

UNIVERSIDADE FEDERAL DA PARAÍBA
CENTRO DE ENERGIAS ALTERNATIVAS E RENOVÁVEIS
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

Isaac Emmanuel Azevedo de Medeiros

**Aplicação de redes neurais artificiais para a
previsão de demanda em subestações de
distribuição considerando a influência da
temperatura**

João Pessoa
2019

Isaac Emmanuel Azevedo de Medeiros

**Aplicação de redes neurais artificiais para a previsão de
demanda em subestações de distribuição considerando a
influência da temperatura**

Trabalho de Conclusão de Curso apresentado
à Universidade Federal da Paraíba como exi-
gência para a obtenção do título de Bacharel
em Engenharia Elétrica.

Universidade Federal da Paraíba
Centro de Energias Alternativas e Renováveis
Curso de Graduação em Engenharia Elétrica

Orientador: Prof. Juan M. Maurício Villanueva

João Pessoa

2019

© Isaac Emmanuel Azevedo de Medeiros

Isaac Emmanuel Azevedo de Medeiros

Aplicação de redes neurais artificiais para a previsão de demanda em subestações de distribuição considerando a influência da temperatura/ Isaac Emmanuel Azevedo de Medeiros. – João Pessoa, 2019-
73 p. : il.

Orientador: Prof. Juan M. Maurício Villanueva

Trabalho de Conclusão de Curso – Universidade Federal da Paraíba
Centro de Energias Alternativas e Renováveis
Curso de Graduação em Engenharia Elétrica, 2019.

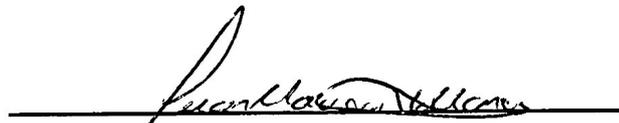
1.Previsão de Demanda. 2.Distribuição de Energia Elétrica. 3.Previsão de Séries Temporais. 4.Redes Neurais Artificiais 5.Inteligência Artificial

Isaac Emmanuel Azevedo de Medeiros

Aplicação de redes neurais artificiais para a previsão de demanda em subestações de distribuição considerando a influência da temperatura

Trabalho de Conclusão de Curso apresentado à Universidade Federal da Paraíba como exigência para a obtenção do título de Bacharel em Engenharia Elétrica.

Trabalho aprovado. João Pessoa, 10 de maio de 2019:


Prof. Juan M. Maurício Villanueva
Orientador


Prof. Helon David de Macêdo Braz
Examinador Interno UFPB


MSc. Pedro Henrique Meira de
Andrade
Examinador Externo

João Pessoa

2019

Agradecimentos

Agradeço primeiramente a Deus por tudo que Ele têm feito, e por ter me permitido chegar até aqui.

À minha querida mãe, pelo apoio indescritível e constante durante toda a minha existência. Sem ti, jamais teria alcançado meus objetivos.

À minha avó Conceição, por todo cuidado e dedicação.

Às minhas tias Karina e Patrícia, que sempre me deram todo amor e carinho.

A todos os demais membros da família que se fizeram presente na minha trajetória.

À Lívia, por todo amor. Obrigado pela paciência, companheirismo, carinho e cuidado.

Aos meus amigos Kaio, Jandilson, Josué, Darlan, Saul, Michael, Jesney e Thiago Moraes pela cumplicidade, parceria nos estudos e por terem feito meus dias de graduação na UFCG mais alegres.

Aos meus amigos Machado, Bruno, Do Ó, Vidal, Jonyelison, Lucas, Matheus, Sávio, Silveira, João, Vinícius, Milton e Henrique pela companhia nos estudos e momentos de lazer.

Aos meus amigos Carlinhos, Rafael, Amaury e Thiago Marinho pela boa convivência e momentos de felicidade.

Um agradecimento especial ao amigo Jean, que se mostrou extremamente leal e sempre me incentivou a buscar o melhor.

Ao professor Juan Maurício Villanueva, por ter sido um orientador extremamente solícito.

À Pedro Meira, por todas as contribuições neste trabalho.

Aos meus companheiros diários da Epasa, pela boa convivência. Em especial, muita gratidão por Carlos Araújo e Rodrigo Almeida, por contribuírem significativamente para o meu crescimento pessoal e profissional.

