

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE ENGENHARIA
CAMPUS DE ILHA SOLTEIRA**

ÁNGELA PATRICIA PADILLA ÁLVAREZ

**Previsão do preço *spot* do Mercado Majoritário Boliviano Utilizando Redes
Neurais Artificiais**

**Ilha Solteira
2015**

**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA
CAMPUS ILHA SOLTEIRA**

ÁNGELA PATRICIA PADILLA ÁLVAREZ



**Previsão do preço *spot* do Mercado Majoritário Boliviano Utilizando Redes
Neurais Artificiais**

Dissertação submetida à Faculdade de Engenharia - UNESP – Campus de Ilha Solteira, para obtenção do título de Mestre em Engenharia Elétrica.
Área de Conhecimento: Automação.

Carlos Roberto Minussi
Orientador

Ilha Solteira
2015

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

P123p Padilla Álvarez, Ángela Patricia.
Previsão do preço *spot* do mercado majoritário boliviano utilizando redes neurais artificiais / Ángela Patricia Padilla Álvarez. -- Ilha Solteira: [s.n.], 2015
78 f. : il.

Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2015

Orientador: Carlos Roberto Minussi

Co-orientador: Anna Diva Plasencia Lotufo

Inclui bibliografia

1. Redes neurais. 2. Sistemas elétricos de potência. 3. Mercados de energia.
4. Previsão do preço *spot* .



UNIVERSIDADE ESTADUAL PAULISTA
CAMPUS DE ILHA SOLTEIRA
FACULDADE DE ENGENHARIA DE ILHA SOLTEIRA

CERTIFICADO DE APROVAÇÃO

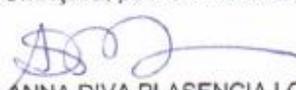
TÍTULO: Previsão do Preço Spot do Mercado Majoritário Boliviano Utilizando Redes Neurais Artificiais

AUTORA: ANGELA PATRICIA PADILLA ALVAREZ

ORIENTADOR: Prof. Dr. CARLOS ROBERTO MINUSSI

CO-ORIENTADORA: Profa. Dra. ANNA DIVA PLASENCIA LOTUFO

Aprovada como parte das exigências para obtenção do Título de Mestre em Engenharia Elétrica ,
Área: AUTOMAÇÃO, pela Comissão Examinadora:


Profa. Dra. ANNA DIVA PLASENCIA LOTUFO
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira


Profa. Dra. MARA LÚCIA MARTINS LOPES
Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira


Profa. Dra. SANDRA CRISTINA MARCHIORI DE BRITO
Departamento de Matemática e Estatística / Universidade Federal do Mato Grosso do Sul

Data da realização: 13 de novembro de 2015.

“A mente que se abre a uma nova ideia jamais voltará ao seu tamanho original.”
Albert Einstein

AGRADECIMENTOS

Agradeço primeiramente a Deus por ter me dado o dom da vida, e a minha família: minha razão de viver, meu motor, meu alento, o principal motivo pelo qual eu estou aqui. Seu apoio incondicional tem sido minha maior fortaleza neste caminho. Agradeço a minha família pela compreensão, meu primo Juan Manuel pelas suas sábias palavras, conselhos e apoio, em geral a toda minha família, muito obrigada por ficar do meu lado sempre.

Quero dar um agradecimento muito especial aos engenheiros do Centro Nacional de Despacho de Carga - CNDC da Bolívia, por todo o apoio brindado, em especial ao engenheiro Igor Jaldín, por sua ajuda incondicional.

Ao meu noivo Angel Manjón pela compreensão e apoio nessa jornada.

Agradeço ao meu Orientador Carlos Roberto Minussi e a coorientadora Anna Diva pelo apoio, incentivo, e por ter disponibilizado as ferramentas necessárias para eu poder prosseguir.

Agradeço a minha companheira e amiga de estudo e aventura no Brasil, Luz Ângela Molina, pela mão amiga nas horas de dificuldade, pela paciência e compreensão.

Ao professor Rubén Romero Lázaro e sua esposa, pelos seus conselhos e pela sua grande ajudam e apoio em Ilha Solteira.

RESUMO

Após a liberação do mercado elétrico boliviano, tornou-se crucial, para as empresas concorrentes no setor elétrico, tentar prever o preço da energia num horizonte de curto prazo, dado que, a partir dessas estimativas, as companhias geradoras podem otimizar suas estratégias de oferta e assim mesmo maximizar seu lucro. Neste estudo, será abordado o problema de previsão usando técnicas de inteligência artificial, especificamente utilizando redes neurais artificiais para prever o preço num horizonte de 24 horas; se utilizará uma rede não-linear autorregressiva com entradas exógenas (NARX) e uma rede neural de reconhecimento de padrões, com o fim de identificar qual destas apresenta melhores resultados de predição.

Palavras-chave: Redes neurais artificiais. Mercados de energia. Preço *spot*. Previsão do preço.

ABSTRACT

With the improvement of the Bolivian electricity market, it becomes important for all the participants of the electricity sector the prediction of the energy price in a short time horizon, giving with this the opportunity to the generating companies to optimize their supply strategies and maximize their profit. In this work, the problem of prediction will be approached using artificial intelligence techniques, specifically the use of an artificial neural network to price prediction for a 24 hours horizon, using a nonlinear autoregressive network with exogenous inputs (NARX) and a pattern recognition network in order to identify the best results of the prediction.

Keywords: Artificial neural networks. Energy markets. Spot price. Price forecast.

LISTA DE FIGURAS

Figura 1 - Empresas e estrutura do MEM.	17
Figura 2 - Sistema Interligado da Bolívia.....	17
Figura 3 - Matriz energética da Bolívia.....	18
Figura 4 - Esquema de preços na geração.	19
Figura 5, formação do preço horário.	21
Figura 6 - Funcionamento do MEM.....	13
Figura 7 - Comportamento da demanda x preço.	14
Figura 8 - Comportamento da demanda típica em função dos dias da semana e feriado.....	15
Figura 9 - Matriz energética da Bolívia, ano 2013.	16
Figura 10 - Comportamento do preço entre duas semanas consecutivas.	17
Figura 11 - Evolução da demanda e o preço dos primeiros quinze dias do mês de janeiro do ano 2012.	17
Figura 12 - ligações neurais.....	21
Figura 13 - Componentes de um neurônio artificial.....	21
Figura 14 - Rede <i>feedforward</i>	26
Figura 15 - Rede Recorrente.....	27
Figura 16 - Rede neural perceptrón multicamada.	28
Figura 17 - Estrutura da rede NARX.....	34
Figura 18 - Rede neural feedforward com função de ativação sigmoidal.....	36
Figura 19 - Comportamento da demanda x preço.	39
Figura 20 - Comportamento da demanda típica em função dos dias da semana e feriado.....	40
Figura 21 - Comportamento do preço entre duas semanas consecutivas.	41
Figura 22 - Evolução da demanda e o preço dos primeiros quinze dias do mês de janeiro do ano 2012.	41
Figura 23 - Rede 1: Relação de entrada - saída da rede neural.	45
Figura 24- Rede 2: Relação de entrada - saída da rede neural.	47
Figura 25 - Rede 3: Relação de entrada - saída da rede neural.	48
Figura 26 - Rede 4: Relação de entrada - saída da rede neural.	50
Figura 27 - Estrutura da rede por reconhecimento de padrões.....	52
Figura 28 - Resultados N fatorial.	58

Figura 29 - Previsões para alguns dias do ano de 2013 realizadas pela primeira rede neural treinada.	60
Figura 30 - Previsões para alguns dias do ano de 2013 realizadas pela segunda rede neural treinada.	61
Figura 31 - Previsões para alguns dias do ano de 2013 realizadas pela terceira rede neural treinada.	63
Figura 32 - Previsões para alguns dias do ano de 2013 realizadas pela quarta rede neural treinada.	65
Figura 33 - Previsão Segunda-Feira.	68
Figura 34 - Previsão Terça-feira.	69
Figura 35 - Previsão Quarta-Feira.	70
Figura 36 - Previsão Quinta-Feira.	70
Figura 37 - Previsão Sexta-Feira.	71
Figura 38 - Previsão Sábado.	71
Figura 39 - Previsão Domingo.	72

LISTA DE TABELAS

Tabela 1 - Algumas funções de ativação.....	23
Tabela 2 - Codificação.....	43
Tabela 3 - Rede 1: parâmetros configurados.....	46
Tabela 4 - Rede 2: Parâmetros configurados.....	47
Tabela 5 - Rede 3: Parâmetros configurados.....	49
Tabela 6 - Rede 4: Parâmetros configurados.....	51
Tabela 7 - Codificação para os dias da semana.....	53
Tabela 8 - Codificação para dos meses do ano.....	53
Tabela 9 - Experimento fatorial.....	54
Tabela 10 - Resultados	54
Tabela 11 - Resultados análises de variância.....	56
Tabela 12 - Resultados.....	57
Tabela 13 - Resultado MAPE rede 1.....	61
Tabela 14 - Resultado MAPE rede 2.....	62
Tabela 15 - Resultado MAPE rede 3.....	64
Tabela 16 - Resultado MAPE rede 4.....	66
Tabela 17 - Resultados para cada topologia.....	66
Tabela 18 - Resultados.....	67

SUMÁRIO

1	INTRODUÇÃO.....	12
1.1	Objetivo	14
1.2	Estrutura do Trabalho	14
2	MERCADOS DE ENERGIA	16
2.1	Funcionamento do Mercado Elétrico Majoritário da Bolívia (MEM).....	16
2.1.1	Descrição do setor.....	16
2.1.2	Descrição das atividades do setor	18
2.2	Fatores que afetam o preço da energia.....	13
2.2.1	Previsão da demanda.....	13
2.2.2	Matriz energética	16
2.2.3	Valores passados do preço	16
3	MODELOS DE PREDIÇÃO	19
3.1	Modelos estatísticos.....	19
3.2	Modelos de inteligência artificial.....	19
3.2.1	Redes neurais artificiais	20
3.2.2	<i>Análise de parâmetros da rede neural</i>	<i>36</i>
4	METODOLOGIA	38
4.1	Arquitetura RNA NARX para calcular o preço <i>Spot</i>	38
4.1.1	Dados de entrada da RNA.....	38
4.1.2	Processo de aprendizagem e treinamento	42
4.1.3	Validação	44
4.1.4	Configurações utilizadas para o cálculo do preço <i>Spot</i>	45
4.2	Rede neural reconhecimento de padrões	51
5	RESULTADOS.....	59
5.1	Resultados rede NARX.....	59
5.1.1	Rede 1- NARX	59
5.1.2	Rede 2 - NARX	61
5.1.3	Rede 3 - NARX	63
5.1.4	Rede 4 - NARX	65
5.2	Resultados rede, reconhecimento de padrões.	67
6	CONCLUSÃO	73
7	REFERÊNCIAS BIBLIOGRÁFICAS	75

1 INTRODUÇÃO

O mundo vive em constante crescimento, o qual o faz cada vez mais dependente da energia elétrica para satisfazer todas as necessidades, e assegurar o crescimento industrial. Sendo assim, é necessário energia de baixo custo constantemente, mas este não é sempre o caso. Deve haver sempre um equilíbrio entre preço e eficiência energética para garantir o fornecimento de eletricidade e garantir a expansão do sistema. Desde início dos anos 90, várias reformas nos mercados de energia vêm sendo executadas, com o fim de cumprir com os objetivos de qualidade, eficiência e economia, caracterizando-se como uma mudança para o setor. (VOROPAI et al., 2001).

Com o anterior modelo monopolista dos mercados de energia, a geração não estava sujeita à concorrência, por tanto era uma tarefa relativamente fácil (ANGELUS, 2001). No entanto, este modelo de mercado começou a mudar no final da década dos anos 80 e princípio de 90, onde muitos sistemas energéticos no mundo e, em especial, nos países latino-americanos tiveram reformas muito relevantes, as quais têm mostrado muita diversidade quanto a sua profundidade, alcance e velocidade de execução (OLADE, 2003). Entre as principais razões para esta reestruturação, é possível destacar a busca de: eficiência, livre concorrência num sector tradicionalmente estadual e transparência no processo de formação dos preços. (MILLAN et al., 2003).

A introdução da concorrência na geração de eletricidade contribuiu para que os preços começassem a refletir o custo real da produção da energia e a responder a variações dos determinantes deste preço. Por exemplo, mudanças na disponibilidade da água, preços internacionais dos hidrocarbonetos, ciclos econômicos e condições particulares do mercado e do sistema como as restrições na rede elétrica, posição dominante, entre outras.

O principal efeito esperado após da liberalização do mercado da eletricidade foi principalmente a queda nos preços da energia, considerando que os comercializadores estariam livres para escolher seus fornecedores. (BASTIAN et al., 1999). No entanto, a desregulamentação dos mercados da energia e a introdução da concorrência levaram a mudanças que afetam a precisão nas previsões. Portanto, não se podem garantir os benefícios aos participantes do mercado. O risco de mercado nas negociações é significativo por causa da alta volatilidade do preço.

Todas estas reformas aumentaram o risco associado à contratação da energia elétrica, considerando-se que os preços de energia no curto prazo são muito flutuantes, entendendo-se como curto prazo um horizonte de 24 horas. Portanto, a quantidade de energia a contratar no médio prazo com os comercializadores converteu-se em uma decisão importantíssima para as companhias, considerando que podem pôr em risco o estado financeiro destas. Este tipo de decisões depende do preço de energia *spot*, por tanto uma decisão mal tomada podem trazer consigo perdas milionárias. (MEDEIROS, 2003).

Levando em conta o exposto, as concessionárias de energia, que possuem grandes quantidades de consumidores, e as companhias com elevado consumo de energia elétrica, que permitam realizar contratos bilaterais, devem contar com ferramentas de apoio que possibilitem tomar decisões acertadas e criar políticas de contratos para participar com um menor risco no mercado competitivo, o que requer modelos para prever os preços no mercado *spot*, assim como os preços nas diferentes negociações nas vendas e compra de energia a médio prazo.

Vários autores têm proposto diferentes modelos para prever os preços da energia elétrica a curto prazo. (CONTRERAS et al., 2003; NOGALES et al., 2002). Utilizam modelos de séries temporais e modelos Autorregressivos, para prever o preço da eletricidade do dia seguinte. Sua aplicação aos mercados de Califórnia e da Espanha mostrou erros médios inferiores a 10%. Ante o comportamento não-linear deste tipo de variáveis econômicas, propuseram-se novos métodos baseados em diferentes estruturas de redes neurais artificiais (AMJADY et al., 2009) assim como métodos híbridos mesclando as redes neurais e os algoritmos genéticos. As características das redes neurais tem feito possível mostrar sua aplicabilidade em mercados de alta volatilidade em diversas áreas da engenharia e as finanças.

Szkuta et al. (1999) treinou uma rede neural multicamadas para prever o preço da energia elétrica para o próximo período no mercado australiano, os dados de entrada utilizados foram o preço de dias anteriores, as reservas do sistema e a demanda potencial. Os resultados mostraram a superioridade das redes neurais, em comparação com as técnicas de regressão lineares convencionais utilizadas pela empresa.

A formação dos mercados de energia elétrica tem como objetivo terminar com os monopólios, com o fim de criar um ambiente de concorrência nas transações de energia, onde o consumidor é livre para escolher o seu fornecedor de energia elétrica. O mercado Boliviano é um mercado liberalizado onde os preços adquirem características voláteis e incertas,

considerando as ofertas de preços e demanda de energia variam hora a hora. A análise deste ambiente competitivo entre oferta e demanda, será realizada com maior detalhe no capítulo 3.

Considerando a importância que tem os modelos de previsão para o processo decisório da comercialização de energia e para as estratégias de contratação, o principal objetivo da dissertação é propor um modelo de previsão do preço no curto prazo (um dia à frente, para as 24 horas do dia) no mercado elétrico Boliviano, utilizando um modelo de rede neural artificial, avaliar-se-á seu desempenho no prognóstico de um dia completo.

1.1 Objetivo

A previsão dos preços da eletricidade nos mercados da energia é um tema de pesquisa interessante, pois, de acordo com Hong et al. (2005), todos os participantes de funcionamento e as decisões estratégicas de mercado baseiam-se nas previsões destes preços. Por exemplo, (SOUZA et al., 2007) afirmam que os produtores precisam de previsões de curto prazo para a formulação de estratégias de marketing e otimizar seu programa de geração, a médio prazo, para negociar contratos bilaterais favoráveis. Enquanto que em longo prazo considera-se que a previsão é uma ferramenta que facilita a tomada de decisões relacionadas com a carteira de ativos de geração e a aquisição de novas plantas (VILLA, 2010).

Tal como foi exposto, a realização deste estudo tem como principal objetivo o desenvolvimento de modelos de previsão do preço da energia elétrica em curto prazo, com o fim de prever os preços para o dia seguinte prévio a que os ofertantes realizem as ofertas no mercado de curto prazo.

Se desenvolvidos vários modelos de previsão de preço utilizando redes neurais artificiais, usando o software Matlab e usando informação de comportamentos históricos de preços e outras variáveis que influem no comportamento do preço.

1.2 Estrutura do Trabalho

Esta dissertação é composta por seis capítulos, conforme descrito a seguir:

Capítulo 2: Mercados de energia

No capítulo 2 descreve-se o funcionamento do mercado elétrico majoritário boliviano, detalhando todos os fatores que influenciam na formação do preço da energia elétrica.

O banco de dados ou informação histórica de geração, demanda e preços foram descarregados do *web site* (<http://www.cndc.bo/home/index.php>) do Centro Nacional de Despacho de Carga - CNDC, esta informação é pública e com ajuda do engenheiro de programação do CNDC Igor Jaldín foram analisados e interpretados.

Capítulo 3: Modelos de predição

Apresenta todo o suporte teórico deste estudo, associado aos modelos de predição.

Capítulo 4: Metodologia

Este capítulo tem por objetivo, apresentar a análise das variáveis que serão utilizadas para a entrada à rede, bem como apresentar o detalhamento diferentes estruturas usadas nesta pesquisa.

Capítulo 5: Resultados

Apresenta os resultados para a cada rede usada.

Capítulo 6: Conclusão

Encontram-se as conclusões desta pesquisa e sugestões para trabalhos futuros.

2 MERCADOS DE ENERGIA

2.1 Funcionamento do Mercado Elétrico Majoritário da Bolívia (MEM)

Com a promulgação da Lei de Eletricidade 1604, em 1994, deu-se um passo à desintegração vertical da indústria elétrica no país. A separação e a capitalização, no mesmo ano, foram realizadas com o propósito de incrementar os investimentos, introduzir eficiência e concorrência em todas as etapas e simular concorrência nas etapas que não aceitassem concorrência direta. O sistema ficou dividido em três atividades independentes: geração, transmissão e distribuição. Trata-se de uma concorrência perfeita para evitar, assim, a existência de operadores dominantes. Estas atividades ficaram a cargo do Comitê Nacional de Despacho de Carga (CNDC), o qual é o responsável pela coordenação da geração, transmissão e despacho de carga ao menor custo e também da administração do Mercado Elétrico Majoritário (MEM) da Bolívia.

Em consequência do tipo de regulação, os preços da remuneração para concessionárias e ao transportador são relativamente estáveis. Pelo contrário, os preços no mercado elétrico de geração tendem a variar constantemente, por causa de que variam em relação à oferta.

Enquanto o setor de distribuição e o setor de transmissão de eletricidade enfrentam condições financeiras estáveis, o setor de geração está sujeito à incerteza quanto as suas rentabilidades.

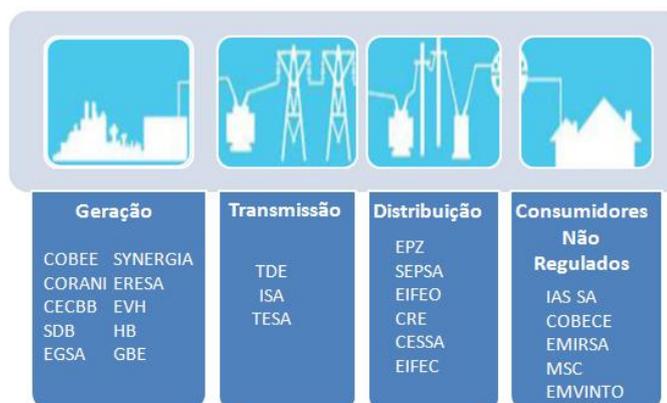
Existem dois tipos de transações no MEM: (1) por contrato e (2) no mercado *spot*. As vendas por contrato assumem preços e quantidades combinadas entre os agentes, enquanto que as operações *spot* realizam-se em relação ao preço vigente no mercado no momento da transação e o consumo é variável de acordo com a hora do dia e da época do ano. Vale ressaltar que quase todas as transações do MEM são feitas no mercado *spot*.

2.1.1 Descrição do setor

As três principais atividades do setor elétrico na Bolívia (geração, transmissão e distribuição) desenvolvem suas atividades no Sistema Interligado Nacional (SIN) que provê energia elétrica de maneira simultânea às principais cidades do país e que, de acordo a estrutura apresentada pela lei 1604 no Art. 15 (Lei N°1604), as empresas

pertencentes às atividades mencionadas, deverão estar desagregadas e dedicadas a uma destas atividades. Cada uma estará sujeita às limitações expostas na lei. O objetivo é o funcionamento de um mercado elétrico majoritário competitivo em relação à geração, no qual a oferta está constituída pelos geradores e a demanda pelas concessionárias de distribuição de energia e os consumidores não-regulamentados. Atualmente, o SIN conta com 10 unidades geradoras, três concessionárias de transmissão e seis concessionárias de distribuição. Além disso, fazem parte do SIN quatro consumidores não-regulamentados. A estrutura do MEM é descrita na Figura 1. Na Figura 2, apresenta-se o sistema interligado da Bolívia.

Figura 1 - Empresas e estrutura do MEM.



Fonte: Elaboração do autor.

Figura 2 - Sistema Interligado da Bolívia.



Fonte: Rodriguez (2007)

O outro sistema, existente na Bolívia é o sistema isolado, o qual provê energia às cidades menores do país. De acordo com o Artigo 20 da lei de eletricidade, as atividades de geração, transmissão e distribuição poderão estar integradas verticalmente (Lei N°1604). Este sistema cobre as regiões que não se encontram interligadas. Este setor é composto por sistemas isolados menores e autogeradores, cuja capacidade instalada é menor que 1 MW, representando uma pequena parte da indústria do setor.

