_{x_n}^2} \quad (11)$$

Finalmente, a incerteza final  $u_{x_F}$  associada a  $x_F$  é calculada como:

$$\frac{1}{u_{x_F}^2} = \frac{1}{u_{x_1}^2} + \frac{1}{u_{x_2}^2} + \dots + \frac{1}{u_{x_n}^2} \quad (12)$$

Pode-se observar que a incerteza final  $u_{x_F}$  é menor do que as incertezas independentes  $u_{x_1}, u_{x_2}, \dots, u_{x_n}$ , isto é, o resultado da fusão apresenta a menor incerteza possível.

Para exemplificar este procedimento, considera-se que uma grandeza é medida utilizando-se dois sensores diferentes, em que o primeiro sensor tem uma incerteza  $\sigma$  e o segundo, uma incerteza  $2\sigma$ . Utilizando o procedimento de fusão de máxima probabilidade, tem-se uma incerteza final de fusão de  $0,89\sigma$ , com um nível de confiança de 68%, como ilustrado na Figura 1.

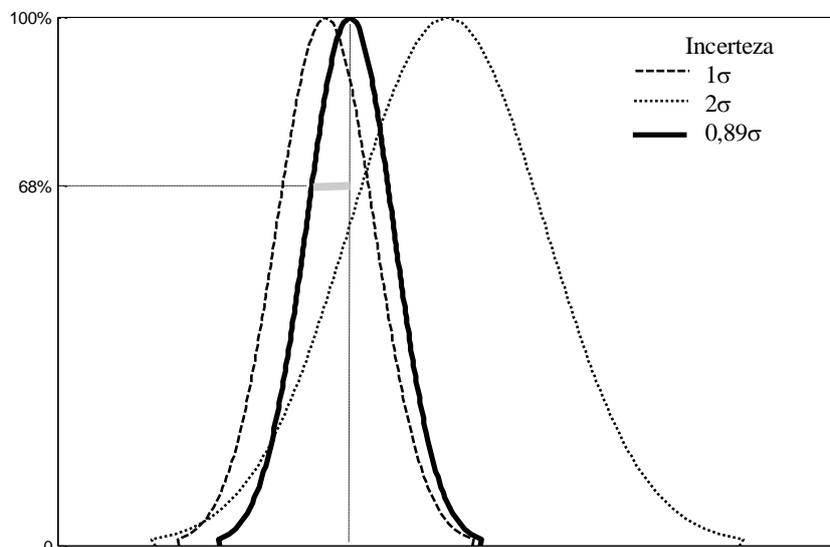


Figura 1. Diminuição da incerteza final ( $0,89\sigma$ ) utilizando o procedimento de fusão de estimação de máxima probabilidade (MLE).

**Aplicação do algoritmo no caso estudado.**

Potência Máxima da Semana	$P_{1max}$	$P_{2max}$	$P_{3max}$
Média das máximas e desvio padrão da Semana	$P_1, \sigma_1$	$P_2, \sigma_2$	$P_3, \sigma_3$
Determinação dos valores de fusão		$P_{2MLE}, \sigma_{2MLE}$	

Valor médio esperado:  $P_{2MLE} = \alpha P_1 + \beta P_2$

Desvio padrão do valor médio esperado;  $\sigma_{2MLE} = \sqrt{\frac{\sigma_1^2 \sigma_3^2}{\sigma_1^2 + \sigma_3^2}}$

Em que:  $\alpha = \frac{\sigma_3^2}{\sigma_1^2 + \sigma_3^2}$        $\beta = \frac{\sigma_1^2}{\sigma_1^2 + \sigma_3^2}$

<b>Algoritmo de Correção</b>
<p>1. Cria-se um intervalo de confiança em que deve estar a potência máxima em análise</p> $P_{2MLE} - k\sigma_{2MLE} \leq P_{2max} \leq P_{2MLE} + k\sigma_{2MLE}$
<p>2. Se <math>P_{2max}</math> está dentro do intervalo de confiança, então o dado está CORRETO</p>
<p>3. Caso contrário se realiza a correção da potência máxima, dado por:</p> $P_{2max} (Corrigido) = \frac{P_{1max} + P_{3max}}{2}$