Por fim, a todos os que contribuíram direta ou indiretamente para a realização deste trabalho.

Resumo

Os estudos de previsão de demanda têm grande importância para empresas do ramo de energia elétrica, pois existe a necessidade de alocação de recursos com antecedência, exigindo um planejamento a médio e longo prazo. Tais recursos incluem a compra de equipamentos, aquisição e construção de linhas de transmissão, manutenções preventivas e comércio de energia. Diante disso, foi desenvolvida uma ferramenta computacional de apoio aos especialistas da área de planejamento estratégico em sistemas de distribuição elétrica, utilizando redes neurais artificiais para previsão de demanda, e incluindo a temperatura como fator externo. Na metodologia proposta, foi implementado um sistema de previsão a curto prazo para a subestação de Alto Branco (Centro), utilizando técnicas computacionais de inteligência artificial baseadas em redes neurais artificiais (RNA), com auxílio do software MATLAB®. Para isso, foram utilizados dados de potência ativa fornecidos pela concessionária de energia, e o histórico dos valores de temperatura locais foram obtidos via site do INMET, todos para o ano de 2008. A janela de previsão utilizada foi de 12 valores atrasados para fornecer um horizonte de 4 dias. Além disso, a acurácia das redes obtidas via treinamento foram medidas considerando o MAPE e erro relativo percentual.

Palavras-chave: Previsão de Demanda, Distribuição de Energia Elétrica, Previsão de Séries Semporais, Redes Neurais Artificiais, Inteligência Artificial.

Abstract

Demand forecasting studies are of great importance for companies in the electric energy sector, because there is a need to allocate resources in advance, requiring medium- and long-term planning. These resources include the purchase of equipment, acquisition and construction of transmission lines, preventive maintenance and commercialization of energy. Therefore, a computational tool was developed to support specialists in the area of strategic planning in electrical distribution systems, using artificial neural networks to forecasting demand, and including temperature as an external factor. In the proposed methodology, a short-term forecasting system was implemented for the Alto Branco (Centro) substation, using computer artificial intelligence techniques based on artificial neural networks (ANN), using MATLAB© software. For this, were used active power data provided by the power utilities, and the history of local temperature values were obtained from INMET's website, all for the year 2008. The forecast window used was 12 lagged values to obtain the following 4. Furthermore, the accuracy of the networks obtained from training were measured considering MAPE and percentage error.

Keywords: Demand Forecasting, Electric Power Distribution, Time Series Prediction, Artificial Neural Networks, Artificial Intelligence.

Lista de ilustrações

Figura 1 – Sistema Elétrico de Potência, partindo da geração até o consumidor final	18
Figura 2 – Sistema Interligado Nacional para o horizonte de 2017	19
Figura 3 – Representação do sistema nervoso via diagrama de blocos	26
Figura 4 – Modelo não-linear de um neurônio	28
Figura 5 – Rede alimentada adiante com neurônios em camada única	32
Figura 6 – Rede alimentada adiante totalmente conectada com uma camada oculta e uma camada de saída	33
Figura 7 – Rede recorrente sem laços de auto-realimentação e neurônios ocultos .	34
Figura 8 – Rede recorrente com neurônios ocultos	35
Figura 9 – Rede recorrente com neurônios ocultos	37
Figura 10 – Fluxo de sinal um neurônio j	37
Figura 11 – Arquitetura de uma RNA com algoritmo de retropropagação resiliente	39
Figura 12 – Exemplo de previsão de séries temporais	40
Figura 13 – RNA com operadores de atraso	41
Figura 14 – Diagrama unifilar simplificado da subestação de Alto Branco, PB . . .	43
Figura 15 – Potências máximas diárias em 2008	48
Figura 16 – Temperaturas máximas diárias em 2008	48
Figura 17 – Entradas e saídas da RNA e janelamento	49
Figura 18 – Entradas e saídas da RNA e janelamento	50
Figura 19 – Realimentação da previsão no processo de validação e teste	52
Figura 20 – Comportamento do MAPE	55
Figura 21 – Curvas com a saída da rede de menor MAPE e objetivo	56
Figura 22 – Curvas com a saída da rede de menor erro relativo e objetivo	57
Figura 23 – Curvas com a saída da rede de menor erro relativo e objetivo	58
Figura 24 – Curvas com a saída da rede com mínimo erro relativo e objetivo	59
Figura 25 – Diferença entre as curvas lineares obtidas via regressão linear e saídas das redes com MAPE e erro relativo mínimos	60
Figura 26 – Comportamento do MAPE	61
Figura 27 – Saída da RNA com menor MAPE e Objetivo	62
Figura 28 – Saída da RNA com menor erro relativo e Objetivo	62
Figura 29 – Tendências das curvas de saída e objetivo com menor MAPE	63
Figura 30 – Tendências das curvas de saída e objetivo com menor erro relativo . . .	63
Figura 31 – Tendências das curvas de saída e objetivo com menor erro relativo . . .	64
Figura 32 – Comportamento do erro relativo considerando potência e temperatura como entradas	65