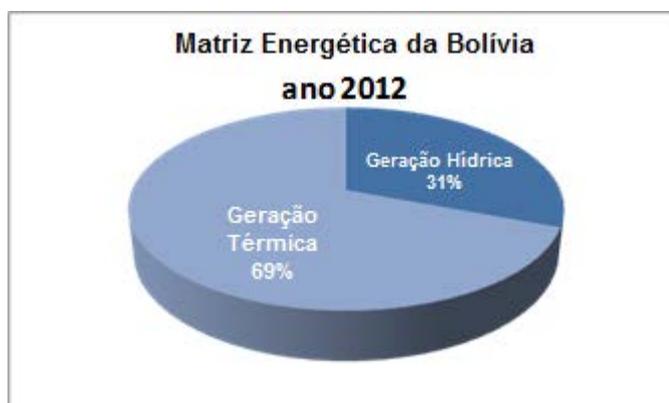
2.1.2 Descrição das atividades do setor

2.1.2.1 Geração

De acordo com a definição exposta na lei 1604, a geração é o processo de produção de eletricidade em centrais de qualquer tipo. Para efeitos de lei, a geração no sistema interligado nacional e a destinada à exportação, constituem produção e venda de um bem privado intangível (Lei N°1604).

Como é mostrado na figura 3, o conjunto das empresas que compõem o setor da geração de eletricidade na Bolívia se divide em dois grupos, basicamente: termelétricos e hidrelétricos. Por causa dos baixos preços do gás natural, a matriz energética boliviana é composta em maior parte por geradores térmicos.

Figura 3 - Matriz energética da Bolívia.



Nota: Utilizada informação publicada no site do CNDC.
Fonte: Elaboração do autor.

O preço da geração define-se a custos marginais, e as geradoras entram por ordem de mérito, isto é, primeiro as de menores custos marginais. Geralmente, as de menor custo marginal são as hidroelétricas. À medida que aumenta a demanda, nas horas pico, entram em operação as geradoras termelétricas a gás natural e, por último, as de óleo diesel.

Na figura 4 é ilustrado o mecanismo de determinação do preço em geração. Este mecanismo faz uma diferenciação entre o custo variável (custos operativos e o custo do combustível) como fator determinante do preço da energia.

Figura 4 - Esquema de preços na geração.



Fonte: Elaboração do autor.

2.1.2.2 Transmissão

Transmissão é a atividade de transformação da tensão da eletricidade e seu transporte desde o ponto de entrega por um gerador, autoprodutor ou outro transmissor, até o ponto de recepção de um comercializador, consumidor não-regulado, ou outro transmissor. Para efeitos da lei, a atividade de transmissão constitui transformação e transporte de um bem privado intangível, sujeita à regulação (Lei N°1604).

O Sistema Principal Interligado (STI) é uma parte constituinte do SIN. O STI é composto pelas linhas de alta tensão, incluindo suas respectivas subestações. Os componentes do STI devem operar em tensões iguais ou superiores a 69 kV, sendo de propriedade de um agente transmissor, dimensionado como um Sistema de Transmissão Economicamente Adaptado (STEA), de acesso aberto, estar operado pelo Comitê Nacional de Despacho de

Carga (CNDC) e ser utilizados pelo MEM em seu conjunto. Além disso, em condições normais de operação, deve existir a possibilidade de fluxo de corrente bidirecional.

2.1.2.3 *Distribuição*

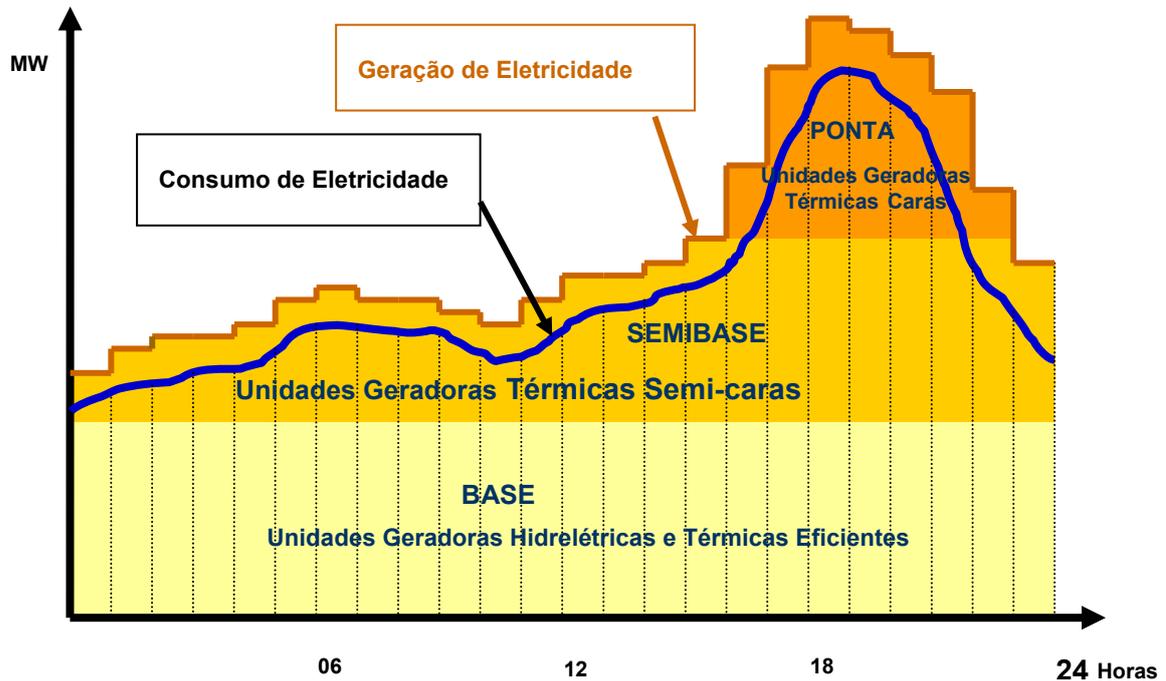
Segundo a lei de eletricidade, define-se a distribuição como a atividade de fornecimento de eletricidade para os consumidores regulados e/ou consumidores não-regulados, mediante instalações de distribuição primárias e secundárias. Para efeitos da lei, a atividade de distribuição constitui um serviço público (Lei N°1604).

As concessionárias participam no mercado elétrico majoritário, no qual compram energia dos geradores em grandes quantidades, em níveis altos de tensão e utilizam o sistema de transmissão para levar esta energia até seus pontos de conexão. Nesse mercado, a demanda de energia encontra-se condicionada fundamentalmente pelas características de demanda das empresas concessionárias (87% do mercado de energia). Os outros agentes econômicos importantes no SIN são os consumidores não-regulados, que se definem como aqueles que demandam acima de 1 MW de potência. Segundo informação publicada pelo CNDC atualmente, existem quatro consumidores não-regulados na Bolívia: Vinto, COBOCE, Inti Raymi (EMIRSA) e a Mina San Cristóbal (MSC).

2.1.2.4 *O mercado elétrico majoritário (MEM)*

O funcionamento do mercado, de acordo ao regulamento de preços e tarifas, é definido como sendo as “operações de compra, venda e transporte de eletricidade no SIN, mais as transações internacionais com mercados e sistemas de outros países (DS 26094)”. As transações de venda e compra, podem-se realizar por meio do mercado de contratos bilaterais cujos preços são definidos entre ambas as partes com contratos de fornecimento. A outra opção é por meio do mercado *Spot*, onde as transações se realizam em curto prazo e onde seus preços são atualizados a cada hora.

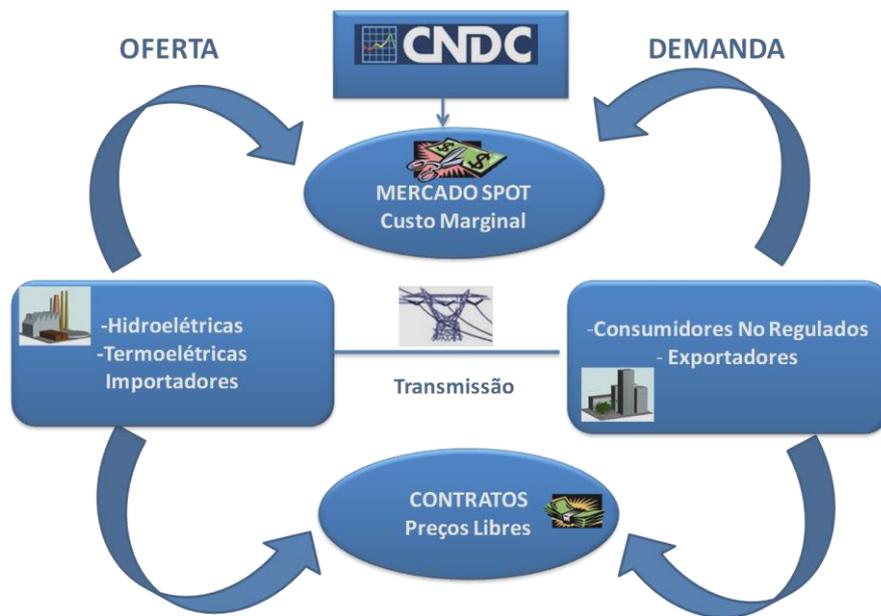
Figura 5 - formação do preço horário.



Fonte: Rodriguez (2007).

O CNDC além de operar o SIN também é o encarregado de administrar o MEM com o objetivo de evitar agentes dominantes no setor. Previamente à venda de energia, as empresas de geração realizam ofertas a diferentes custos marginais. O CNDC é quem decide, em função da demanda projetada dentro de um bloco horário, qual empresa injetará primeiro a energia. A empresa com custo marginal mais baixo é a primeira a injetar energia para um nível de demanda dado. O preço da energia no MEM é o custo marginal de curto prazo. Deste modo, em todo momento encontram-se operando as geradoras com menores custos marginais e na medida em que aumenta a demanda (nas horas pico), entram em operação as geradoras com maiores custos marginais, tal como se observa na figura 5. É importante mencionar que a demanda no MEM (figura 6) está dada pelos requerimentos individuais de todas as concessionárias de distribuição de energia no SIN, que por sua vez retransmite ao SIN a demanda dos consumidores finais, acrescida de um percentual de perdas no transporte de energia.

Figura 6 - Funcionamento do MEM.



Fonte: Rodriguez (2007)

2.2 Fatores que afetam o preço da energia

Gao (2000) expressam que ao construir os modelos de previsão de energia, é necessário identificar as variáveis que têm maior participação na previsão do preço, considerando que o preço da energia é sensível a diferentes variáveis. É muito importante realizar a sensibilidade para identificar aqueles que têm o maior impacto. No entanto, existem muitas que são fáceis de identificar, por exemplo, a demanda e o clima, que possuem uma relação direta com as variações na demanda.

Entre todas as variáveis as que têm maior impacto para a formação dos preços e, conseqüentemente, para a criação de uma rede neural são:

2.2.1 Previsão da demanda

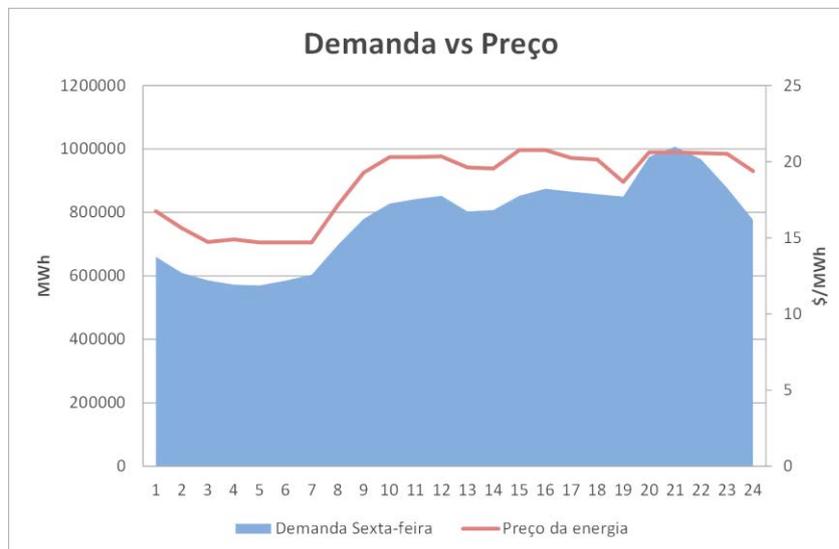
A demanda é uma das variáveis mais relacionadas com o preço que terá a energia (RODRÍGUEZ et al, 03).

A previsão da demanda de potência é fundamental em qualquer problema de tomada de decisões sobre um sistema elétrico. Portanto, é uma das atividades básicas no planejamento. Para estudos de planejamento de longo, médio e curto prazo, para a previsão de demanda deve-se considerar uma base de dados robusta, apropriada segundo o horizonte de tempo que se deseja prever. A determinação da área geográfica depende do requerimento de planejamento nos diferentes setores de geração, transmissão ou distribuição (GARCÍA; CABRERA, 2003).

Nesta investigação, a demanda de potência de curto prazo refere-se à curva de carga diária ou demanda de potência horária, por meio da qual se pretende realizar projeções a nível nacional. A previsão da demanda no curto prazo é muito importante para o manejo eficiente do sistema elétrico e assegurar uma adequada operação e, ainda, realizar o despacho horário mais econômico possível.

Quanto maior for a demanda, maior será o preço. No entanto, a relação entre ambas variáveis não é linear, porque dependem de outros fatores, tais como: o tipo de tecnologia utilizada para a geração, fatores especulativos (situações de ordem pública, ambientais, etc.). Na figura 7 observa-se a relação que existe entre o preço e a demanda.

Figura 7 - Comportamento da demanda x preço.



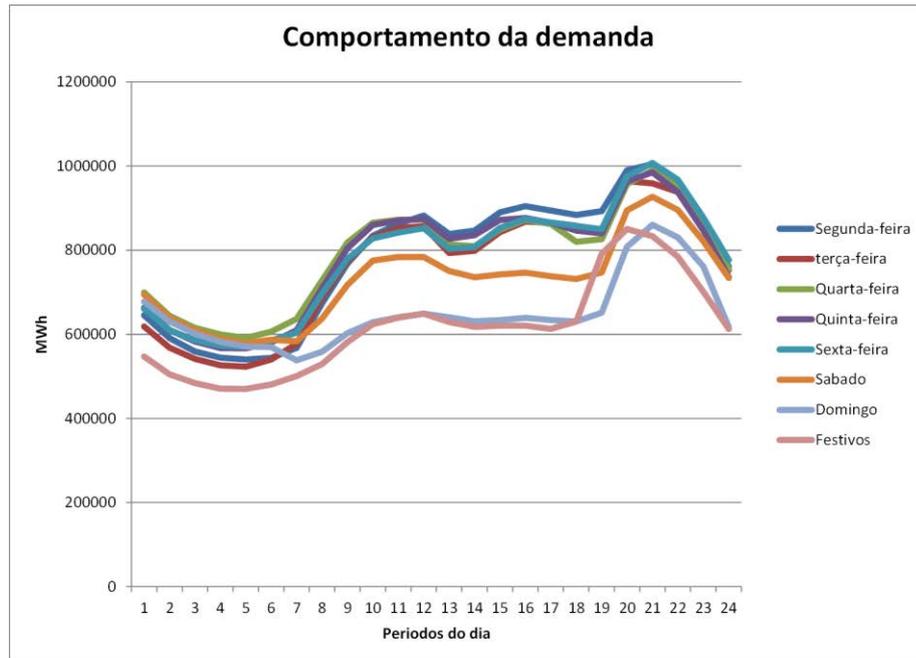
Nota: Utilizada informação publicada no site do CNDC.

Fonte: Elaboração do autor.

A demanda tem um comportamento diferente todos os dias. Na Figura 8, observa-se o comportamento da demanda para cada dia da semana. Nos dias com tendência

normal (segunda-feira à sexta-feira) a demanda tem um comportamento similar. No entanto, sábados, domingos e feriados têm comportamentos totalmente diferentes e apresentam *spikes* menores em comparação com dias com tendência normal. Assim, há necessidade de realizar esta diferenciação no momento de executar o treinamento da rede neural.

Figura 8 - Comportamento da demanda típica em função dos dias da semana e feriado.



Nota: Utilizada informação publicada no site do CNDC.

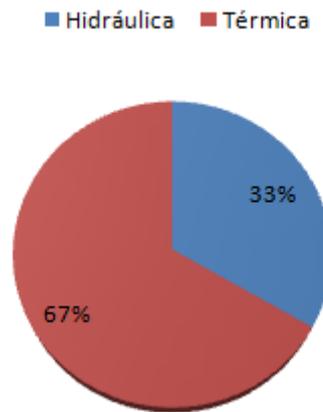
Fonte: Elaboração do autor.

O despacho econômico de carga é uma das atividades técnicas mais importantes dentro do sistema do Mercado Elétrico Majoritário, o qual deve garantir o fornecimento de energia, maximizar a segurança do Sistema Interligado Nacional, e minimizar os preços majoritários no mercado horário de energia. Para isso o CNDC elabora um plano de despacho, determinando a atribuição de produção dos geradores mais econômicos, segundo a declaração de custos que estes realizam à mencionada instituição. Além disso, dado que a natureza da energia elétrica, esta deve ser produzida no preciso momento que é requerida. Para tanto, deve-se ser realizado um rastreamento contínuo chamado operação em tempo real, que tem como finalidade verificar o cumprimento do programa de despacho e tomar de maneira imediata às ações necessárias para enfrentar os desvios que surgem respeito do mesmo, tais como: o aumento ou diminuição da demanda de energia. (NARDO G et al., 2010).

2.2.2 *Matriz energética*

A matriz energética corresponde ao conjunto de tecnologias usadas em cada período do dia para abastecer a demanda. Segundo a informação mais recente, publicada pelo CNDC no ano 2013, a matriz energética boliviana é constituída em maior parte por recurso térmico (67%) e hidráulico (33%), como mostra a figura 9.

Figura 9 - Matriz energética da Bolívia, ano 2013.



Nota: Utilizada informação fornecidas pelo CNDC.
Fonte: Elaboração do autor.

Os custos fixos de geração variam segundo o tipo de tecnologia, sendo a hidráulica muito mais barata que a energia térmica. A energia térmica varia muito com os preços dos combustíveis. Portanto, em cada período do dia gera-se energia com uma percentagem diferente para cada tipo de tecnologia. O custo por MWh produzido será também diferente. Assim, conhecendo-se a matriz energética de geração, pode-se ser prognosticado o preço da energia com maior precisão.

2.2.3 *Valores passados do preço*

De acordo com Muñiz (2010) a outra série de dados considerada contém os preços marginais *spot* do mercado elétrico majoritário. Esta é uma variável absolutamente necessária, será usada na rede neural de forma horária, isto é um dia terá 24 dados. Na Figura 10 observa-se que o preço ao longo da semana tem um componente cíclico, isto é, os dias são similares entre si, pelo que o preço de uma segunda-feira na hora h , será similar ao preço à mesma hora

do dia terça-feira. No entanto, esta relação não é tão direta entre dias feriado e dias de trabalho. Isto se deve à relação direta que existe entre o preço e a demanda.

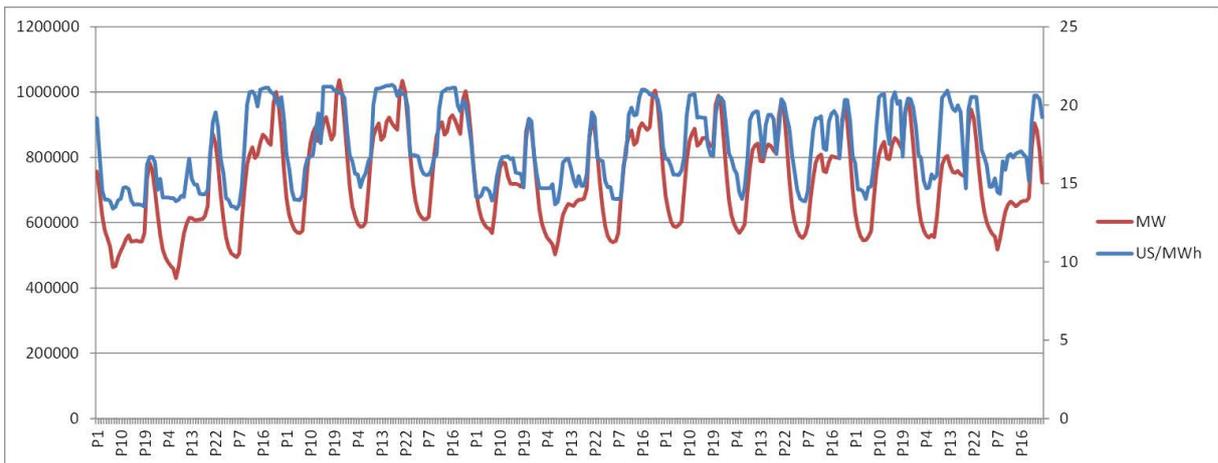
Figura 10 - Comportamento do preço entre duas semanas consecutivas.



Nota: Utilizada informação fornecidas pelo CNDC.
 Fonte: Elaboração do autor.

Na figura 11, observa-se a evolução da demanda e o preço dos primeiros quinze dias do mês de janeiro do ano 2012.

Figura 11 - Evolução da demanda e o preço dos primeiros quinze dias do mês de janeiro do ano 2012.



Nota: Utilizada informação fornecidas pelo CNDC.
 Fonte: Elaboração do autor.

Portanto, para construir a rede neural terá de partir de todas as variáveis endógenas e exógenas e identificar quais são as mais significativas e as que produzem melhores predições. (MUÑIZ, 2010).

3 MODELOS DE PREDIÇÃO

A volatilidade extrema do preço da energia, em alguns mercados elétricos internacionais, que pode chegar a ser de até duas ordens de magnitude maior que para outros ativos, tem forçado às companhias a investir no desenvolvimento e investigação de novos modelos e métodos de predição do preço (MUÑIZ J, 2010). Por causa disso, tem surgido um grande número de modelos de predição, alguns utilizando métodos clássicos econométricos e outros utilizando técnicas de inteligência artificial.

3.1 Modelos estatísticos

Para prever, com precisão, o preço é necessário selecionar uma metodologia que consiga capturar os padrões dinâmicos dos valores passados da série de preços. Para este propósito, são usados os modelos ARIMA e os modelos de Regressão Dinâmica. O modelo de Regressão Dinâmica é mais robusto que o modelo ARIMA, e com ele se obtêm melhores resultados. O modelo ARIMA é muito influenciado pela volatilidade da série; não obstante, em trechos estáveis da série, este modelo prediz bem. As séries de preços dos mercados estudados são muito voláteis e, portanto, o modelo ARIMA pode não proporcionar bons resultados. A obtenção dos modelos ARIMA e de Regressão Dinâmica realiza-se por meio de um estudo detalhado das principais características da série horária de preços, e da série de demandas, para o caso do modelo de Regressão Dinâmica. (ESPINOLA, 2004).

Na literatura, foram propostas diversas técnicas para realizar a predição de séries de tempo. Das disponíveis, as redes neurais artificiais têm se mostrado serem mais robustas em comparação com outras técnicas tradicionais como ARIMA, especialmente na representação de relações complexas que exibem comportamentos não-lineares. Segundo (MASTERS, 1993), existem várias razões pelas quais deveriam ser utilizados uma RNA em vez de alguma técnica tradicional. Entre estas, destacam-se: as RNA possuem uma ampla capacidade para aprender relações desconhecidas a partir de um conjunto de exemplos; possuem boa tolerância a padrões estranhos presentes na série; e são suficientemente robustas para processarem informação incompleta, inexata ou contaminada.

3.2 Modelos de inteligência artificial

Os modelos de inteligência artificial são flexíveis e podem resolver problemas de maior complexidade com relações não-lineares. Estes modelos são especialmente adequados para realizar previsões de curto prazo. Entre todos os métodos existentes, as redes neurais artificiais são, provavelmente, as que maior atenção têm recebido.

Em mercados de energia realizaram-se contribuições importantes, entre elas Velásquez et al. (2005) analisam as dificuldades encontradas pelos pesquisadores e profissionais quando tentam prognosticar os preços da eletricidade, com o objetivo de contribuir a identificar as barreiras para tal fim. Gareta et al. (2004) mostra que as redes neurais são uma ferramenta adequada para prever os preços horários com base no mercado majoritário da eletricidade do mercado elétrico Europeu. Segundo Velásquez (2005) as experiências reportadas na literatura mostram que a dinâmica da maioria das séries de preços da eletricidade é não-linear, invariante no tempo e possui uma quantidade significativa de variáveis. A previsão destas séries exige o uso de técnicas robustas que permitam capturar e conhecer o comportamento complexo de estas séries. Portanto, os modelos inteligentes têm grande capacidade de adaptação.

3.2.1 *Redes neurais artificiais*

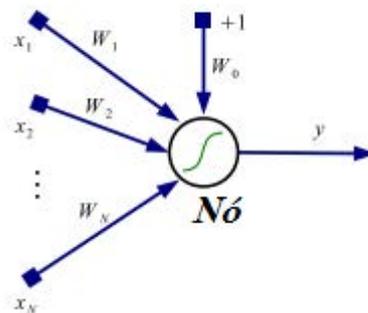
As redes neurais têm sido usadas para resolver muitos problemas, entre eles, econômicos e financeiros, ressaltando fortemente sua aplicação na previsão de séries temporais e sua capacidade de detectar e explodir a não-linearidade existente nos dados, mesmo em condições onde existem dados incompletos ou a presença de ruído; também se destacam por seu desempenho na solução de problemas complexos, onde o reconhecimento de modelos é importante; por causa do bom comportamento que possuem as redes neurais na previsão de séries de tempo tem motivado a realização da presente investigação onde será utilizado um modelo de rede neural para prever preços marginais da energia elétrica (*spot*) no mercado majoritário de energia de Bolívia.

Segundo Flores (2011) as redes neurais podem ser definidas como:

- Um modelo matemático composto por um número de elementos que processam informação e ao mesmo tempo estão organizados em níveis.
- Um sistema de computação composto por um número de elementos simples, elementos de processos interligados, os quais processam informação por médio de seu estado dinâmico como resposta a entradas externas.

A figura 12 mostra uma forma simples de conexão de um neurônio.

Figura 12 - Ligações neurais.



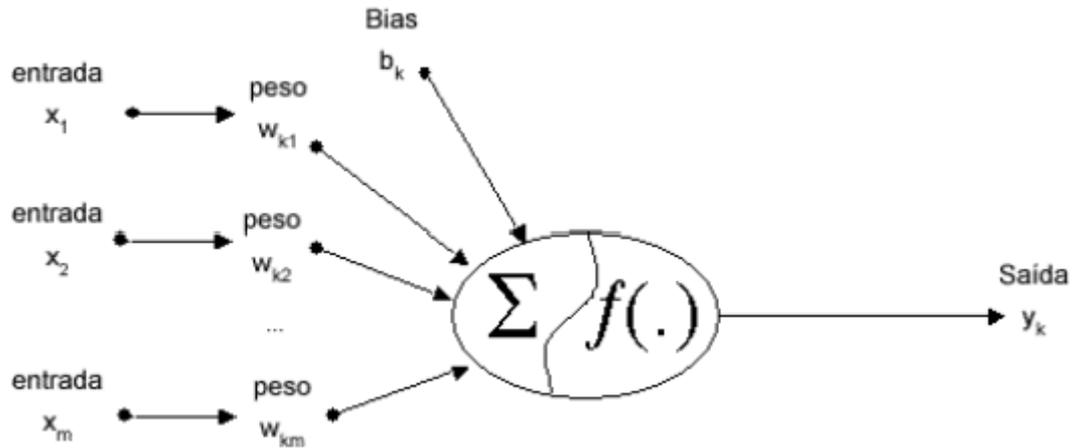
Fonte: Flores (2011)

As redes neuronais artificiais são mecanismos de processamento de informação inspirados no funcionamento das redes neurais biológicas (ROMERO, 2008). As redes neurais são uma ferramenta poderosa, as quais, por suas características, são utilizadas em diferentes campos de aplicação tais como: telecomunicações, aplicações médicas, reconhecimento do fala, finanças, biologia, análise de mercados, indústrias de semicondutores, predição, falhas em motores elétricos, aplicações biomédicas, controle de processos e refinaria de petróleo. Também, são utilizadas em aplicações militares como: guia automático de mísseis e combate aéreo (FLORES, 2011).

3.2.1.1 Modelo padrão de um neurônio

Na figura 13 mostra-se o modelo regular de um neurônio artificial. Como pode ser observado, consistem num conjunto de entradas, pesos sinápticos, uma função de ativação e uma saída. (BONIFACIO, 2007).

Figura 13 - Componentes de um neurônio artificial.



Fonte: Santos (2013).

O neurônio é tratado, ao conjunto de valores, primeiramente como se fosse um só. Os valores de entrada, primeiramente, são multiplicados pelos pesos sinápticos. A função de ativação é modificada a saída de um neurônio, cujo valor normalmente vai de (0 a 1) ou de (-1 a 1). Isto é assim, porque um neurônio pode estar totalmente inativo (0 ou -1) ou ativo (1). (FLORES, 2011) Existem diferentes tipos de funções de ativação. As mais comuns mostram-se na tabela 1.

Tabela 1 - Algumas funções de ativação

Função	Expressão Matemática	Intervalo	Gráfico
Linear	$f(x) = x$	$[-\infty, +\infty]$	
Relé	$f(x) = \text{sign}(x)$	$[-1, +1]$	
Linear por partes	$f(x) = \begin{cases} -1, & \text{se } x < -1 \\ x, & \text{se } -1 \leq x \leq +1 \\ +1, & \text{se } x > +1 \end{cases}$	$[-1, +1]$	
Sigmoide	$f(x) = \frac{1 - e^{-x}}{1 + e^{-x}}$	$[-1, +1]$	
Gaussiana	$f(x) = A e^{-Bx^2}$	$[0, +1]$	
Senoidal	$f(x) = A \text{sen}(wx + \phi)$	$[-1, +1]$	
Etc.	-	-	-

Fonte: Flores (2011).

Matematicamente, a saída do neurônio regular (mostrado na Figura 13) é definida por:

$$S_i = \sum_j^n w_{ij} x_i \quad (1)$$

Segundo WASERMAN,1989) o processo de treinamento de um neurônio artificial é:

- Um conjunto de entrada X_i .
- Peso associado, V_n a qual multiplica cada sinal de X_i
- Após a entrada ser multiplicada por um peso associado é aplicado ao um bloco somatório \sum , denominado soma, que corresponde ao corpo celular biológico, cuja função é adicionar todos os sinais de entrada que foram ponderados a fim de produzir um valor de potencial de ativação (JARDIM, 2015).
- Se a soma ponderada das entradas for maior que o valor do “bias” o neurônio é ativado provocando um pulso na saída. Caso contrário, o neurônio não é ativado (JARDIM, 2015).
- A função de ativação ativa o neurônio artificial e limita a saída do neurônio.

Na atualidade, é possível encontrar muita informação de redes neurais e de diversas aplicações. Além disso, existem vários modelos de neurônios artificiais, os quais são concebidos para tentar simular o comportamento de um neurônio real (NELLES, 2001).

3.2.1.1.1 Estrutura da rede

Como foi mencionado anteriormente (Subseção 3.2.1.1), as redes neurais são compostas por unidades de processamento simples chamadas neurônios. Estas unidades se interligam entre si para dar lugar a uma rede. Estas conexões podem ir desde uma entrada de um neurônio, de um neurônio a uma camada e de uma camada a uma saída; existem modelos mais desenvolvidos, que estão compostos por retroalimentações onde a informação se propaga por meio da rede e volta aos nós iniciais como uma entrada adicional. Uma rede simples consta, basicamente, de três tipos de camadas de neurônios (MUÑIZ, 2010):

- **Camada de entrada:** É a camada que recebe a informação inicial, processa-a e transfere-a para os neurônios das camadas seguintes por meio das diferentes conexões.
- **Camada de saída:** Esta camada reúne toda a informação calculada pelos neurônios precedentes. Essa camada terá tantos neurônios quanto for o número do componentes da saídas.
- **Camadas ocultas:** São as camadas que existem entre as camadas de entrada e as camadas de saída. Nos neurônios das camadas ocultas reside o maior potencial da rede neural, já que são as encarregadas de estabelecer as conexões entre as variáveis de entrada e de saída.

3.2.1.1.1.1 Tipos de redes

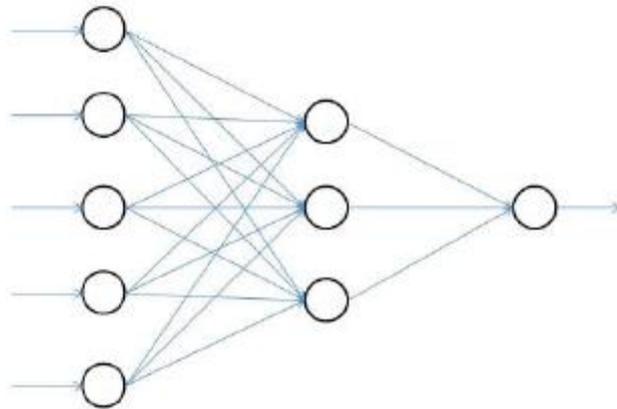
Muñiz (2010) menciona em seu estudo que existem quatro modelos básicos de redes neurais, a partir dos quais, desenvolvem-se modelos mais específicos:

- Redes de propagação adiante (*feedforward*);
- Redes recorrentes;
- Redes estocásticas;
- Redes modulares.

a) Redes de propagação adiante (*feedforward*).

É o tipo de rede mais simples e foi o primeiro modelo proposto na literatura, esta se observa na figura 14. Neste tipo de redes, a informação transmite-se por meios das conexões entre neurônios, desde a camada de entrada até a camada de saída. Pode conter uma camada oculta (*perceptron* simples) ou por várias camadas ocultas como na rede neural *perceptron* multicamada. Segundo Krose (1996), qualquer função que tome um conjunto de números reais e devolva outro conjunto de números reais pode ser aproximada, com uma boa precisão, por uma rede *perceptron* multicamada com uma única camada oculta. Por isso, é um tipo de rede adequado para a previsão de séries temporárias.

Figura 14 - Rede *feedforward*



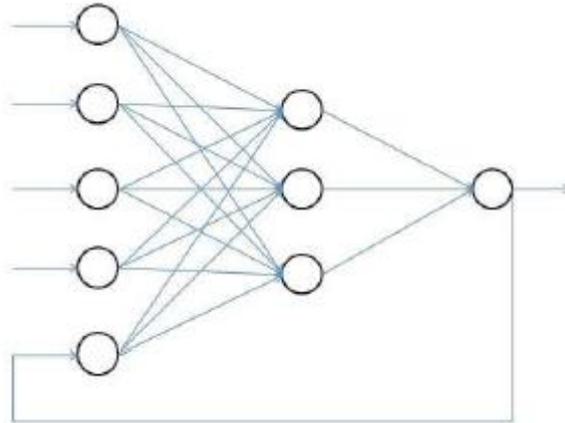
Fonte: Muñiz (2010)

Adicionalmente à rede neural *perceptron* multicamada, existe o modelo ADALINE (Rede linear adaptativa), a qual consiste em uma rede que adapta seus parâmetros em função das entradas mais recentes, utilizando um sinal de polarização, um peso e uma função “somatório” (MUÑIZ, 2010). A RBF (Rede com Função de Base Radial) é um tipo de interpolador multidimensional que usa funções de base radial em cada neurônio. Utilizando um sinal de polarização, um peso e uma função somatório.

b) Redes Recorrentes

Na figura 15 mostra-se uma rede recorrente. A saída fornecida pela rede neural depende das variáveis de entrada e, também, do estado da rede de fases anteriores (MUÑIZ, 2010). Há uma variedade de redes recorrentes, como de Elman, NARX e de Hopfield entre outras.

Figura 15 - Rede Recorrente.



Fonte: Muñiz (2010)

c) Redes estocásticas

As redes estocásticas constituem uma alternativa às anteriores RNA descrita, ao utilizar neurônios com funções de ativação não determinísticas, cujas saídas se obtêm de forma probabilística e mediante mecanismos de aprendizagem estocásticos. (FLOREZ et al., 2008).

Igualmente à maioria de sistemas neurais, as redes estocásticas tratam de minimizar uma função de erro, recorrendo ao símil termodinâmico da mecânica estatística para sortear os mínimos locais e tratar de atingir o mínimo global da função. (FLOREZ et al, 2008).

d) Redes modulares

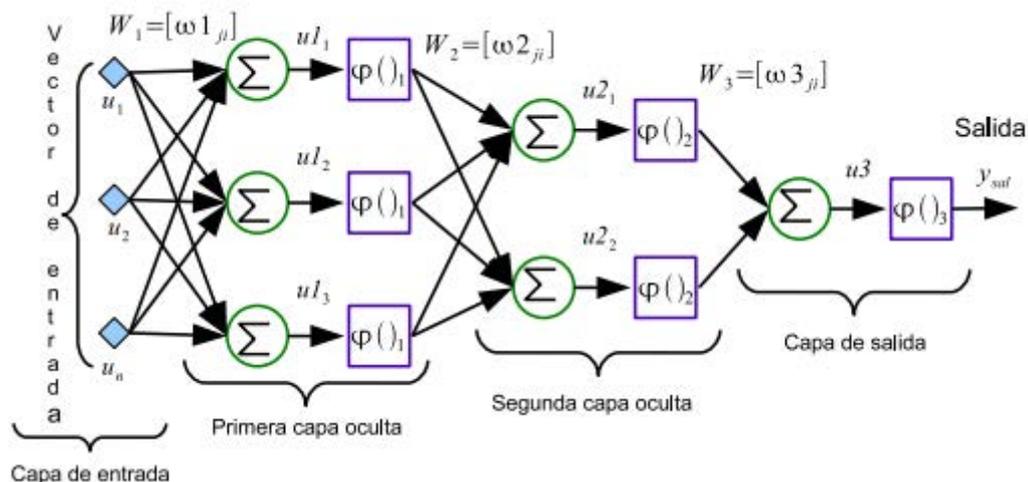
As Redes Neurais Artificiais (RNA) são em si mesmas estruturas matemáticológicas de inspiração biológica. Sua utilidade tem sido provada em diferentes campos. No entanto, a complexidade de alguns problemas junto com a necessidade de construir modelos para estruturas biológicas vinculadas à Consciência (de maior nível de abstração), tem levado a que recentemente alguns pesquisadores tenham focado sua atenção em criar Sistemas de RNA, chamados RNAM para a resolução desses problemas. (MARTINEZ, 2006).

3.2.1.1.1.2 Modelo matemático

Segundo Flores (2011), um perceptrón multicamada ou MLP (Multi-Layer Perceptrón) os neurónios são ordenados em uma ou mais capa ocultas e conectadas a uma capa de saída; esta arquitetura é treinada mediante o algoritmo de propagação de erros ou back-propagation, considerando que é o mais utilizado e comum para este tipo de rede.

Na figura 16, observa-se uma arquitetura multicamada de quatro capas, onde a primeira camada só alimenta à primeira camada oculta, a qual junto com a segunda camada oculta realizam operações modificando os sinais de entrada e por último a camada de saída que só entrega o sinal estimado ao exterior (FLORES, 2011).

Figura 16 - Rede neural perceptron multicamada.



Fonte: Flores (2011),

A equação de entrada - saída é mostrada na equação 2 (FLORES, 211):

$$y_{sal} = \varphi_3[W_3 * \varphi_2[W_2 * \varphi_1[W_1 * u]]] \quad (2)$$

Onde:

y_{sal} É à saída da rede neural.

$u = [u_1, u_2, \dots, u_n]$, vetor de entrada na rede.

φ Operador conhecido como função de ativação.

$\omega_1, \omega_2, \omega_3$ Pesos sinápticos.

W_1 Matriz de pesos sinápticos da camada de entrada.

W_2 Matriz de pesos sinápticos da primeira camada oculta.

W_3 Matriz de pesos sinápticos da segunda camada oculta.

O algoritmo de aprendizagem é usado visando o ajuste dos pesos sinápticos de um perceptron multicamada é conhecido como retro-propagação do erro (FLORES, 2011). O erro da saída é:

$$e = y(k) - y_{sal} \quad (3)$$

Onde:

$y(k)$ É a saída do sistema no instante k.

y_{sal} É a saída da rede neural.

A função objetivo está dada por:

$$E(k) = \frac{1}{2}(e(k))^2 \quad (4)$$

Usando o gradiente descendente, o ajuste dos pesos é realizado da seguinte forma:

$$\Delta\omega_{j,i} = \omega_{j,i}(k+1) - \omega_{j,i}(k) = -\eta \frac{\partial E(k)}{\partial \omega_{j,i}(k)} \quad (5)$$

O termino $\Delta\omega_{j,i}(k)$ é conhecido como a regra delta. O termino $\frac{\partial E(k)}{\partial \omega_{j,i}(k)}$ calcula-se como:

$$\frac{\partial E(k)}{\partial \omega_{j,i}(k)} = \frac{\partial E(k)}{\partial e(k)} \frac{\partial e(k)}{\partial y_{sal}(k)} \frac{\partial y_{sal}(k)}{\partial v(k)} \frac{\partial v(k)}{\partial \omega_{j,i}(k)} \quad (6)$$

As derivadas parciais estão dadas por:

$$\begin{aligned} \frac{\partial E(k)}{\partial e(k)} &= e(k) & \frac{\partial e(k)}{\partial y_{sal}(k)} &= -1 \\ \frac{\partial y_{sal}(k)}{\partial v(k)} &= \varphi'(v(k)) \text{ com } \varphi'(\beta) = \frac{\partial \varphi(\beta)}{\partial \beta} \\ \frac{\partial v(k)}{\partial \omega_{j,i}(k)} &= y_{sal}(k) \end{aligned} \quad (7)$$

Por tanto, a regra delta pode se escrever como:

$$\Delta\omega_{j,i}(k) = \eta\delta(k) \quad (8)$$

com:

$$\delta(k) = -\frac{\partial E(k)}{\partial \hat{y}(k)} \frac{\partial y_{sal}(k)}{\partial v(k)} \quad (9)$$

Por último, usualmente a função de ativação é uma função não linear. É uma função sigmoïdal definida como:

$$f(x) = \varphi(x) = \tanh(x) = \frac{1}{1+e^{(-x)}} \quad (10)$$

3.2.1.1.2 Processo de aprendizagem

Durante a operação de uma rede neural podem-se distinguir claramente duas fases ou modos de operação: a fase de aprendizagem ou treinamento, e a fase de operação ou execução.

Na fase de aprendizagem, a rede é treinada para realizar um determinado tipo de processamento. Uma vez atingido um nível de treinamento adequado, passa à fase de operação, onde a rede é utilizada realizar a tarefa para a qual foi treinada (BERTONA, 2005).

3.2.1.1.2.1 Fase de treinamento

Segundo Bertona (2005) Uma vez selecionada o tipo de topologia da rede neural, é necessário a treiná-la para que a rede possa ser utilizada. Partindo de um conjunto de pesos sinápticos aleatório, o processo de aprendizagem procura um conjunto de pesos que permitam à rede desenvolver corretamente uma determinada tarefa. Durante o processo de aprendizagem vai-se refinando, iterativamente, a solução até atingir um nível suficientemente adequado.

O processo de aprendizagem pode ser dividido em três grandes grupos de acordo com suas características (ISASI et al, 2004):

- Aprendizagem supervisionada: Apresenta-se, à rede neural, um conjunto de padrões de entrada junto com a saída esperada. Os pesos vão se modificando de maneira proporcional ao erro que se produz entre a saída real da rede e a saída desejada.
- Aprendizagem não-supervisionada: Apresenta-se, à rede neural, um conjunto de padrões primeiramente, mas não há informação disponível sobre a saída desejada. O processo de treinamento, neste caso, deverá ajustar seus pesos com base à correlação existente entre os dados de entrada.
- Aprendizagem por reforço: Este tipo de aprendizagem localiza-se entre os dois tipos de treinamentos (supervisionado / não-supervisionado). Apresenta-se à rede um conjunto de padrões de entrada e indica-se, à rede neural, se a saída obtida é ou não correta. No entanto, não é informado o valor da saída desejada. Este tipo de aprendizagem é muito útil nos casos em que se desconhece qual é a saída exata que deve proporcionar a rede.

a) Algoritmo de treinamento

No treinamento de uma rede, procura-se usar um método que, a partir de um vetor de parâmetros iniciais e uma série de exemplos, consegue-se encontrar o conjunto de parâmetros ótimo que minimize o erro de predição. Estes métodos se denominam funções de treinamento e há uma variedade deles e com diferentes características e propriedades. As características mais importantes são: a capacidade de encontrar mínimos globais (não permanecer em mínimos locais) e tempo de execução reduzido (MUÑIZ, 2010).