Figura 33 – Comportamento do erro relativo considerando apenas entradas em
potência 66

Lista de tabelas

Tabela 1 – Algumas medidas de potência ativa no primeiro dia de 2008	46
Tabela 2 – Alguns valores de potências máximas diárias em 2008	47
Tabela 3 – Especificações técnicas da máquina utilizada	51

Lista de abreviaturas e siglas

SE	Subestação
ET	Estação transformadora
RNA	Rede Neural Artificial
Rprop	Algoritmo <i>Resilient Backpropagation</i>
MCP	Memória de curto prazo
MLP	<i>Multilayer perceptron</i>
LM	Levenberg-Marquardt
MCM	1000 circular mils, que correspondem a $0.5067mm^2$ aproximadamente
SCADA	<i>Supervisory Control and Data Acquisition</i>
Tts	Objetivo para os padrões de teste
Ttr	Objetivo para os padrões de treinamento
MAPE	<i>Mean absolute percentage error</i>
ONS	Operador Nacional do Sistema Elétrico

Lista de símbolos

β	Letra grega Beta
η	Letra grega Eta
μ	Letra grega Mi
Σ	Letra grega maiúscula Sigma
φ	Letra grega minúscula Fi
ρ	Letra grega minúscula Rô

Sumário

1	INTRODUÇÃO	15
1.1	Pertinência e motivação do trabalho	15
1.2	Objetivos	16
1.3	Organização do trabalho	17
2	FUNDAMENTAÇÃO TEÓRICA	18
2.1	O Sistema Elétrico	18
2.2	Séries temporais	21
2.3	Técnica de previsão utilizada neste trabalho	22
2.4	Redes Neurais Artificiais	22
2.4.1	Benefícios das redes neurais	24
2.5	O cérebro humano	26
2.6	Modelos de um neurônio	27
2.6.1	Tipos de função de ativação	29
2.6.2	Modelo estocástico de um neurônio	30
2.7	Arquitetura de redes	31
2.8	Perceptrons de múltiplas camadas	35
2.9	Taxa de aprendizado e <i>momentum</i>	38
2.10	Retropropagação Resiliente (<i>Resilient Propagation</i>)	38
2.11	O Algoritmo de Levenberg-Marquardt	39
2.12	Previsão de séries temporais utilizando RNA	40
3	METODOLOGIA PARA A PREVISÃO DE DEMANDA	43
3.1	Objeto de estudo	43
3.2	Visão geral	44
3.3	Implementação do banco de dados	45
3.4	Treinamento da RNA	48
3.5	Parâmetros de treinamento	50
3.6	Teste e validação da RNA	51
3.7	Correlação da potência com temperatura	52
4	RESULTADOS	54
4.1	Redes considerando temperatura e potência como entradas	54
4.1.1	Cálculo do MAPE	54
4.1.2	Cálculo do erro relativo	55
4.1.3	Teste da RNA	55

4.2	Redes considerando apenas os dados de potência como entradas . .	60
4.2.1	Cálculo do MAPE	60
4.2.2	Cálculo do erro relativo	61
4.2.3	Teste da RNA	61
4.3	Média dos erros relativos em ambas as configurações	64
4.3.1	Redes com entradas em potência e temperatura	64
4.3.2	Redes com entradas apenas em potência	65
4.4	Conclusão	66
5	CONSIDERAÇÕES FINAIS	67
6	REFERÊNCIAS BIBLIOGRÁFICAS	68

1 Introdução

1.1 Pertinência e motivação do trabalho

A predição do futuro sempre foi almejada pelo ser humano. Desde épocas antigas, na tentativa de prever períodos de colheita e chuvas, registra-se a busca pela projeção do futuro para tomar decisões no presente. Uma das formas de fazer isto é por meio da observação, estudo e análise do passado. Estimar comportamentos futuros é bastante útil nas mais diversas áreas do conhecimento, tais como: meteorologia, comércio, economia, entre outros.

As empresas de distribuição de energia elétrica devem elaborar relatórios periódicos de previsões de demanda das cargas localizadas em sua área de concessão, nos horizontes definidos pelo Operador Nacional do Sistema (ONS) e pela Empresa de Pesquisa Energética (EPE) (RIBEIRO, *et al.*, 2006). Além desses estudos, as empresas procuram fazer análises internas, objetivando planejar as decisões de operação, controle e manutenção dos sistemas. Em relação aos recursos que necessitam de antecedência de reserva, destacam-se: construção de novas linhas transmissão, compra e venda de energia, compra de novos equipamentos e manutenções preventivas.

A previsão de demanda pode ser feita para os horizontes de longo, médio, curto e curtíssimo prazo (PAN; LEE, 2012). A possibilidade de diversos horizontes de planejamento, portanto, conduz a prática de previsão de demanda para grande complexidade. A previsão a longo prazo possui como horizonte o período de anos ou décadas, e objetiva o planejamento para incrementar a capacidade das linhas de transmissão ou construção de novas plantas de geração. A previsão de demanda de médio prazo, que ocorre desde semana a meses, permite às concessionárias e empresas de energia elétrica alocar seus recursos como: manutenções nas redes elétricas, a compra de equipamentos, expansão do seu sistema, estratégias no mercado de energia (GHIASSI; ZIMBRA; SAIDANE, 2006) e (PAN; LEE, 2012). A previsão de curto prazo possui algumas horas como horizonte, e pode avaliar a segurança do sistema, analisar confiabilidade, planejamento de manutenções, entre outros. A previsão de curtíssimo prazo prevê minutos à frente, e é bastante importante na regulação entre a demanda e oferta por energia elétrica a fim de evitar flutuações, ajustando a geração de energia às constantes mudanças (CARMONA, *et al.*, 2002).

Em Karayiannis *et al.* (2003), os seguintes aspectos foram destacados a respeito da previsão de demanda:

- Distribuição econômica das unidades geradoras;

- Intercâmbio de energia entre empresas;
- Programação da produção, que pode resultar em economia para os consumidores;
- Distribuição da poluição ambiental;

Para uma visão a longo prazo, o intervalo de tempo deverá variar de cinco a dez anos, se aproximando do limite superior para redes de transmissão de subestações, e do limite inferior para redes de distribuição. A atualização destes planos deve ser anual, de forma a permitir ao regulador e à sociedade acompanhar mudanças de tendências nos investimentos, bem como, comparar o que foi planejado e o que foi efetivamente implementado, considerando, naturalmente, as motivações e barreiras de caráter econômico, financeiro, estrutural, legal, ambiental, etc. (SANTOS; HADDAD; CRUZ, 2008). Os estudos de previsão de demanda têm como objetivo auxiliar no plano anual de expansão.

Na tentativa de sempre buscar melhor exatidão nos resultados de previsão, vários métodos estão sendo desenvolvidos, adaptados e aprimorados ao longo do tempo. Anteriormente ao surgimento da inteligência artificial, apenas os métodos estatísticos e probabilísticos, liderados pelos modelos Box e Jenkins (BOX; JENKINS; REINSEL, 2008) eram aplicados em séries temporais para previsão. Com o desenvolvimento de técnicas computacionais, que levavam vantagem diante da não linearidade dos dados e sem depender de complexos modelos matemáticos, métodos de inteligência artificial passaram a ser utilizados em previsão de demanda.

Apesar dos métodos já mencionados, ao seu modo, trazerem resultados satisfatórios, tais técnicas continuam sendo aperfeiçoadas objetivando melhorar a exatidão e confiabilidade da previsão. Assim, os resultados podem vir a ser utilizados como ferramentas de auxílio no planejamento da alocação dos recursos no setor elétrico.