Já que o processo de aprendizagem tem como objetivo fazer com que a diferença entre a saída obtida e a saída desejada seja a menor possível, o algoritmo de aprendizagem tem de resolver um problema de minimização (MUÑIZ,2010):

$$\text{Min}_w(E) \tag{11}$$

Sendo: W é o conjunto de parâmetros da rede e E é uma função que avalia o erro obtido na predição das saídas. Em muitas ocasiões, a função erro é definida da seguinte forma (MUÑIZ, 2010)

$$E = \frac{1}{N} \sum_{n=1}^N e(n) \quad (12)$$

Com N representando o número de padrões e $e(n)$ o erro na predição do padrão, sendo n (MUÑIZ, 2010):

$$e_n = \frac{1}{2} \sum_{i=1}^{nc} (S_i(n) - y_i(n))^2 \quad (13)$$

Sendo: $\mathbf{y}(n) = [y_1(n) \ y_2(n) \ \dots \ y_{nc}(n)]^T$ e $\mathbf{S}(n) = [s_1(n) \ s_2(n) \ \dots \ s_{nc}(n)]^T$ são os vetores de saídas obtidas e desejadas, respectivamente, para o padrão n .

Assim, se \mathbf{W}^* é um conjunto de parâmetros da rede que proporciona um mínimo da função do erro E , e se, neste ponto, o erro é próximo de zero, então, a saída obtida encontra-se próxima à saída desejada. Neste caso, considera-se que se atingiu o objetivo da aprendizagem. A aprendizagem é equivalente a encontrar um ponto mínimo global. No obstante, como as funções de transferência dos neurônios são não-lineares, a relação entre os parâmetros da rede e da saída obtida será também não-linear. Assim, o processo de aprendizagem transforma-se num problema de otimização não-linear o qual requer o uso técnicas especiais para sua resolução.

3.2.1.1.3 Fase de operação

Uma vez finalizada a fase de aprendizagem, a rede pode ser utilizada para realizar a tarefa para a qual foi treinada. Uma das principais vantagens que possui este modelo é que a rede aprende a relação existente entre os dados, adquirindo a capacidade de generalizar conceitos. Desta maneira, uma rede neural pode trabalhar com informação que não lhe foi apresentada durante da fase de treinamento.

Procurando um complemento entre os bons resultados dos modelos econométricos e os resultados de uma rede neural, numa parte da investigação, será utilizada a rede neural tipo NARX (rede neural não-linear autorregressiva com entrada exógena). Trata-se de uma rede neural dinâmica recorrente, com conexões de retroalimentação que encerram várias camadas da rede.

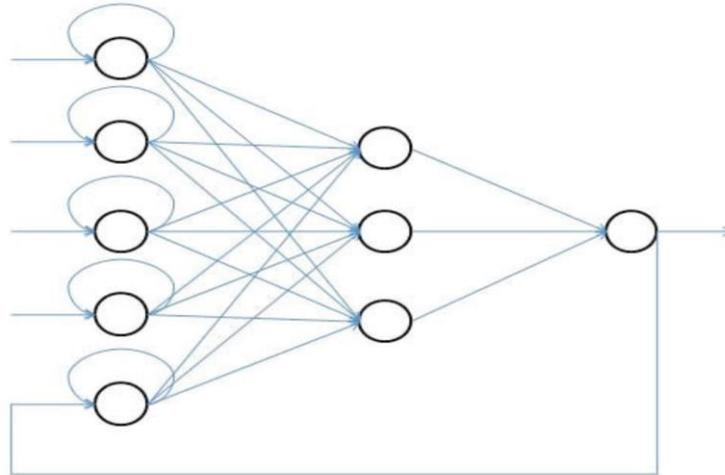
3.2.1.2 Rede neuronal tipo NARX

A rede utilizada é do tipo NARX (*Nonlinear AutoRegressive with eXternal inputs*, em inglês), é uma rede dinâmica com conexões de realimentação, formando um laço onde a informação propaga da frente para trás como se vê na Figura 17. O modelo NARX está baseado no modelo linear ARX que é muito utilizado para a predição de séries temporais.

O modelo NARX é a generalização não-linear do modelo bem conhecido ARX, o qual constitui uma ferramenta regular na identificação de sistemas lineares tipo caixa preta. Um modelo NARX formula-se como uma equação entrada-saída de tempo discreto como se observa na Equação (14), de maneira que a saída y e o tempo t dependem dos valores anteriores da entrada e saída.

$$y(t) = f(u(t-n_u), \dots, u(t-1), u(t), y(t-n_y), \dots, y(t-1)) \quad (14)$$

Figura 17 - Estrutura da rede NARX.



Fonte: Muñiz (2010)

Sendo $y(t)$ o valor da série temporal de interesse de prever; $u(t)$ é o conjunto de variáveis de entrada exógenas no tempo t . Os termos $u(t), \dots, u(t-Du)$ e $y(t), \dots, y(t-Dy)$ representam os retardos das variáveis exógenas e endógenas entre o instante t e os instantes Du e Dy , respectivamente. A função f é uma função não-linear (LENNART LJUNG, 2010). O laço de realimentação que esta rede possui permite criar uma memória interna onde são guardados os valores passados da saída e os reintroduzem após um número determinado de retardos na rede como uma variável de entrada adicional. Neste estudo serão comparados os resultados obtidos com esta rede NARX, *versus* os resultados obtidos com uma rede neural com reconhecimento de padrões.

Este tipo de rede neural tem sido usado, com sucesso, para vários modelamentos e diferentes processos altamente não-lineares como aqueles associados com modelos oscilatórios para descrever os movimentos dos sistemas biológicos com múltiplas extremidades (SIEGELMANN et al., 97). Além disso, também se comparou as redes NARX *versus* outras redes neurais recorrentes com problemas como inferência gramática e sistemas de identificação não-lineares e, desta maneira, chegou-se à conclusão que as redes NARX tipicamente convergem bem mais rápido e geralmente oferecem bons resultados (GILES, 1994; HORNE, 1997).

3.2.1.3 Rede Neural com reconhecimento de padrões

Esta rede tem por objetivo classificar dados (padrões) num número de categorias ou classes. Um padrão pode ser qualquer entidade na qual se tem um interesse de reconhecimento e/ou identificação (WATANABE, 1985). Existem muitos exemplos de padrões, tais como: um pixel em uma imagem em 2D ou 3D, um gesto, uma impressão digital, um rosto humano, a voz de um indivíduo, séries de tempo, a forma de um animal, entre muitos outros exemplos (KPALMA; RONSIN, 2007).

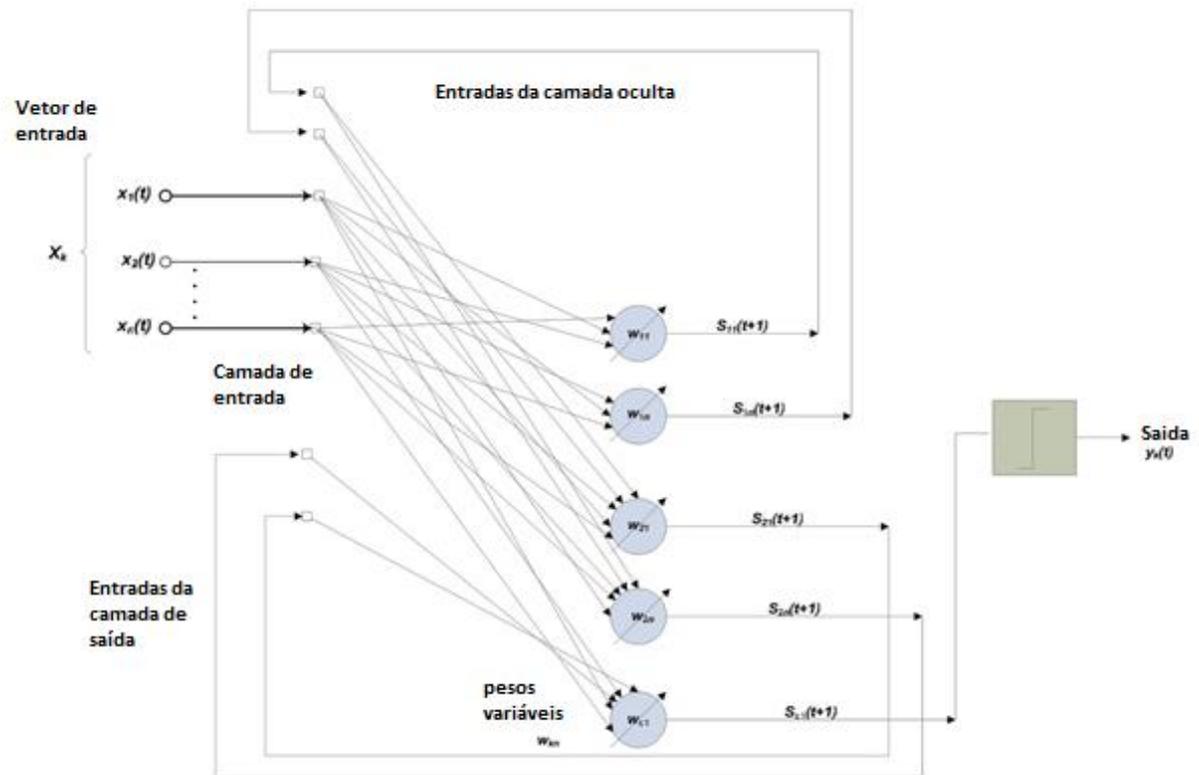
O sistema de reconhecimento de padrões é um sistema automático que se destina em classificar padrões primeiramente em classes específicas. Neste, têm-se duas tarefas sucessivas:

- A análise (ou descrição) no qual se extraem as características do padrão a ser estudado.
- A classificação (ou reconhecimento) na qual se permite reconhecer um objeto (ou padrão) usando algumas características derivadas do primeiro passo.

O tipo de rede mais usada para o reconhecimento de padrões são as do tipo *Feedforward*, nas quais como se começa com a apresentação de um vetor de entrada que é equivalente, em magnitude, ao número de neurônios da primeira camada da rede, as quais processam o vetor elemento por elemento em paralelo. A informação, modificada pelos fatores multiplicativos dos pesos em cada neurônio, é transmitida para diante pela rede passando pelas camadas ocultas para, finalmente, ser processada pela camada de saída. É por isso que estes tipos de redes recebem esse nome (CLAVEL, 2008).

Na Figura 18 ilustra-se uma rede *feedforward*, onde todos os neurônios de uma camada estão interligados com os neurônios da seguinte camada, iniciando com a camada principal (camada de entrada) onde são aplicados os elementos do vetor \mathbf{X}_k , que produzirão as saídas $S_{mn}(t+1)$. O vetor de pesos \mathbf{W}_k é atualizado conforme as épocas passam, enquanto o treinamento prossegue, e ao final do mesmo os pesos individuais $w_{11} \cdots w_{1n}, \cdots w_{21} \cdots w_{2n}$, etc. assumem seus valores finais para iniciar o trabalho da rede com dados de entrada novos uma vez que se chegou a uma ou várias saídas globais $s_{on}(t + 1)$ (CLAVEL, 2007).

Figura 18 - Rede neural feedforward com função de ativação sigmoidal



Fonte: Clavel (2007).

3.2.2 Análise de parâmetros da rede neural

Um dos pontos mais importantes a considerar nesta investigação consiste da determinação de quais são parâmetros críticos para o desenvolvimento da rede neural.

Neste sentido, com a finalidade de ter um suporte sólido que apoie a configuração final, usou-se o seguinte procedimento:

- **Projeto experimento fatorial de:** Em general por experimento fatorial entende-se que em cada ensaio ou réplica completa do experimento, estudam-se todas as combinações possíveis dos níveis dos fatores. Ou seja, se o fator A possui a níveis, e o fator B possui b níveis, cada réplica terá todas as ab combinações dos tratamentos. Em alguns experimentos pode ser encontrado tal que a diferença na resposta entre os níveis de um fator não é a mesma para todos os níveis dos outros fatores, pelo que se diz que no efeito de os dois fatores existem uma interação. Assim, entre as razões que se tem para usar um desenho fatorial, pode ser mencionado:

- a) Encontrar um modelo que descreva o comportamento geral do fenômeno em estudo.
- b) Otimizar a resposta ou variável dependente, isto é, encontrar a combinação de níveis que otimizam a variável dependente.
- c) A característica geral e essencial, faz-se necessário o estudo conjunto de fatores e suas interações.

Além do mencionado, têm-se como vantagens, a economia no material experimental já que se obtém informação sobre vários fatores sem incrementar o tamanho do experimento e permite o estudo da interação, ou seja, determinar o grau e a forma na qual se modifica o efeito de um fator pelos níveis de outro fator (MENDOZA, 2015; MONTGOMERY, 1997).

Uma vez obtidos os dados do experimento fatorial, é necessário realizar processar tais dados. Este procedimento denomina-se análise de variância (ANOVA, em inglês). Esta análise é uma técnica estatística usada em medidas que dependem de várias classes de efeitos que operam simultaneamente. Permite estimar os efeitos e para decidir quais efeitos são importantes. A base teórica da análise de variância foi desenvolvida e publicada por Fisher et al. (1925).

Assim, a ANOVA é um conjunto de procedimentos que se ajustam às características do projeto experimental usado na obtenção dos dados. Não é um método fixo, pelo contrário este se adapta a cada projeto e pode ser classificado de diferentes formas. Neste sentido, se o projeto é unifatorial, pode ser aplicado à análise de uma via. No caso multifatorial, a análise será de duas vias quando se têm dois fatores, de três vias para três fatores e assim sucessivamente. Por outro lado, de acordo ao número de repetições tem-se ANOVA com grupos iguais para projetos balanceados, isto é, igual número de repetições por tratamento, ou ANOVA com grupos desiguais para desenhos desbalanceados.

O objetivo central da ANOVA é a comparação de dois ou mais tratamentos, a cada um dos quais representa uma população, como é usual nos experimentos comparativos (DÍAZ, 2009).

4 METODOLOGIA

As redes neurais artificiais têm sido usadas para resolver muitos problemas, entre eles, econômicos e financeiros, ressaltando fortemente sua aplicação na previsão de séries temporais e sua capacidade de detectar e explorar a não-linearidade existente nos dados, mesmo em condições onde existem dados incompletos ou a presença de ruído. Também se destacam por seu desempenho na solução de problemas complexos, onde o reconhecimento de modelos é importante. Como consequência do bom comportamento que as redes neuronais têm na predição de séries de tempo, têm motivado a realização a presente investigação onde será utilizado um modelo de rede neural para prever os preços marginais da energia elétrica no mercado majoritário de energia de Bolívia.

Um dos aspectos fundamentais, quando se vai enfrentar um projeto com redes neuronais, é dispor de um banco de dados histórico da variável de interesse (e.g., séries temporais), para garantir que o processo de treinamento seja confiável. Para isso, a série de dados utilizada corresponde a dados históricos em resolução horária do ano 2012 até setembro de 2013. Esta base de dados foi fornecida pela Comissão Nacional de Despacho de Carga (CNDC) que é o operador da rede de energia da Bolívia e responsável pela gestão do sistema elétrico nacional.

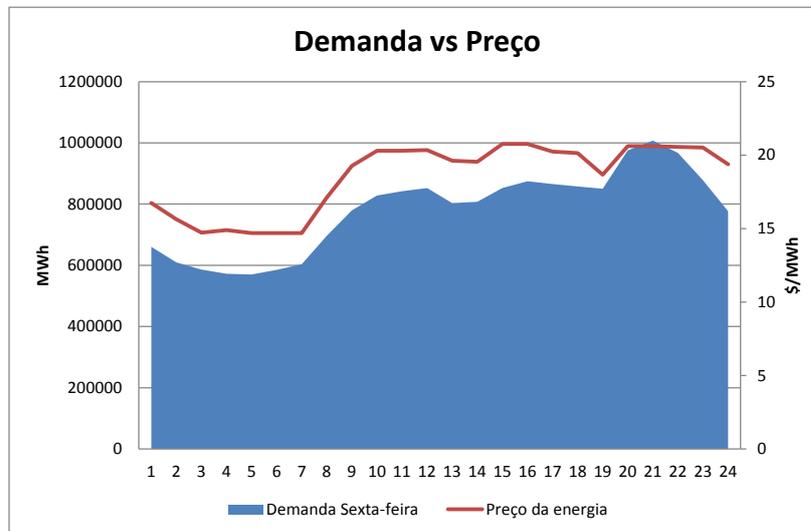
A rede utilizada na primeira fase do projeto é a tipo NARX (Nonlinear AutoRegressive with external inputs, em inglês) e na segunda fase do projeto, a previsão foi feita utilizando uma rede neural de reconhecimento de padrões.

4.1 Arquitetura RNA NARX para calcular o preço Spot

4.1.1 Dados de entrada da RNA

Utilizou-se a demanda total do Sistema Interligado Nacional (SIN) da Bolívia. A demanda é uma das variáveis mais relacionadas com o preço da energia (RODRIGUEZ, 2003). Quanto maior for a demanda, maior será o preço da eletricidade, tal como se evidencia na Figura 19.

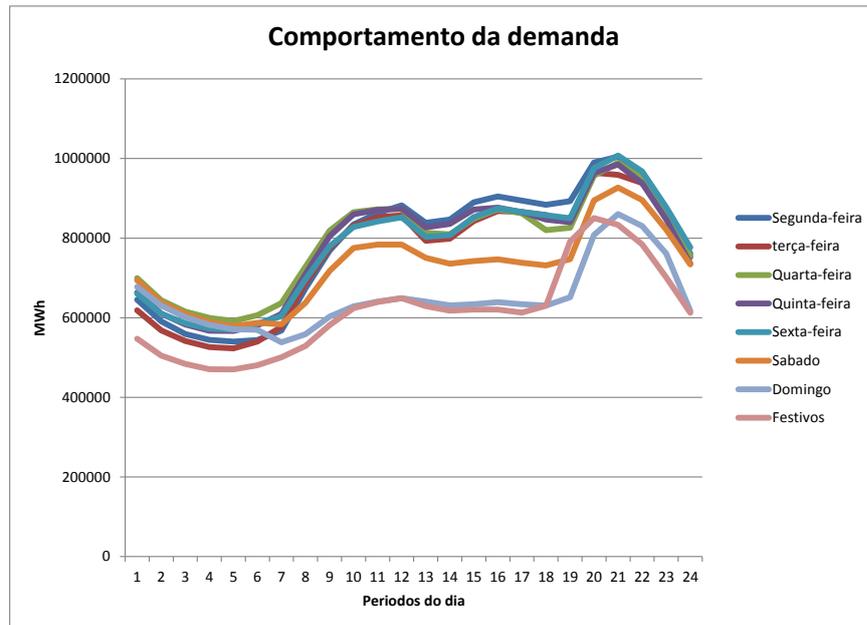
Figura 19 - Comportamento da demanda x preço.



Nota: Utilizada informação fornecidas pelo CNDC.
Fonte: Elaboração do autor.

A demanda possui um comportamento diferente todos os dias. Na Figura 21, observa-se o comportamento da demanda para cada dia da semana. Nos dias com tendência normal (segunda-feira à sexta-feira) a demanda possui um comportamento similar. No entanto, sábados, domingos e feriados têm comportamentos totalmente diferentes e apresentam *spikes* menores em comparação com dias com tendência normal. Assim, há necessidade de realizar esta diferenciação no momento de executar o treinamento da rede neural.

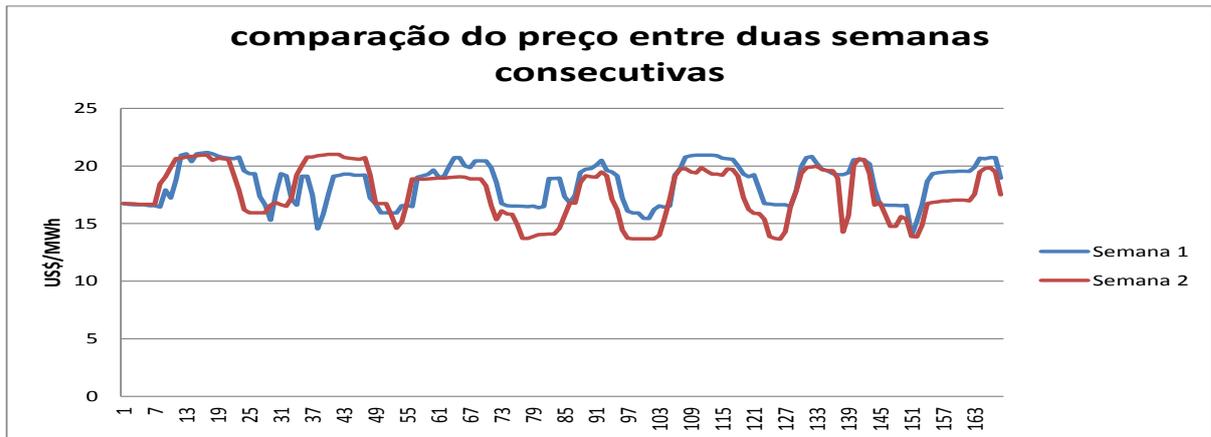
Figura 20 - Comportamento da demanda típica em função dos dias da semana e feriado.



Nota: Utilizada informação fornecidas pelo CNDC.
Fonte: Elaboração do autor.

A outra série de dados considerada contém os preços marginais *spot* do mercado elétrico majoritário. Esta é uma variável absolutamente necessária, porque é a que se vai prever no tempo. Será introduzida na rede neural de forma horária. Na Figura 21, observa-se que o preço, ao longo da semana, possui um componente cíclico, isto é, os dias são similares entre si. O preço correspondente de uma segunda-feira na hora h , será similar ao preço à mesma hora do dia terça-feira. No entanto, esta relação não é tão direta entre dias feriados e dias de trabalho. Isto se deve à relação direta que existe entre o preço e a demanda.

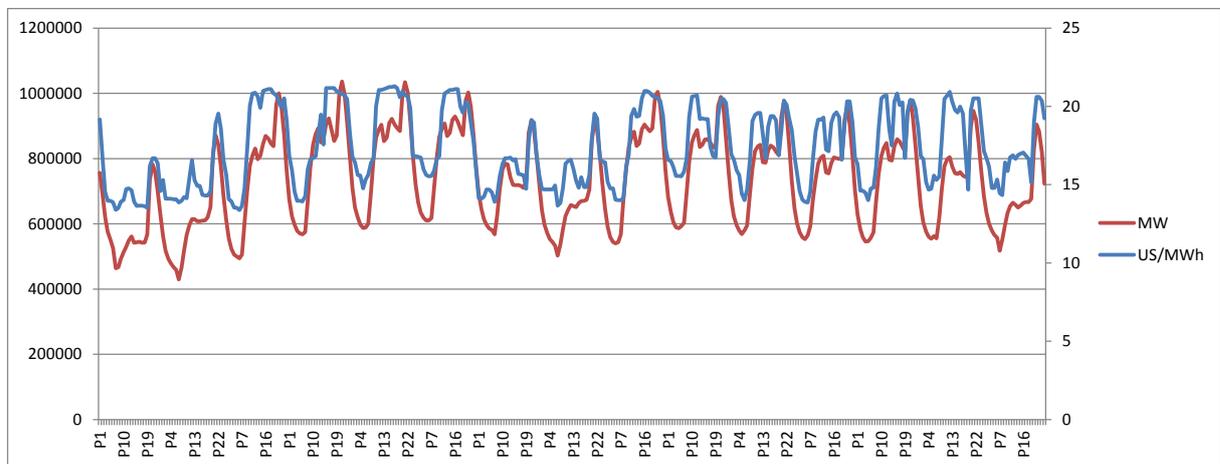
Figura 21 - Comportamento do preço entre duas semanas consecutivas.



Nota: Utilizada informação fornecidas pelo CNDC.
Fonte: Elaboração do autor.

A seguir (Figura 22) observa-se a evolução da demanda e o preço dos primeiros quinze dias do mês de janeiro do ano 2012.

Figura 22 - Evolução da demanda e o preço dos primeiros quinze dias do mês de janeiro do ano 2012.



Nota: Utilizada informação fornecidas pelo CNDC.
Fonte: Elaboração do autor.

Portanto, para construir a rede neural é preciso começar por todas as variáveis endógenas e exógenas, bem como identificar quais são as mais significativas e as que produzem melhores predições.

As variáveis econômicas podem ser classificados em Jimenez (2012):

Exógenas: São variáveis independentes e cujo valor não se determina dentro de um modelo econômico, mas que influi na determinação das variáveis endógenas.

Endógenas: São variáveis cujos valores são determinados ou explicados pelas relações existentes dentro de um modelo econômico a partir de um conjunto de dados conhecidos como variáveis exógenas.

Para o treinamento são utilizados 366 dias, os quais correspondem ao ano 2012 em sua totalidade e para a validação se utilizam 273 dias, os quais correspondem ao período de janeiro a setembro de 2013.

No entanto, além das variáveis anteriormente mencionadas, existem outras variáveis que possuem sensibilidades significativas para prever o preço. Entre as que se utilizam no presente estudo, encontram-se a geração por tipo de tecnologia, isto é, geração hidráulica e geração térmica.

4.1.2 Processo de aprendizagem e treinamento

O objetivo da aprendizagem ou treinamento da rede neural é ajustar os parâmetros, pesos etc., com a finalidade de que as entradas apresentadas produzam as saídas desejadas, isto é com a finalidade de minimizar a função de erro. Quanto ao número de camadas escondidas e os neurônios por camada, não existe nenhum método ou regra para determinar o número ótimo. Geralmente, esse número é determinado por tentativa e erro, ou seja, partindo de uma arquitetura já treinada, realizam-se mudanças aumentando e diminuindo o número de neurônios ocultos e o número de capas até conseguir a arquitetura que se ajuste à solução do problema. A seleção da melhor estrutura, nesta pesquisa, foi realizada por meio das medidas tradicionais de avaliação do prognóstico dentro e fora da mostra.

Antes da execução do processo de treinamento, foi necessário realizar um estudo detalhado das variáveis de entrada, identificando os dados correspondentes ao dia da semana, os meses do ano e os feriados, os quais são variáveis qualitativas. Portanto, foi necessária a seguinte codificação para converter esses dados em valores quantitativos (Tabela 2).

Tabela 2 - Codificação

Variável	Valores Qualitativos	Representação Binária
Dia da semana	Domingo	001
	Segunda-feira	010
	Terça-feira	011
	Quarta-feira	100
	Quinta-feira	101
	Sexta-feira	110
	Sábado	111
Mês do ano	Janeiro	0001
	Fevereiro	0010
	Março	0011
	Abril	0100
	Maio	0101
	Junho	0110
	Julho	0111
	Agosto	1000
	Setembro	1001
	Outubro	1010
	Novembro	1011
	Dezembro	1100
Feriado	Não	0
	Sim	1

Fonte: Elaboração do autor.

A fase de concepção ou construção da arquitetura da rede implica na determinação do número de camadas, número neurônios nas camadas ocultas, as funções de ativação, bem como a determinação da conectividade entre todos os neurônios da rede neural. Esta etapa é crítica no processo de projeto de uma rede neural, pois isto determinará a capacidade de aprendizagem da rede.

O problema nesta fase é que não existe uma técnica que realize este processo. A determinação da topologia da rede é feita mediante a experiência ou por meio de um processo heurístico.

Quanto ao algoritmo de treinamento, foram utilizados dois algoritmos para configurações diferentes e avaliar seu comportamento. Estes foram o algoritmo *Levenberg-Marquardt* e o algoritmo Bayesiano.

O algoritmo normalmente utilizado para o treinamento de redes neurais usadas para a previsão do preço é baseado em *Levenberg-Marquardt*, por causa, principalmente, da sua rapidez de convergência com erros suficientemente pequenos conformes às necessidades do

problema. No entanto, atingir erros pequenos não garante a capacidade de generalização do modelo neural, produzindo, neste caso, um problema de sobre-treinamento, o qual significa que a rede apresenta um erro muito baixo com os padrões de treinamento, mas o erro aumenta com os padrões de validação (RODRIGUEZ et al., 2009).

Entre as diferentes alternativas para evitar o sobre-treinamento destaca-se o algoritmo de regularização automática ou aprendizagem Bayesiano. Em aplicações de identificação de sistemas, isto se explorou tendo em conta como resultado que a qualidade dos modelos neuronais melhora quando se usa a aprendizagem Bayesiano em vez da aprendizagem convencional como Levenberg Marquardt (LOPEZ, 2007).

4.1.3 Validação

A precisão geral de qualquer modelo de previsão é determinada por meio da comparação dos valores previstos com os valores reais ou observados. F_t denota a previsão no tempo t e A_t denota a demanda real correspondente ao t . O erro de previsão ou desvio é definido como (HEIZER, 2004):

$$\begin{aligned} \text{Erro do Prognóstico} &= \text{preço real} - \text{valor previsto} \\ &= A_t - F_t \end{aligned} \quad (15)$$

Existem várias medidas de uso comum na prática para calcular o erro global do prognóstico. Estas medidas servem para comparar diferentes modelos de prognóstico, bem como para monitorar os prognósticos e garantir o seu bom desempenho (HEIZER, 2004).

A medida mais comuns é:

- a) MAPE; Erro Percentual Absoluto Médio:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Real - Pred.}{Real} \right| \times 100 \quad (16)$$

O MAPE é a média das diferenças absolutas entre os valores prognosticados e os reais, expresso como percentagem dos valores reais.

4.1.4 Configurações utilizadas para o cálculo do preço Spot

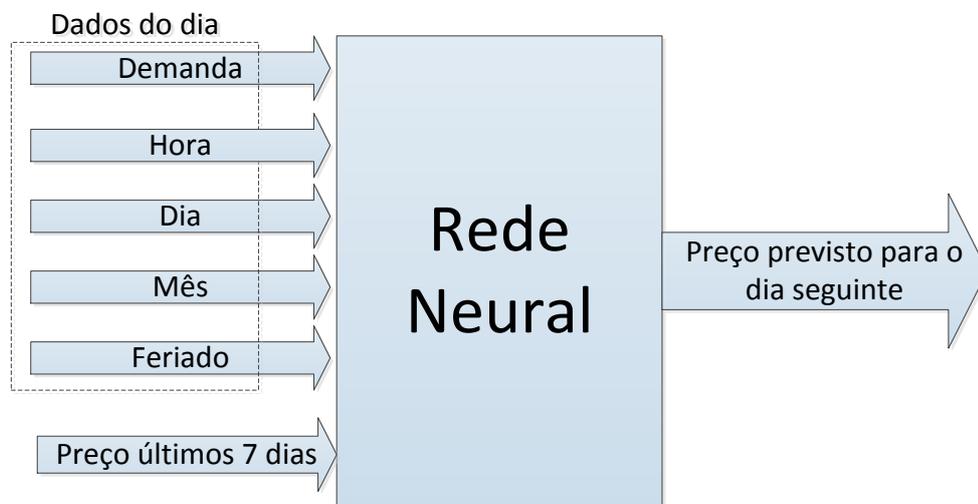
Tal como foi mencionado anteriormente, foram realizados previsões com diferentes configurações da rede neural. Portanto, revisar-se-á cada uma por separado.

4.1.4.1 *Rede 1: Rede neural NARX, considerando entradas individuais para cada uma das variáveis usadas.*

Dados de entrada da RNA

As séries de dados de entrada foram fornecidas pelo CNDC constituído porá dados de demanda e de preços marginais correspondentes ao ano 2012. A Bolívia, atualmente, não tem intercâmbios internacionais de energia elétrica. Portanto, só é considerada a demanda nacional. A figura 23 representa o desenho desta rede.

Figura 23 - Rede 1: Relação de entrada - saída da rede neural.



Fonte: Elaboração do autor.

A configuração dos parâmetros é relacionada na Tabela 3:

Tabela 3 - Rede 1: parâmetros configurados.

Parâmetros configurados	
% Dados para treinamento	70
% Dados para teste	15
% Dados para validação	15
Número de neurônios da camada escondida	10
Numero de retardos (<i>delays</i>) utilizados	7

Fonte: Elaboração do autor.

Treinamento

Nesta rede, durante o processo de treinamento, foram utilizadas as seguintes configurações:

- **Algoritmo de treinamento:** *Levenberg-Marquardt*, função Trainlm do Toolbox de redes neurais do aplicativo de simulação MATLAB.
- **Função de transferência utilizada:** Tan-Sigmoid  na primeira camada, na segunda camada escondida Purelin  e Purelin na camada de saída.
- **Numero de camadas ocultas:** Uma camada oculta, com 10 neurônios.

4.1.4.2 *Rede 2: Rede neural com entrada individual para demanda, preços e um conjunto concatenado das variáveis hora, dia, mês e feriados.*

Dados de entrada da RNA

Os dados de entrada desta rede correspondem aos mesmos usados na rede anterior. A diferença se refere à concatenação da informação das variáveis “hora”, “dia”, “mês” e “feriados”. A finalidade desta concatenação é obter um melhor uso computacional, por causa de não se ter melhor recurso computacional como detalhado na figura 24.

Figura 24 - Rede 2: Relação de entrada - saída da rede neural.



Fonte: Elaboração do autor.

A configuração dos parâmetros encontra-se descrita na tabela 4:

Tabela 4 - Rede 2: Parâmetros configurados

Parâmetros configurados	
% Dados para treinamento	70
% Dados para teste	15
% Dados para validação	15
Número de neurônios da camada escondida	20
Numero de retardos (<i>delays</i>) usados	7

Fonte: Elaboração do autor.

Treinamento

Nesta rede, durante o processo de treinamento foram utilizadas as seguintes configurações:

- **Algoritmo de treinamento:** *Levenberg-Marquardt*, função Trainlm do Toolbox de redes neurais do aplicativo de simulação MATLAB;
- **Funções de transferência utilizadas:** Tan-Sigmoid \mathcal{f} na primeira camada, na segunda camada oculta Purelin \mathcal{I} e Purelin na camada de saída.
- **Número de camadas ocultas:** Uma camada oculta, com 20 neurônios.

4.1.4.3 *Rede 3: Rede neural com entrada individual para demanda, preços, geração térmica, geração hidráulica e um conjunto concatenado da variáveis hora, dia, mês e feriados.*

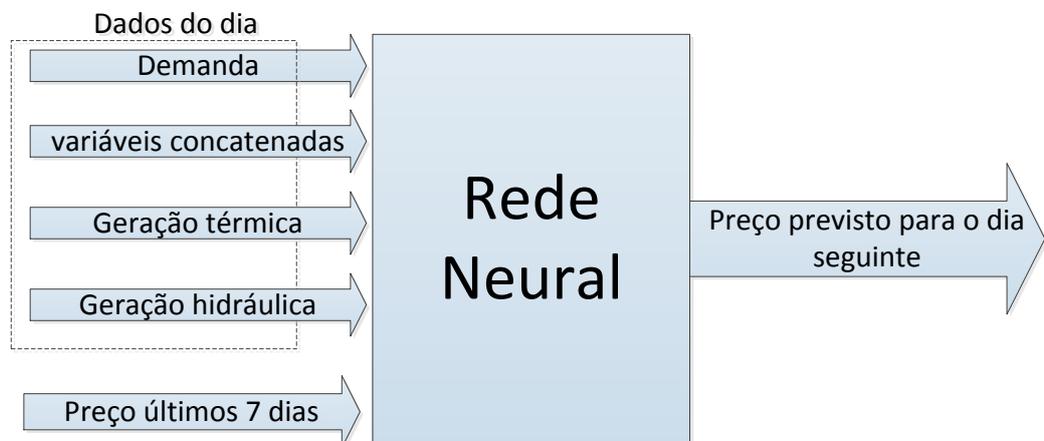
Dados de entrada da RNA

Embora seja verdade que a demanda desempenha um papel importante na determinação do preço da energia, é importante considerar o conjunto de tecnologias utilizadas em um momento t para a produção de eletricidade. A Bolívia possui seis (6) usinas hidráulicas e dezessete (17) usinas térmicas, o que demonstra que a matriz energética do país depende principalmente da energia térmica gerada por combustíveis fósseis (gás, petróleo e biomassa).

A energia hidráulica é mais barata que a energia térmica. No despacho realizado diariamente, as unidades geradoras são despachadas por ordem de mérito, gerando sempre na base a energia mais barata e a mais cara cobrem o resto da demanda do dia.

Assim, para cada período do dia a eletricidade é gerada com diferentes percentuais de cada tecnologia e o preço do MWh também será diferente tal como se observa na figura 26. É por isso que estas variáveis são incluídas neste modelo de rede neural, a fim de alcançar uma maior precisão na previsão.

Figura 25 - Rede 3: Relação de entrada - saída da rede neural.



Fonte: Elaboração do autor.

A configuração dos parâmetros é mostrada na tabela 5:

Tabela 5 - Rede 3: Parâmetros configurados

Parâmetros configurados	
% Dados para treinamento	70
% Dados para teste	15
% Dados para validação	15
Número de neurônios da camada escondida	8
Número de retardos (<i>delays</i>) usados	35

Fonte: Elaboração do autor.

Treinamento

Nesta rede neural, durante o processo de treinamento, foram utilizadas as seguintes configurações:

- **Algoritmo de treinamento:** *Bayesian-Regulation*, função `trainbr` do Toolbox de redes neurais do aplicativo de simulação Matlab; nesta configuração escolheu-se este algoritmo por ter maior quantidade de dados e, portanto, trata-se de evitar o sobre-treinamento da rede.
- **Funções de transferência utilizadas:** Tan-Sigmoid  na primeira camada,  na segunda camada oculta e Purelin na camada de saída.
- **Número de camadas ocultas:** Uma camada oculta com oito neurônios.

4.1.4.4 *Rede 4: Rede neural com entrada individual para demanda, preços, geração térmica, geração hidráulica e um conjunto concatenado das variáveis hora, dia, mês e feriados.*

Como se mencionou anteriormente, antes de introduzir os dados à rede neural é recomendável realizar o tratamento dos mesmos.

As redes neurais são muito sensíveis à média e à variância que tenham as diferentes variáveis de entrada. Desta forma, se uma variável tem uma média e uma variância muito pequenas com respeito a outras variáveis, é possível que a rede neuronal não consiga estabelecer umas relações adequadas entre elas. Se for

aplicado um tratamento para estas variáveis de tal forma que tenham uma distribuição estatística comparável é possível que a predição melhore.

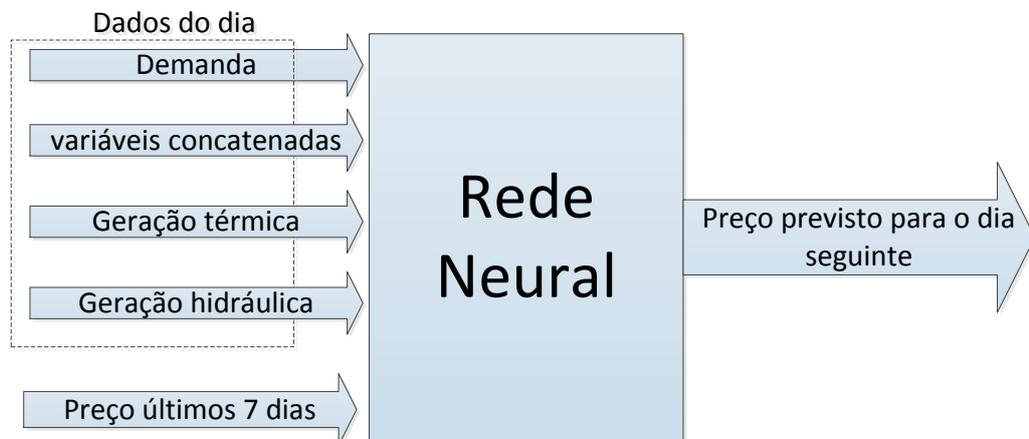
Para realizar este tratamento utilizou-se a função chamada “mapstd” da Toolbox de Redes Neurais do MATLAB. Esta função toma as variáveis de entrada da rede e as transforma em outras equivalentes com média nula e variância unitária. Desta forma, as predições deveriam ser mais precisas.

Dados de entrada da RNA

Igualmente à rede anterior, deve-se levar em as seguintes variáveis de entrada, ver figura 28:

- Demanda;
- Geração Térmica;
- Geração Hidráulica;
- Preço há 30 dias.

Figura 26 - Rede 4: Relação de entrada - saída da rede neural.



Fonte: Elaboração do autor.

A configuração dos parâmetros usada neste experimento encontra-se relacionada na Tabela 6:

Tabela 6 - Rede 4: Parâmetros configurados

Parâmetros configurados	
% Dados para treinamento	70
% Dados para teste	15
% Dados para validação	15
Número de neurônios da camada escondida	4
Numero de retardos (<i>delays</i>) usados	30

Fonte: Elaboração do autor.

Treinamento

Durante o processo de treinamento foram utilizadas as seguintes configurações:

- **Algoritmo de treinamento:** *Levenberg-Marquardt*, esta configuração é escolhida, principalmente, por causa de sua rápida convergência e produzir pequenos erros.
- **Funções de transferência utilizadas:** Tan-Sigmoid  na primeira camada, na segunda camada oculta Purelin  e Purelin na camada de saída.
- **Numero de camadas ocultas:** Uma camada oculta com oito neurônios.

4.2 Rede neural reconhecimento de padrões

Neste caso, realizar a previsão de preços mediante o reconhecimento de padrões foi possível tratando os dados conforme mostrado a seguir.

Primeiramente definiram-se as seguintes variáveis com as que se treinará a rede.

1. Geração hidráulica;
2. Geração térmica;
3. Preços anteriores
4. Dia da semana;
5. Mês do ano;
6. Dia feriado;
7. Demanda.

Considerando o desenvolvimento anterior, a estrutura da rede ficou da seguinte forma descrita na figura 30:

Figura 27 - Estrutura da rede por reconhecimento de padrões



Fonte: Elaboração do autor.

Na Figura 30 mostram-se os dados de entrada, os quais são introduzidos na rede com dois “*delays*”, obtendo como saída única, um dia à frente considerando-se um período de 24 horas.

Assim, se tem um vetor de entradas de 200 linhas com uma coluna, e um vetor de saída com 24 linhas e uma coluna. Desta forma, este vetor deve ser construído para cada um

dos dias. Além disso, deve ser criada uma matriz para a entrada com 200 linhas e **D** colunas onde **D** é o número de dias usados para realizar a previsão. Igualmente para a saída deve ser construída uma matriz com 24 linhas e **D** colunas.

É importante mencionar que a codificação para os dias da semana, nos meses do ano, é realizada utilizando-se codificação binária, tal como se apresentada na Tabela 1 e na Tabela 2.

Tabela 7 - Codificação para os dias da semana.

Dia	Codificação
Domingo	001
Segunda-feira	010
Terça-feira	011
Quarta-feira	100
Quinta-feira	101
Sexta-feira	110
Sábado	111

Fonte: Elaboração do autor.

Tabela 8 - Codificação para dos meses do ano

Mês	Codificação
Janeiro	0001
Fevereiro	0010
Março	0011
Abril	0100
Mai	0101
Junho	0110
Julho	0111
Agosto	1000
Setembro	1001
Outubro	1010
Novembro	1011
Dezembro	1100

Fonte: Elaboração do autor.

Depois de se dispor os dados para treinar, devem-se especificar os seguintes parâmetros para proceder com o treinamento.

1. Número de camadas internas (escondida);
2. Número de *delays*;

3. Porcentagem dos dados usados para o treinamento;
4. Tipo de algoritmo de treinamento.

Para ter uma boa aproximação dos valores que cada um destes parâmetros deve ter, procedeu-se a realização de um experimento fatorial 2^k , com os níveis mostrados na seguinte Tabela 9, usando, como variável de resposta, o valor MSE (Mean Squared Error) dos valores de prova (Teste de avaliação) usados pelo algoritmo de treinamento.

Tabela 9 - Experimento fatorial

Nível	Número de camadas internas	Número de <i>delays</i>	Porcentagem de dados usados para o treinamento	Tipo de algoritmo de treinamento
Baixo	5	2	50	Levenberg-Marquardt (trainlm)
Alto	15	7	80	Bayesian regulation backpropagation (trainbr)

Fonte: Elaboração do autor.

Deste jeito obtiveram-se os resultados apresentados a continuação:

Tabela 10 - Resultados

Nº de prova	Número de camadas internas	Número de <i>delays</i>	Porcentagem de dados usados para o treinamento	Tipo de algoritmo de treinamento	Valor MSE
1	5	2	50	trainlm	0.020108
2	5	2	50	trainbr	0.006444
3	5	2	80	trainlm	0.024614
4	5	2	80	trainbr	0.007611
5	5	7	50	trainlm	0.011765
6	5	7	50	trainbr	0.007207
7	5	7	80	trainlm	0.013110
8	5	7	80	trainbr	0.005549
9	15	2	50	trainlm	0.005139
10	15	2	50	trainbr	0.004649
11	15	2	80	trainlm	0.011741
12	15	2	80	trainbr	0.005734
13	15	7	50	trainlm	0.010350
14	15	7	50	trainbr	0.005276
15	15	7	80	trainlm	0.012771
16	15	7	80	trainbr	0.005883

Fonte: Elaboração do autor.