Além de todos os fatores supracitados, a temperatura pode ser uma variável poderosa no desenvolvimento de estudos, já que regiões com altas temperaturas geralmente fazem uso de sistemas de refrigeração para ambientes, o que implica no aumento do consumo de energia elétrica, com picos de demanda específicos durante o dia. Dessa forma, o estudo da previsão de demanda, ao levar em conta tais particularidades, estabelece um enfoque estratégico acerca da área em estudo, possibilitando a verificação das influências que devem ser ponderadas.

1.2 Objetivos

O objetivo geral deste trabalho consiste desenvolver uma ferramenta computacional para previsão de demanda, destinada a especialistas da área de planejamento estratégico em sistemas de distribuição, com enfoque em redes neurais artificiais. Além disso, haverá

a análise da variável de temperatura e seu impacto na previsão, com uma posterior comparação entre os resultados considerando ou não este aspecto.

1.3 Organização do trabalho

Este trabalho foi estruturado em seis capítulos. No primeiro capítulo, será feita uma introdução, abordando a importância e motivação do tema. Além disso, foram citados os objetivos gerais e específicos.

No segundo capítulo, serão feitas uma fundamentação teórica e considerações a respeito do Sistema Elétrico de Potência, assim como as características dos sistemas de geração, transmissão e distribuição de energia elétrica. Conceitos relacionados à previsão de séries temporais e métodos estatísticos baseados em inteligência artificial também serão apresentados.

O terceiro capítulo abordará a metodologia de previsão utilizada, partindo da descrição do objeto de estudo. Dando continuidade, será exposta a forma de implementação do banco de dados, treinamento da RNA e seus parâmetros, com a fundamentação dos testes e da validação da Rede Neural. Por fim, há um tópico abordando a correlação entre os dados de potência e temperatura.

No quarto capítulo, os resultados serão apresentados. Para facilitar o entendimento, estes serão divididos em etapas, com apresentação de gráficos com as melhores aproximações.

O quinto capítulo constará da conclusão do trabalho, comparando os resultados com a inclusão da temperatura como variável de entrada e levando em conta apenas os valores de potência passados.

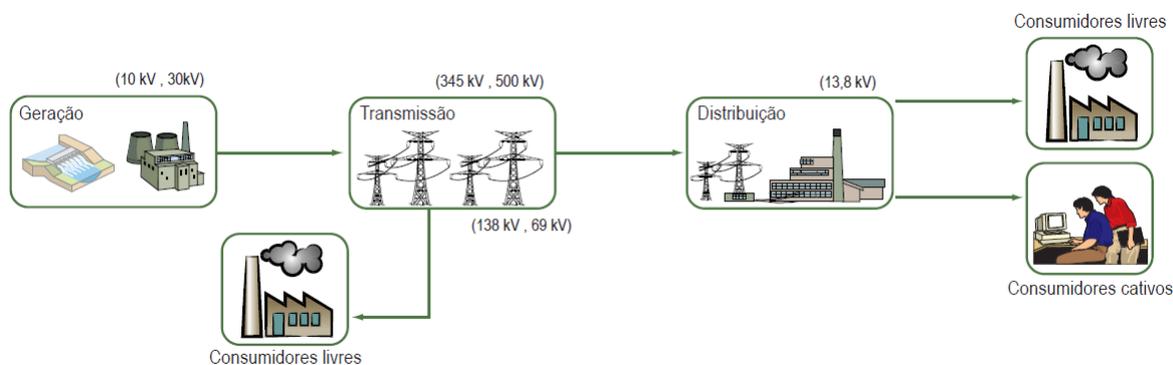
Por fim, o sexto capítulo aponta as referências bibliográficas.

2 Fundamentação teórica

2.1 O Sistema Elétrico

A principal função do Sistema Elétrico de Potência (SEP) é fornecer energia elétrica aos usuários, com qualidade apropriada, na medida em que essa for solicitada, convertendo energia de naturezas diversas (hidráulica, mecânica, térmica, etc.) em energia elétrica e assim, distribuindo aos consumidores (KAGAN; OLIVEIRA; ROBBA, 2005) e (ANDRADE *et al.*, 2010). Na figura 1, é possível visualizar os subsistemas de geração, transmissão e distribuição de energia elétrica, assim como os consumidores.