Por meio destes resultados, obteve-se a Tabela 11 com a análise de variância dos resultados.

Tabela 11 - Resultados análises de variância.

Fonte de variação	Soma de Quadrados	Grau de Liberdade	Quadrado Médio	Valor de distribuição F	Probabilidade	Significância com 95% (Valores < 0.05)
Número de camadas internas	7.59739E-05	1	7.59739E-05	5.37	0.0408	Significativo
Número de <i>delays</i>	1.24767E-05	1	1.24767E-05	0.88	0.368	No Significativo
Porcentagem de dados usados para o treinamento	1.61488E-05	1	1.61488E-05	1.14	0.3084	No Significativo
Tipo de algoritmo de treinamento	0.000234444	1	0.000234444	16.56	0.0019	Significativo
Resíduo	0.000155759	11	1.41599E-05			
TOTAL	0.000494803	15				

Fonte: Elaboração do autor.

Pelos resultados obtidos, observa-se que os parâmetros que mais possuem importância para o treinamento deste tipo de rede neural, com estes dados fornecidos são:

- Número de camadas internas;
- Tipo de algoritmo de treinamento.

Como a probabilidade é menor que 0,05 e, de acordo com comparação de médias obteve-se uma média, dada pelo algoritmo de treinamento trainbr, de 0.00604391, a qual é menor que o dado por trainlm que foi de 0.0136997. Portanto, deduz-se que, neste caso, o algoritmo trainbr apresenta melhor desempenho.

Neste sentido, analisando o número de camadas internas tem-se que para um número de 15 obteve-se um menor valor do MSE. No obstante, não se tem a certeza que o valor de 15 seja o melhor. Portanto, realizaram-se outra série de experimentos variando este fator desde 10 camadas internas até 35, com variações entre níveis de cinco. Quanto aos outros parâmetros fixaram-se da seguinte maneira

- **Número de *delays*:** dois, Escolheu-se este valor já que seu efeito não é estatisticamente significativo. Portanto, poucos delays não precisam de uma grande capacidade de cálculo.
- **Percentagem de dados usados para o treinamento:** Fixou-se o valor em 80 para que o algoritmo tenha uma maior quantidade de dados para se treinar.
- **Tipo de algoritmo de treinamento:** Como se mencionou anteriormente, utilizar-se-á o *trainbr*.

Na tabela 12 mostram-se os resultados para a nova série de experimentos.

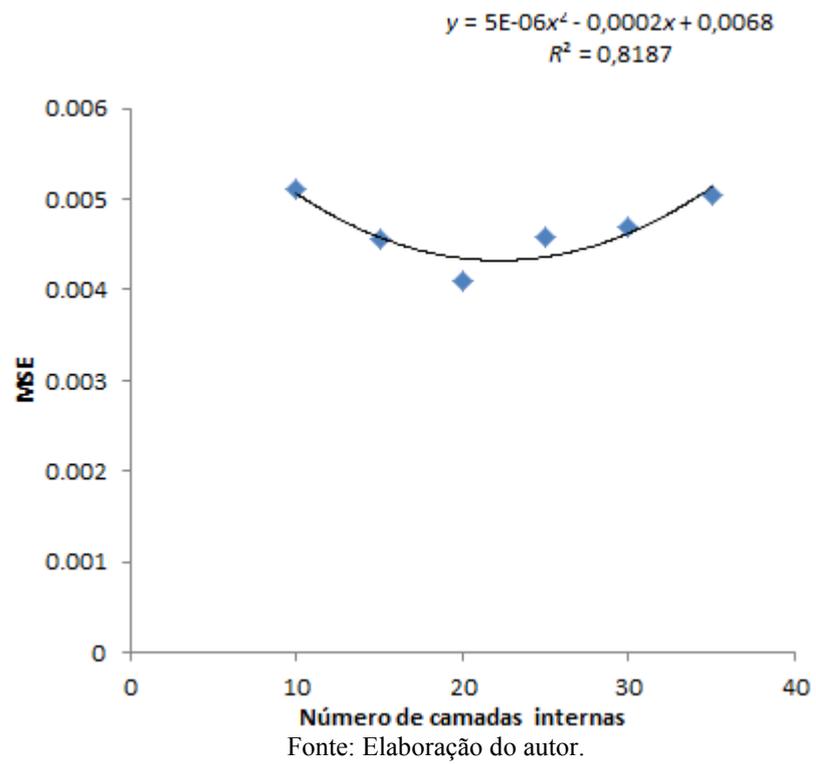
Tabela 12 - Resultados.

Camadas Internas	MSE
10	0,005118946
15	0,004564346
20	0,004093173
25	0,004579743
30	0,004692081
35	0,005052804

Fonte: Elaboração do autor.

Traçando os dados anteriores tem-se, então, a Figura 28. Observa-se na Tabela 12 que o valor do MSE diminui até ao redor de um valor de 20 camadas internas. Depois deste ponto, os valores aumentam ligeiramente com o aumento do número de camadas internas e requer uma maior capacidade computacional, pelo que este foi o ponto escolhido.

A rede definitiva a ser usada incluirá 20 camadas internas, dois *delays*, 80% de dados usados para o treinamento e se utilizará o algoritmo *Bayesian regulation backpropagation* (*trainbr*).

Figura 28 - Resultados N fatorial.

5 RESULTADOS

A seguir, apresentam-se os resultados para a cada uma das topologias mencionadas anteriormente. Para cada uma das redes, foram calculados os erros, utilizando o índice MAPE.

5.1 Resultados rede NARX

5.1.1 Rede 1- NARX

Idealmente, a princípio tinha-se a intenção de usar uma maior quantidade tanto de neurônios escondidos, bem como de dados para o treinamento da rede neural. Não obstante em consequência das limitações computacionais, só foi possível usar a configuração descrita anteriormente.

Desta maneira, procedeu-se a predição de alguns dos dados apresentados no ano 2013.

Esta comparação entre a predição e os dados reais é mostrada na Figura 29. O MAPE obtido encontra-se indicado na tabela 12.

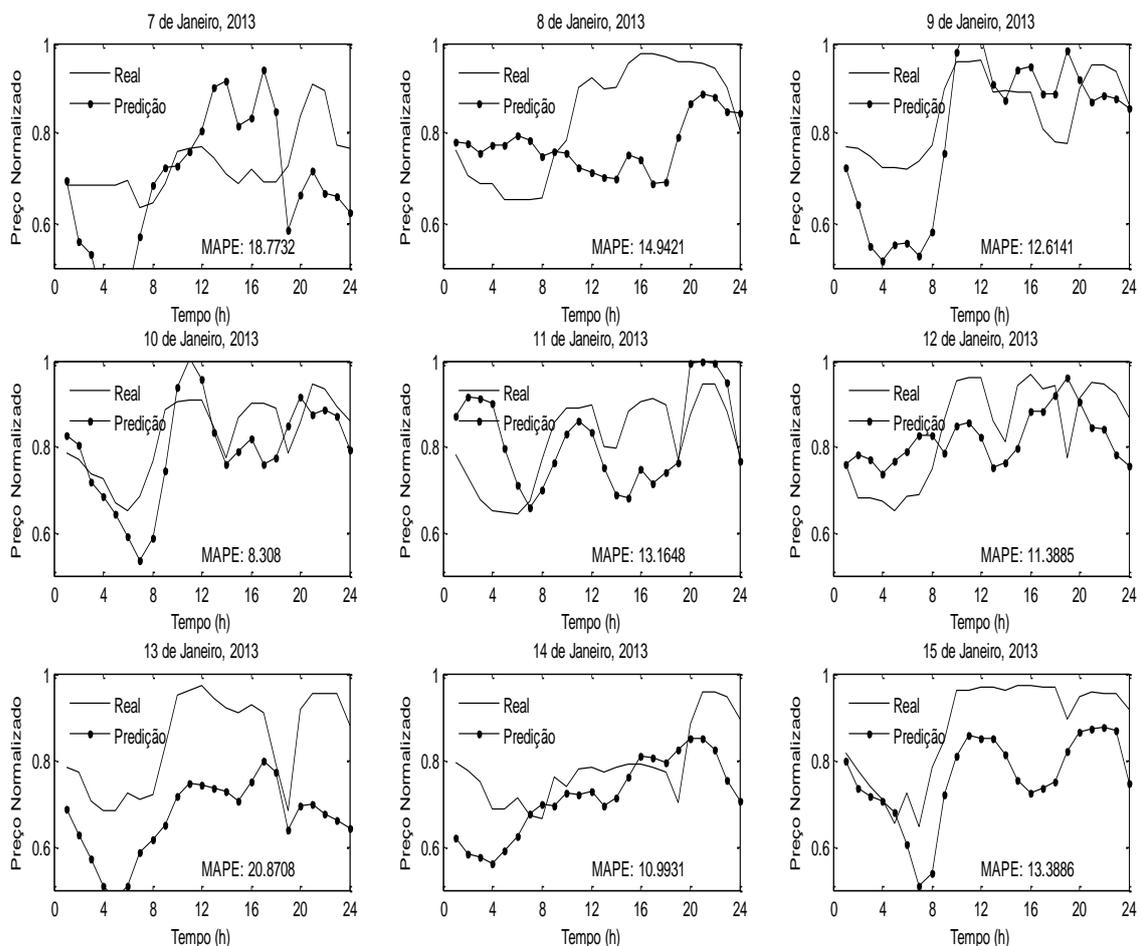
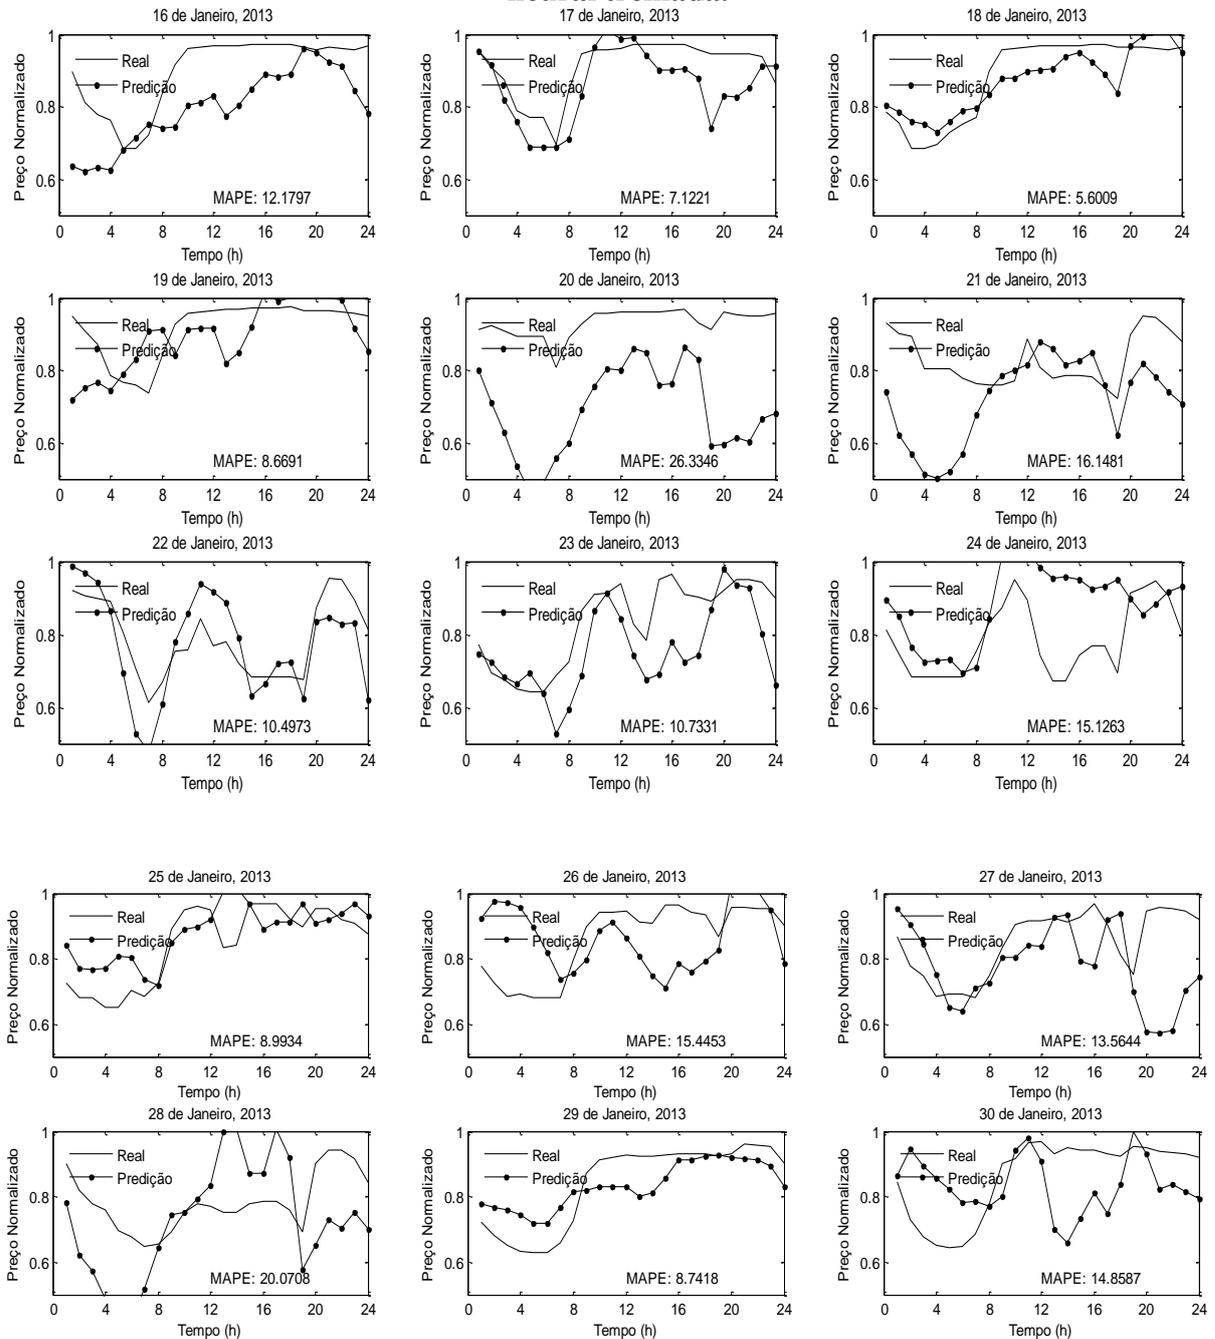


Figura 29 - Previsões para alguns dias do ano de 2013 realizadas pela primeira rede neural treinada.



Fonte: Elaboração do autor.

Tabela 13 - Resultado MAPE rede 1.

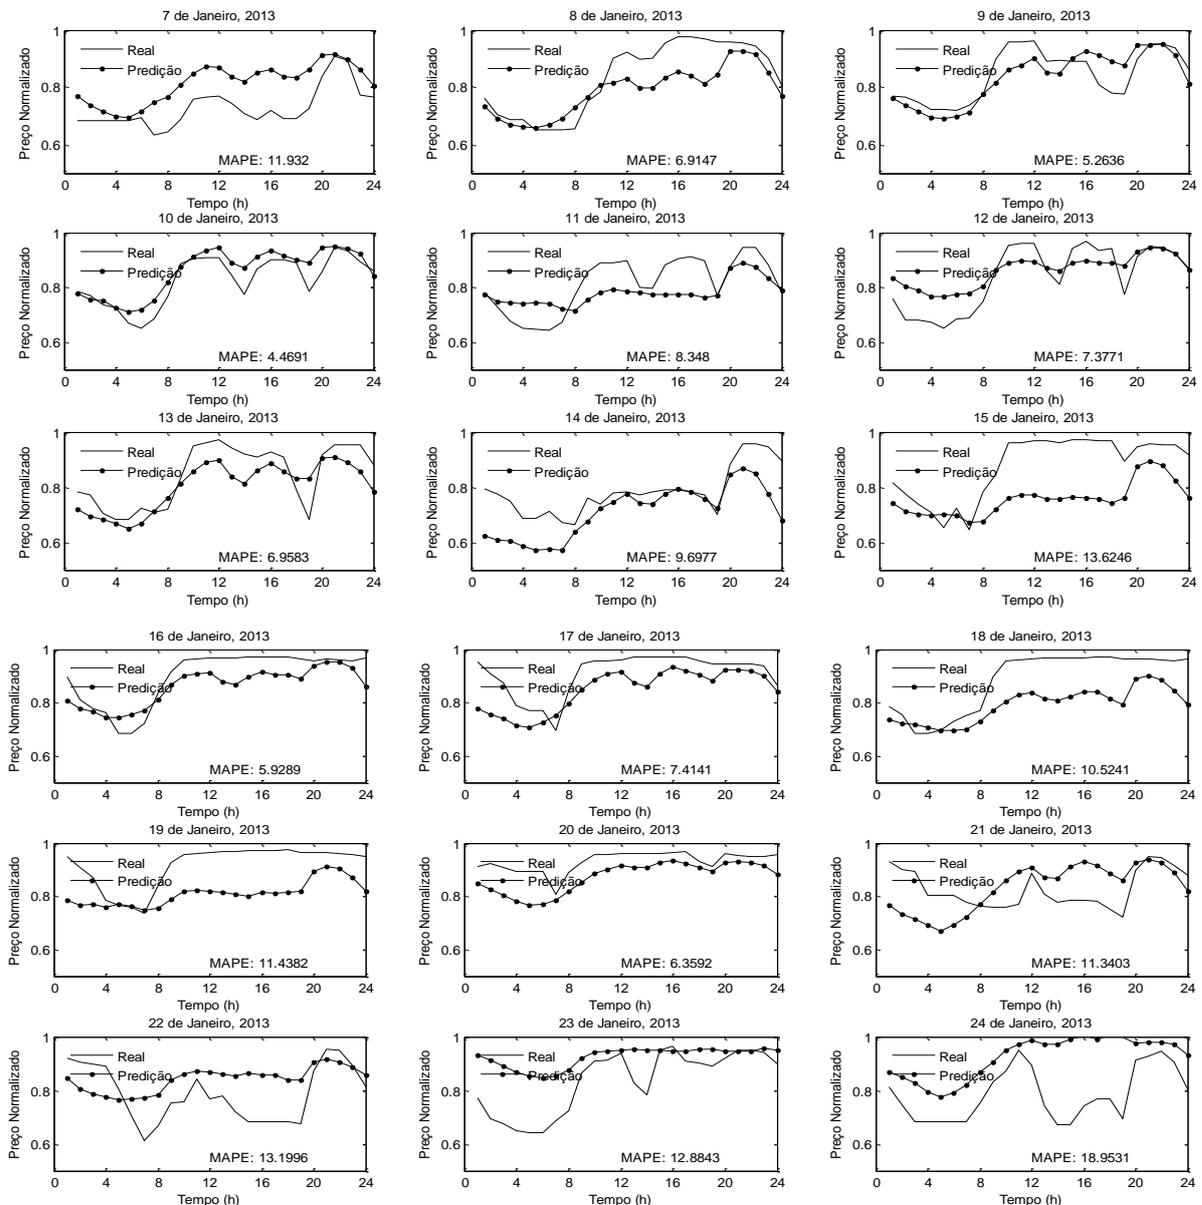
Erro	Resultado
MAPE (%)	13,2721

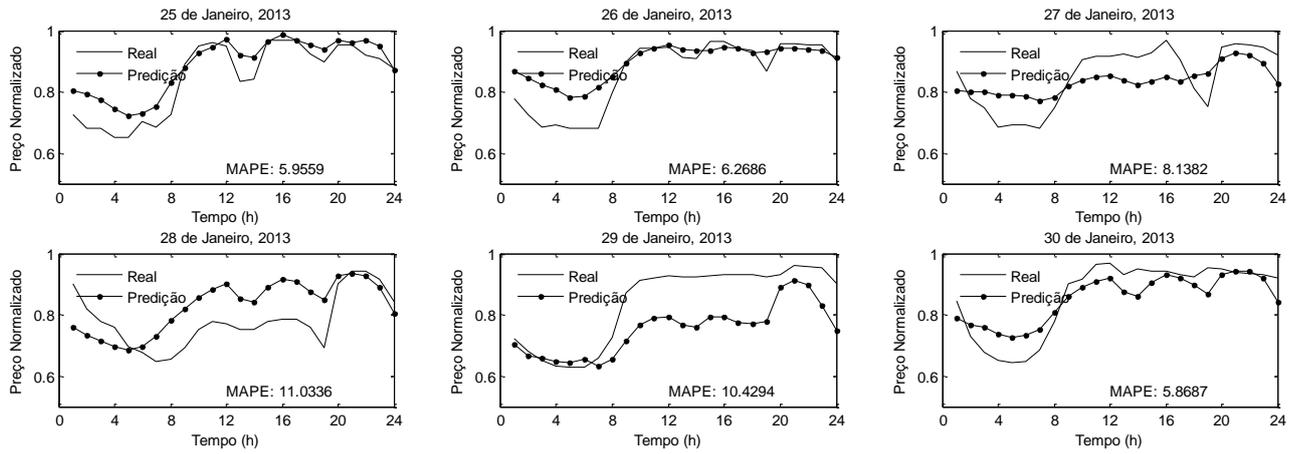
Fonte: Elaboração do autor.

5.1.2 Rede 2 - NARX

A previsão foi comparada com o mês de janeiro de 2013. Foram obtidos os seguintes dados e erros, figura 30 e o resultado do MAPE se amostra na tabela 14:

Figura 30 - Previsões para alguns dias do ano de 2013 realizadas pela segunda rede neural treinada.





Fonte: Elaboração do autor.

Tabela 14 - Resultado MAPE rede 2.

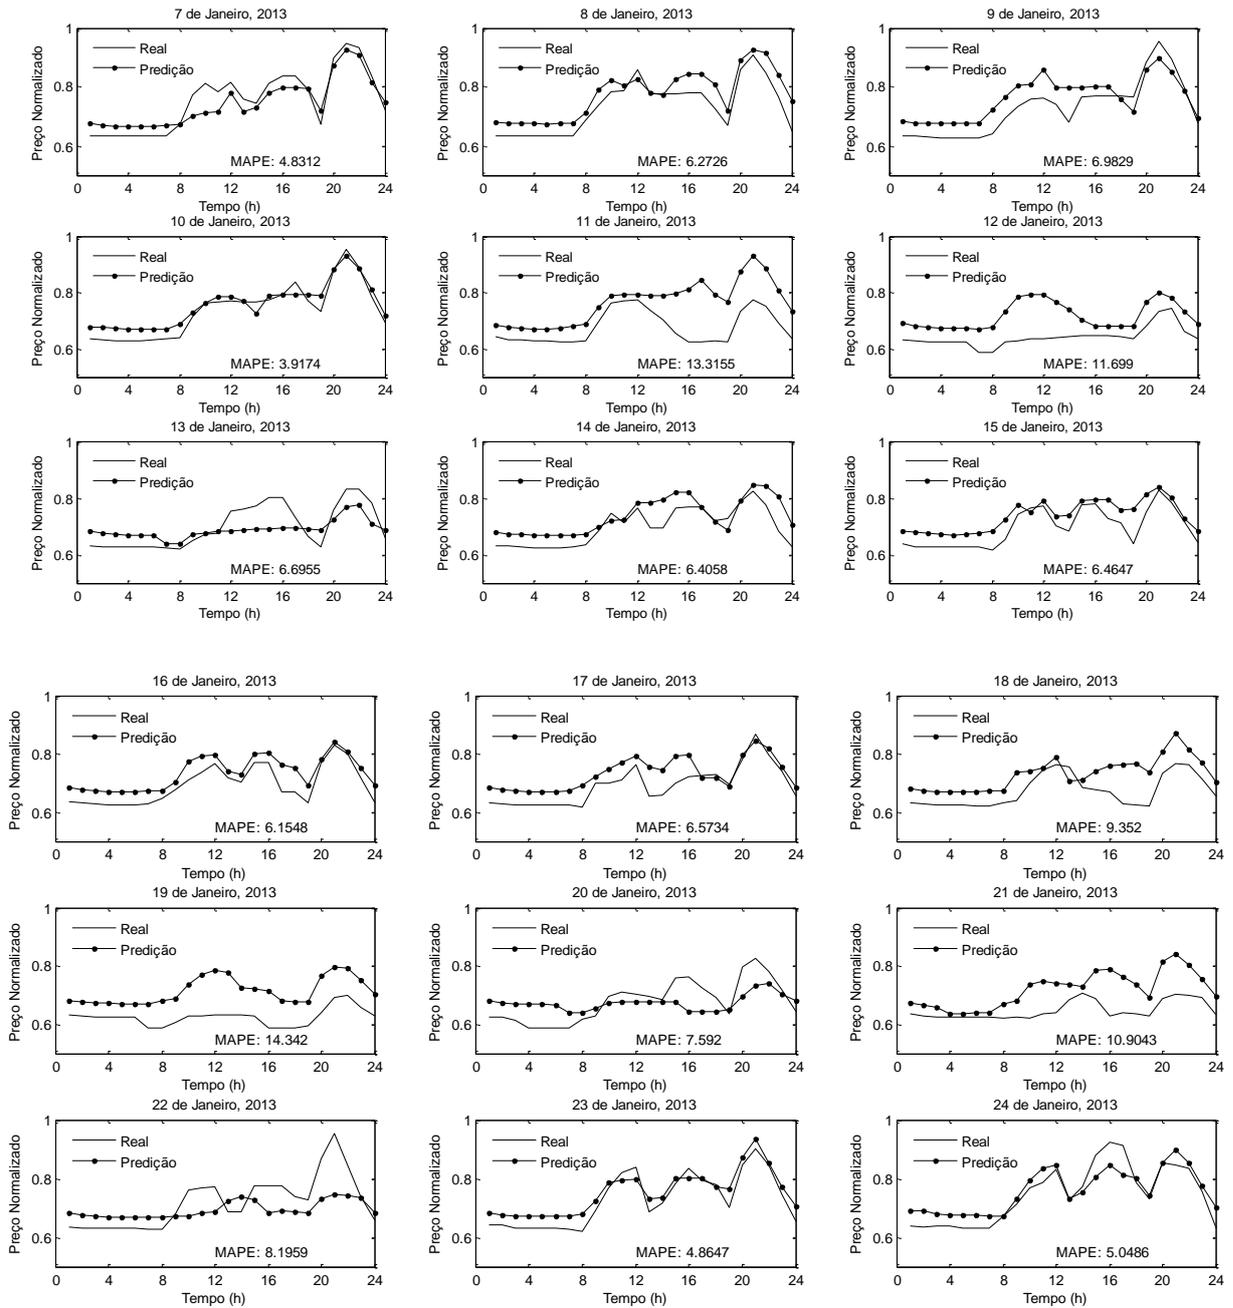
Erro	Resultado
MAPE (%)	9,1775

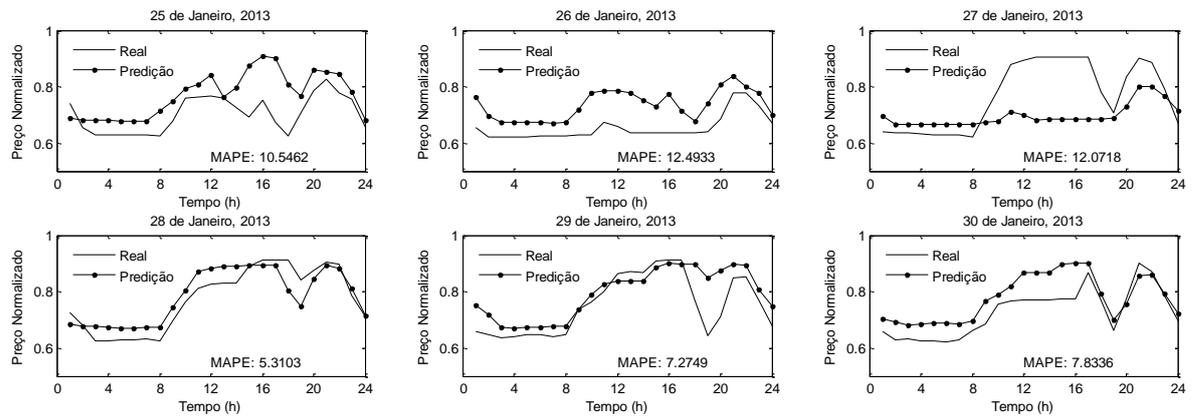
Fonte: Elaboração do autor.

5.1.3 Rede 3 - NARX

Os resultados obtidos para esta rede são os seguintes, apresentados na figura 31 e a tabela 15:

Figura 31 - Previsões para alguns dias do ano de 2013 realizadas pela terceira rede neural treinada.





Fonte: Elaboração do autor.

Tabela 15 - Resultado MAPE rede 3.

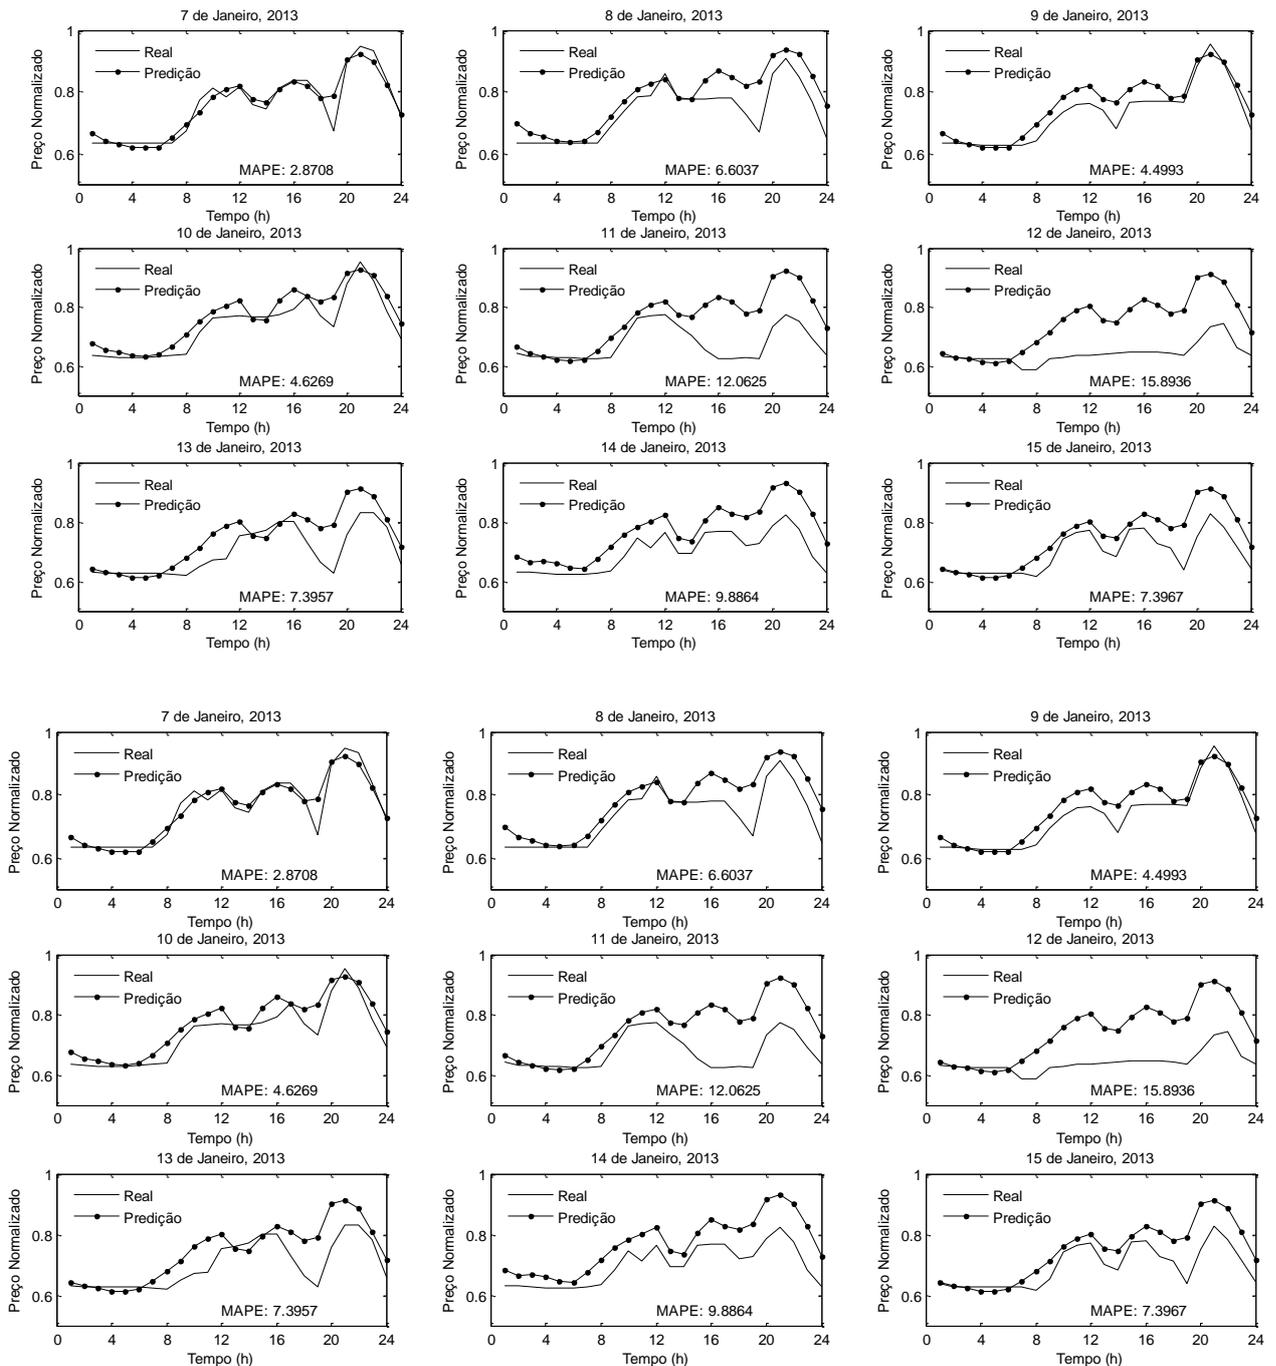
Erro	Resultado
MAPE (%)	7,88

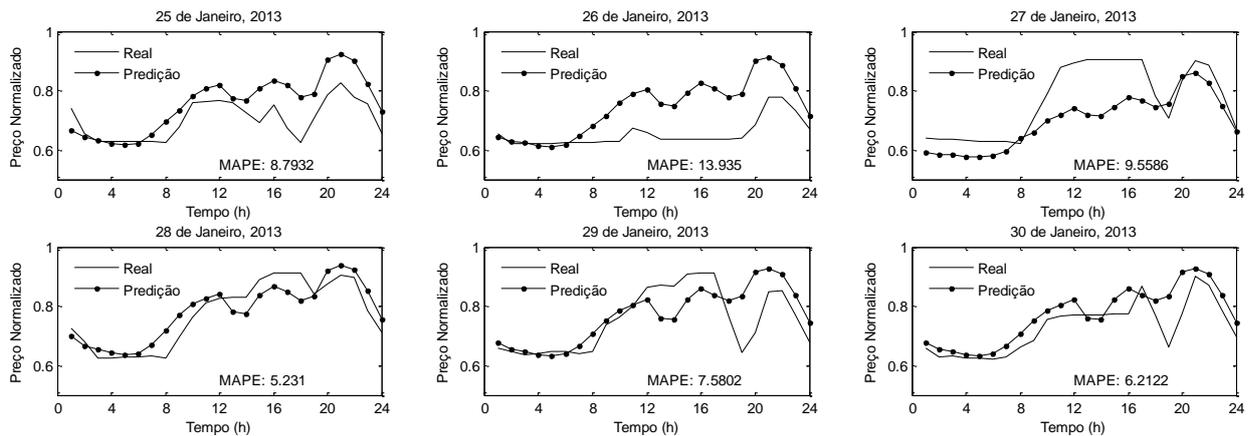
Fonte: Elaboração do autor.

5.1.4 Rede 4 - NARX

Nesta rede foi realizado um tratamento prévio aos dados primeiramente e obtiveram-se os seguintes resultados, apresentados na figura 32 e na Tabela 16:

Figura 32 - Previsões para alguns dias do ano de 2013 realizadas pela quarta rede neural treinada.





Fonte: Elaboração do autor.

Tabela 16 - Resultado MAPE rede 4.

Erro	Resultado
MAPE (%)	8,0736

Fonte: Elaboração do autor.

Na tabela 17, observam-se os resultados obtidos para a cada topologia:

Tabela 17 - Resultados para cada topologia.

Configuração Rede	MAPE
Rede 1	13,2721
Rede 2	9,1775
Rede 3	7,8821
Rede 4	8,0736

Fonte: Elaboração do autor.

De acordo com os resultados dos erros calculados, evidencia-se que a rede que apresentou o melhor resultado apresenta é a rede neural 3, isto é, pela inclusão das variáveis suficientemente significativas o qual evidentemente influi num melhor resultado.

5.2 Resultados rede, reconhecimento de padrões.

A seguir mostram-se os resultados obtidos para o mês de janeiro do ano 2013. O valor de MAPE foi calculado de acordo com a seguinte equação.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Real - Pred.}{Real} \right| \times 100$$

Tomou-se como exemplo no dia segunda-feira 07 de janeiro de 2013 se obtivendo os seguintes resultados, apresentados na tabela 18:

Tabela 18 - Resultados.

Previsão	Real	% Desvio $\left \frac{Real - Previsto}{Real} \right \times 100$
0,66553502	0,63457696	4,87853387
0,64750528	0,63309018	2,27694175
0,63607261	0,63309018	0,47109112
0,62850355	0,63309018	0,72448305
0,62739892	0,63309018	0,89896615
0,62693488	0,63309018	0,97226389
0,61696422	0,63309018	2,54718287
0,64535289	0,67420899	4,27999333
0,68280019	0,77349812	11,72568189
0,71199396	0,81280491	12,40284632
0,72722718	0,78474190	7,32912675
0,73517394	0,81601078	9,90634513
0,69716329	0,75784045	8,00658802
0,69168374	0,74394833	7,02529953
0,72358908	0,81382707	11,08810423
0,73792328	0,83821958	11,96539679
0,73004582	0,83821958	12,90518162
0,70733997	0,79064257	10,53606280
0,70447352	0,67383729	4,54653187
0,84461357	0,89871300	6,01965589
0,87720380	0,94768387	7,43708665
0,85070527	0,93560377	9,07419392
0,76878631	0,83710449	8,16124960
0,69410926	0,72081030	3,70430899
	Soma	158,883116

Fonte: Elaboração do autor.

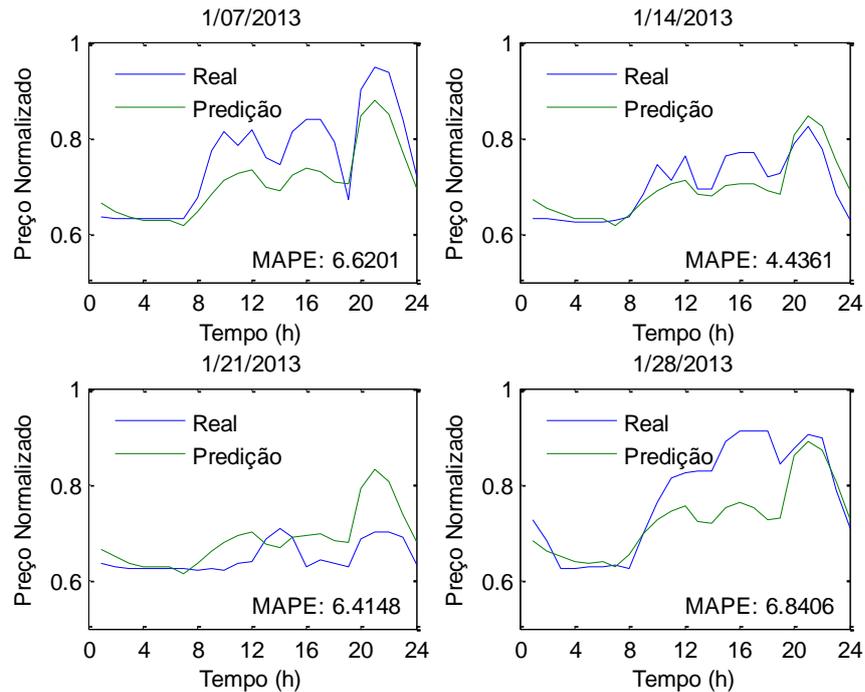
Portanto:

$$MAPE = \frac{158.883116}{24} = 6,6201\%$$

Os dados podem ser observados na figura 33:

Segunda-feira:

Figura 33 - Previsão Segunda-Feira.

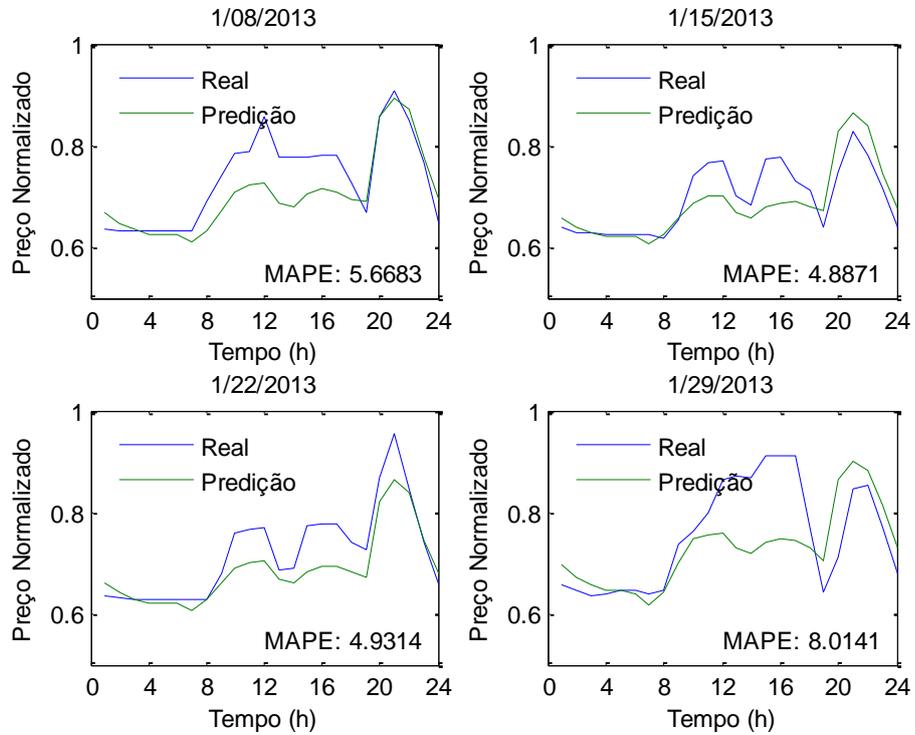


Fonte: Elaboração do autor.

Para ter certeza que o método estava funcionando com outros dias, se obtiveram-se os seguintes resultados, mostrados na figura 34:

Terça-feira:

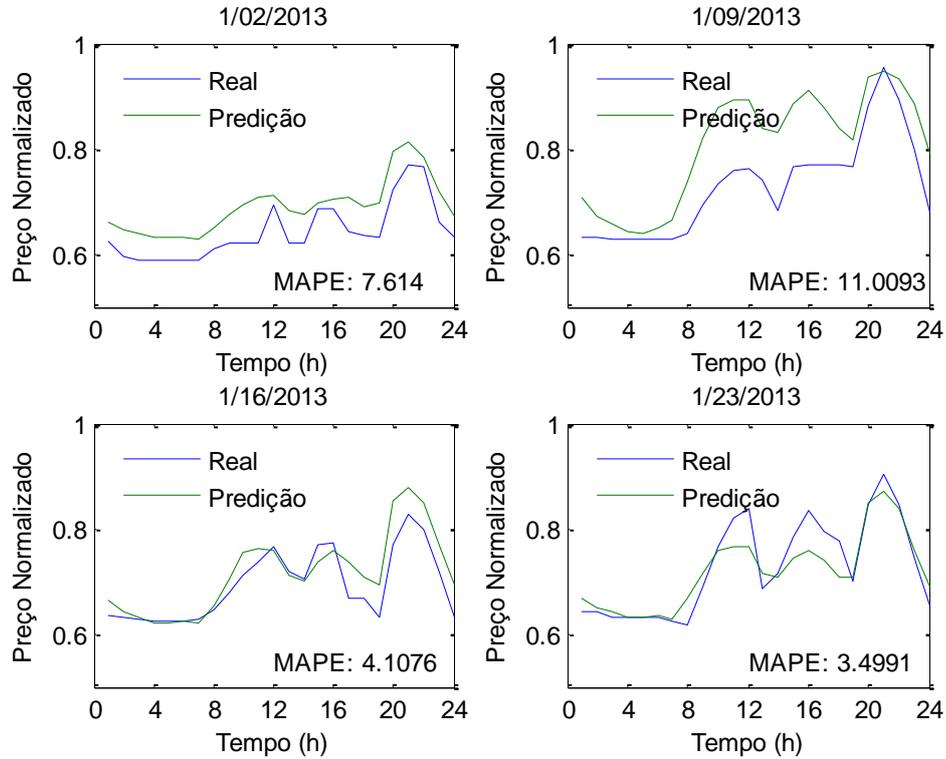
Figura 34 - Previsão Terça-feira



Fonte: Elaboração do autor.

Quarta-feira:

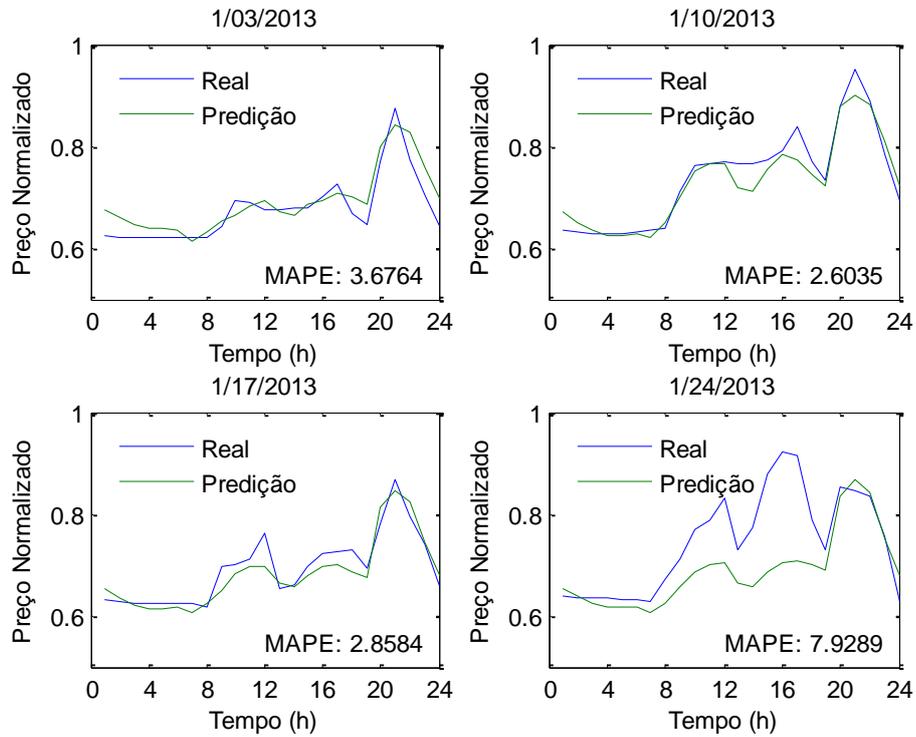
Figura 35 - Previsão Quarta-Feira



Fonte: Elaboração do autor.

Quinta-feira:

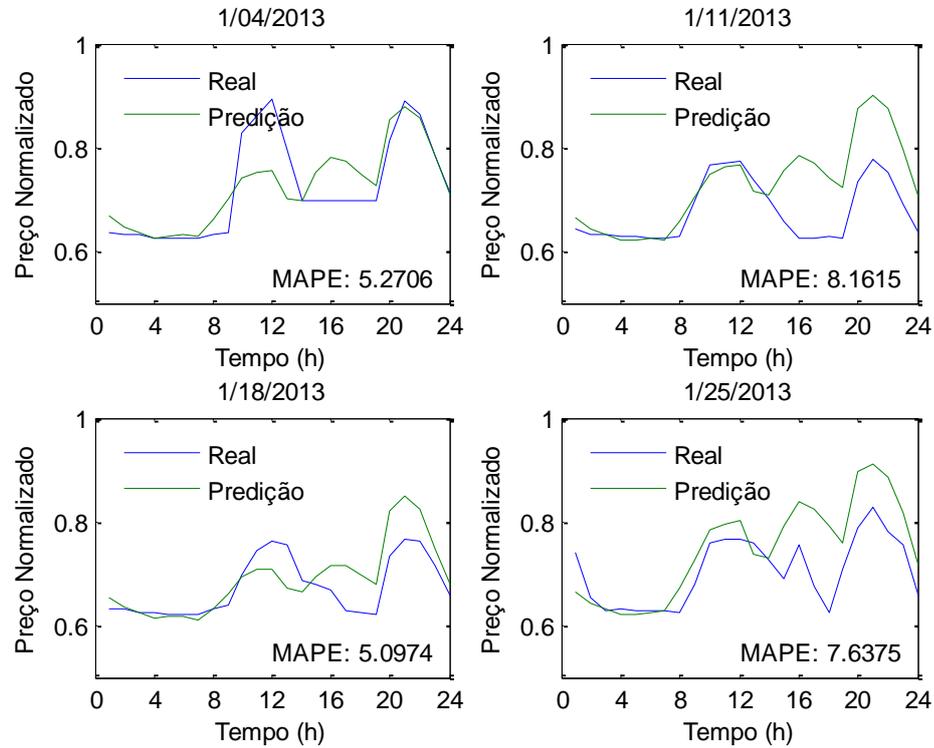
Figura 36 - Previsão Quinta-Feira.



Fonte: Elaboração do autor.

Sexta-feira:

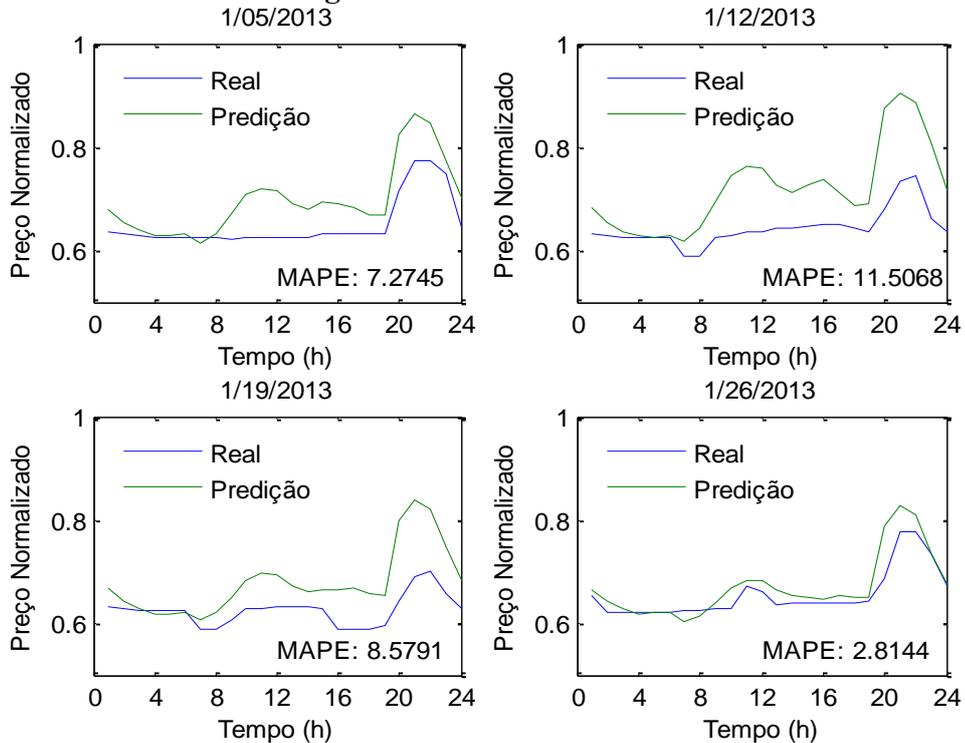
Figura 37 - Previsão Sexta-Feira



Fonte: Elaboração do autor.

Sábado:

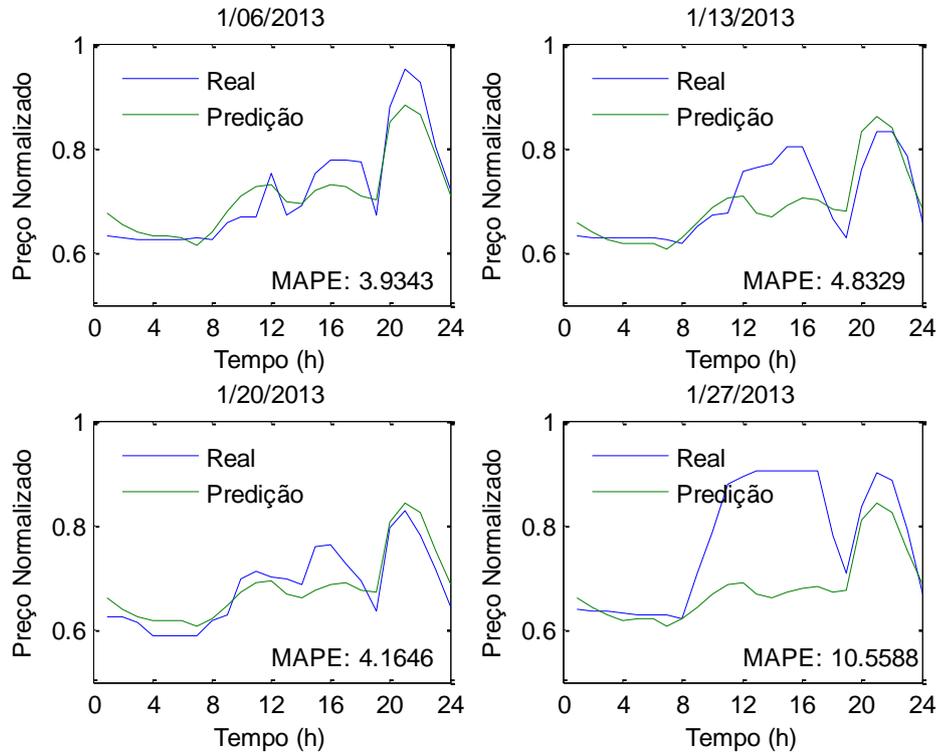
Figura 38 - Previsão Sábado



Fonte: Elaboração do autor.

Domingo:

Figura 39 - Previsão Domingo



Fonte: Elaboração do autor.

6 CONCLUSÃO

Ao realizar as previsões, demonstrou-se que é muito benéfico para as redes neurais aplicar um tratamento prévio aos dados a serem utilizados. Faz-se especialmente indicada a transformação das variáveis de entrada à rede de tal forma que todas tenham média nula e variância unitária. Ademais, a eliminação da tendência do preço da eletricidade para que tenha uma média estacionária melhora substancialmente as previsões. Também é conveniente eliminar, na fase de treinamento, os valores extremos que, às vezes, apresenta o preço da eletricidade, conhecidos como *spikes*.

Por conseguinte, isto explica porque os erros MSE são muito elevados nas primeiras configurações.

Na terceira configuração utilizou-se o algoritmo de treinamento bayesiano, por causa a que, nesta configuração, incluíram-se muitos mais dados e o objetivo principal foi reduzir o erro e evitar um possível excesso de treinamento. Porém, o custo computacional foi muito alto, mas mesmo assim o erro MSE melhora substancialmente em comparação com as duas redes anteriores; além disso, o número de *delays* utilizado foi muito alto.

É importante anotar que as previsões melhoraram quando se incluiu a informação do *mix* energético utilizado nos dias analisados na series de dados, confirmando que esta é uma das variáveis que proporciona maior impacto têm na formação do preço de *spot*.

Devem-se realizar a análise estatística de sensibilidade, para determinar se existem outras variáveis significativas que possam ajudar a melhorar a resposta da rede e melhorar o erro. Além, deve-se realizar outras configurações de rede neural.

Com o fim de obter melhores resultados, foi projetada desenhou-se uma rede neuronal com a estrutura de reconhecimento de padrões. Nesta rede foram utilizadas as mesmas variáveis das redes três e quatro, criando um vetor de entrada à rede; para criar a estrutura da rede realizou-se um experimento fatorial 2k com o qual se identificou que os parâmetros que mais possuem importância são o número de camadas e o tipo de algoritmo de treinamento.

Assim, realizou-se um experimento de sensibilidade para identificar qual seria o melhor valor de camadas internas, obtendo que o valor do MSE diminui até um valor de 20 camadas internas. Depois deste ponto, os valores aumentam ligeiramente com o aumento do número de camadas internas e requer uma maior capacidade computacional, pelo que este foi o ponto escolhido e o algoritmo escolhido foi o *Bayesian regulation backpropagation* (trainbr).

Finalmente, o resultado, obtido com esta rede neural, melhorou em comparação com os resultados das redes anteriores.

Para trabalhos futuros sugere-se incluir informação de outras variáveis que influem na formação do preço *spot* da energia, tal como os preços dos combustíveis e topologia da rede de transmissão, tendo em conta que esta última pode impactar significativamente no despacho de geração, mas cara para o mercado.

REFERÊNCIAS

ANGELUS, A. Electricity price forecasting in deregulated markets. **The Electricity Journal**, Philadelphia, v. 46, n. 4, p. 32-41, abr. 2001.

AMJADY, N.; KEYNIA, F. Day-ahead price forecasting of electricity markets by mutual information technique and cascaded neuro-evolutionary algorithm. **IEEE Transactions on Power Systems**, Piscataway, v. 24, n. 1, p. 306-318, fev. 2009.

BASTIAN, J.; ZHU, J.; BANUNARAYANAN, V.; MUKERJI, R. Forecasting energy prices in a competitive market. **IEEE Computer Application in Power**, Piscataway, p. 40-45, jul. 1999.

BERTONA, L. F. **Entrenamiento de redes neuronales basado en algoritmos evolutivos**. [S. l.: s. n.], 2005.

BONIFACIO, M.; SANZ, A. **Redes neuronales y sistemas borrosos**. 3. ed. Ciudad del México: Alfaomega, 2007.

BOLÍVIA. Vicepresidencia del estado plurinacional de Bolivia. **Ley de electricidad nº1604**. La Paz, 1994.

CLAVEL, C. A. O. **Modelado y simulacion de un sistema de deteccion de intrusos utilizando redes neuronales recurrentes**. Ciudad del México: Universidad de las Américas, 2007.

CONTRERAS, J.; ESPÍNOLA, R.; NOGALES, F. J.; CONEJO, A. ARIMA models to predict next-day electricity prices. **IEEE Transactions on Power Systems**, Piscataway, v. 18, n. 3, p. 1014–1020, ago. 2003.

DÍAZ, A. **Diseño estadístico de experimentos**. 2 ed. Bogotá: Editorial Universidad de Antioquia, 2009.

ESPINOLA, R. **Predicción a corto plazo de los precios de la energía eléctrica**. Madri: [s. n.], 2004.

FISHER, R. A. Applications of “student’s” distribution. **Metron**, Heidelberg, v. 5, n. 3, p. 90–104, 1925.

FLORES, U. **Identificación de sistemas no lineales mediante las estructuras NARX y Hammerstein-Wiener**. Cuernavaca: [s. n.], 2011.

FLOREZ, R; FERNANDEZ, J., **Las redes neuronales artificiales, fundamentos teóricos y aplicaciones prácticas**. Madri: Netbiblo, 2008.

GARCÍA, D; CABRERA, A. **Predicción de la demanda eléctrica de corto plazo mediante redes neuronales artificiales**. Madri: [s. n.], 2003.

- GARETA, R.; GIL, A.; MONZÓN, A.; ROMEO, L. Las redes neuronales como herramienta para predecir el precio de la energía eléctrica. **Energía: Ingeniería energética y medioambiental**, año 30, n. 180, p. 67-72, 2004.
- GAO, A. **Forecasting power market clearing price and quantity using a neural network method**. Piscataway: IEEE, 2000.
- GILES, C. L.; HORNE, B. G. **Representation and learning in recurrent neural network architectures**. [S. l.: s. n.], 1994.
- HEIZER, J., RENDER, B. **Principios de administración de operaciones**. 5. ed. Ciudad del Mexico: Pearson Educación, 2004.
- HONG, Y.; LEE, C. A neuro-fuzzy price forecasting approach in deregulated electricity markets. **Electric Power Systems Research**, Amsterdam, v. 73, n. 2, p. 151-157, fev. 2005.
- HORNE, B. G.; GILES, C. L. An experimental comparison of recurrent neural networks. in **Advances in Neural Information Processing Systems**, Maryland Heights, v. 7, p. 697-704, 1995.
- ISASI, V.; GALVÁN, L. **Redes neuronales artificiales: un enfoque práctico**. Madrid: Prentice Hall, 2004.
- AMORIM, A. A. **Desenvolvimento de uma rede neuro-fuzzy para a previsão da carga**. [S. l.: s. n.], 2015.
- JIMENEZ, F. **Elementos de teoría y políticas macroeconómicas para una economía abierta**. Lima: Pontificia Universidad Católica del Perú, 2012.
- KROSE, B. **An introduction to neural networks**. Amsterdam: The University of Amsterdam, 1996.
- KPALMA, K.; RONSIN, J. An overview of advances of pattern recognition systems in computer vision. In: OBINATA, G.; DUTTA, A. (Ed.) **Vision systems: segmentation and pattern recognition**. [s. l.]: I-Tech Education and Publishing, 2007. Cap. 10, p. 170-197.
- LOPEZ J. AND CAICEDO E. **Identificación de sistemas usando redes neuronales entrenadas con aprendizaje bayesiano**: memórias do Congresso Internacional de Inteligência Computacional. [S. l.: s. n.], 2007.
- LENNART LJUNG. **System identification toolbox**. [S. l.: s. n.], 2010.
- MARTINEZ, M. **Redes neuronales artificiales modulares: una posible especificación y su aplicación a problemas tecnológicos así como al modelado e implementación de funciones cognitivas**. Madri: [s. n.], 2006.
- MASTERS, T. **Practical neural network recipes in C++**. New York: Academic , 1993.

- MEDEIROS, L. **Previsão do preço spot no mercado de energia elétrica**. 2003. Tese (Doutorado em Engenharia Elétrica) - Pontifícia Universidade Católica, Rio de Janeiro, 2003.
- MENDOZA, H. **Diseño experimental**. Bogotá: [s. n.], 2015
- MILLAN, J.; VON DER, F.. **Keeping the Lights On: Power Sector Reform in Latin America**. Washington. D.C.: Inter-American Development Bank, 2003.
- MONTGOMERY, D. C. **Design and analysis of experiments and educational version of design expert (vol. 1997)**. New York: John Wiley & Sons, 1997.
- MUÑIZ, J. C. **Predicción del precio de la electricidad mediante redes neuronales**. Madrid: Universidad Pontificia de Comillas, 2010.
- NELLES, O. **Nonlinear system identification**. Berlin: Springer, 2001.
- NARDO, G.; ALIAGA, J. **Análisis y pronóstico de la demanda de potencia eléctrica en Bolivia: una aplicación de redes neuronales**. La Paz: [s. n.], 2010.
- NOGALES, F. J.; CONTRERAS, J.; CONEJO, A.; ESPÍNOLA, R. Forecasting next-day electricity prices by time series models. **IEEE Transactions on Power Systems**, Piscataway, v. 17, n. 2, p. 342–348, 2002.
- OLADE-CEPAL-GTZ. **Energía y desarrollo sustentable en américa latina y el caribe: guía para la formulación de políticas energéticas**. Santiago: CEPAL, 2003.
- BOLÍVIA. Presidencia de la República. **Decreto Supremo DS 26094 02 de marzo de 2001, Reglamento de precios y tarifas (RPT), PP 2**. La Paz, 2001.
- RODRIGUEZ, C. P.; ANDERS, G. J. **Energy price forecasting in the ontario competitive power system market**. Toronto: IEEE, 2003.
- RODRIGUEZ-TORO, V. A.; GARZON, J. E.; LOPEZ, J. A. Control neuronal por modelo inverso de un servosistema usando algoritmos de aprendizaje levenberg-marquardt y Bayesiano. In: CONGRESSO DA ASSOCIAÇÃO COLOMBIANA DE AUTOMÁTICA, 8., 2009, Cartagena. **Anales...** Cartagena: Universidade Tecnológica de Bolívar, 2009.
- ROMERO, H. **Identificación de sistemas utilizando redes neuronales**. Ciudad del México: [s. n.], 2008.
- RODRIGUEZ, J. **Determinación de precios del mercado eléctrico mayorista**. Santa Cruz: [s. n.], 2007.
- SANTOS, J. **Utilização de redes neurais artificiais na modelagem de processos bioquímicos**. [S. l.: s. n.], 2013.

SIEGELMANN, H. T.; HORNE, B. G.; GILES, C. L. Computational capabilities of recurrent NARX neural networks. **IEEE Trans. Syst. Man. Cybern. B. Cybern.**, Piscataway, v. 27, n. 2, p. 208–15, jan. 1997.

SZKUTA, B. R.; SANABRIA, L. A.; DILLON, T. S. Electricity price short-term forecasting using artificial neural networks. **IEEE Transactions on Power Systems**, Piscataway, v. 14, n. 3, p. 851-857, 1999.

SOUZA, C. S.; RESONSEW, I. D.; HENAO, J. V. ¿Por qué es tan difícil obtener buenos pronósticos de los precios de la electricidad en mercados competitivos?. **Cuadernos de administración**, Bogotá, v. 20, n 34, p. 259-282, jul./dez. 2007.

VOROPAI, N. I.; HANDSCHIN, E. J. Liberalization and modernization of power systems. **IEEE Power Engineering Review**, Piscataway, v. 21, n. 1, 2001.

VELÁSQUEZ J., R. DYNER AND R.C. SOUZA. **Predicción condicional del precio mensual de bolsa basada en Escenarios de Eventos Hidrológicos extremos.** In: SEMINARIO INTERNACIONAL SOBRE ANÁLISIS Y MERCADOS ENERGÉTICOS & I SEMINARIO CERES, 7., 2005, Bogotá. **Anales...** Bogotá: [s. n.], 2005.

VILLA, F. **Modelado y predicción del precio de la electricidad en mercados de corto plazo liberalizados usando redes cascadas correlación.** Medellín: [s. n.], 2010.

WASSERMAN, P. D. **Neural computing: theory and practice.** New York: Van Nostrand Reinhold, 1989.

WATANABE, S. **Pattern recognition: human and mechanical.** New York: [s. n.], 1985.