Figura 1 – Sistema Elétrico de Potência, partindo da geração até o consumidor final

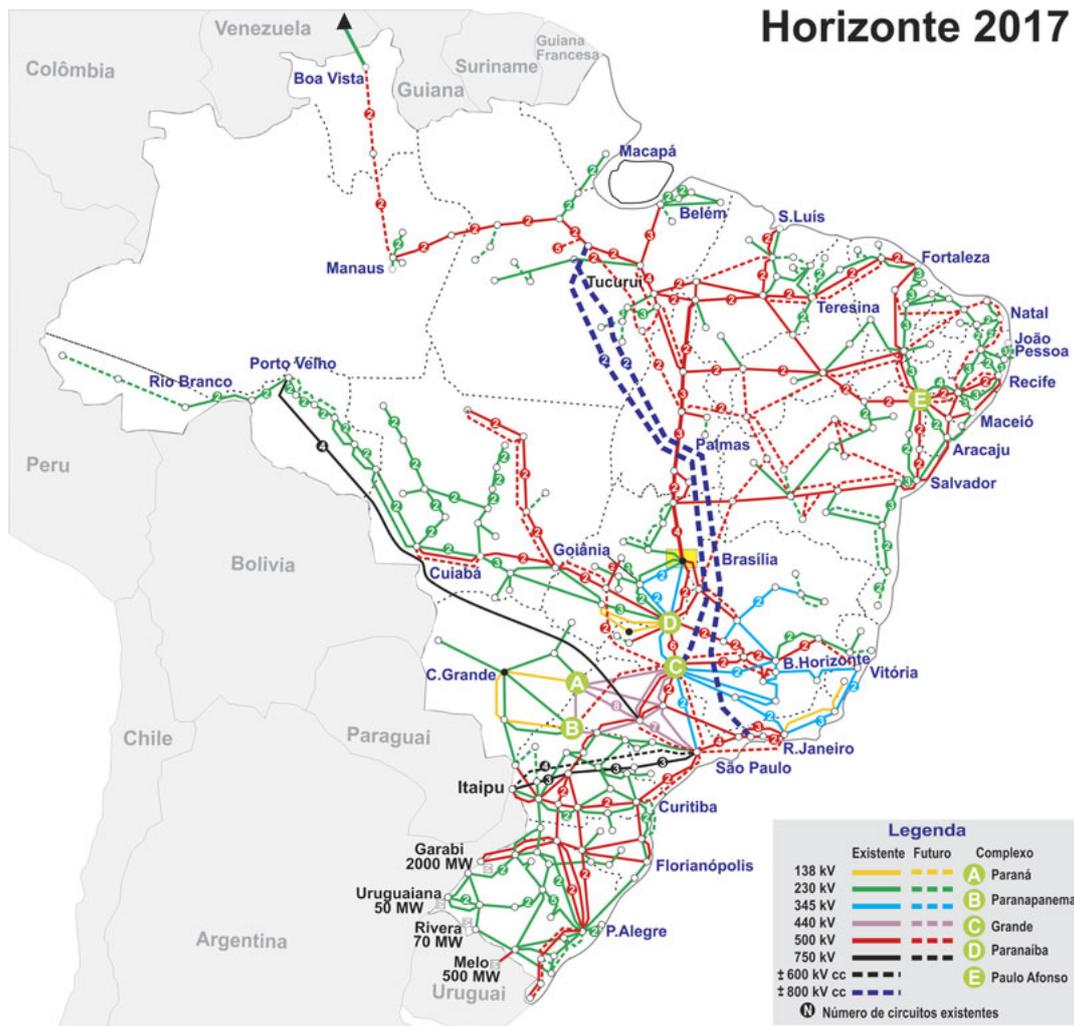


Fonte: adaptado de (ANEEL, 2008)

A geração de energia elétrica se faz através de variadas tecnologias, onde as principais consistem em máquinas rotativas, geradores síncronos ou alternadores, utilizando turbinas hidráulicas, a vapor ou eólicas. A energia elétrica obtida via usinas hidrelétricas encontra-se no topo da matriz energética brasileira, devido aos grandes recursos hídricos distribuídos ao longo de boa parte do território. As demais fontes que compõem tal matriz, são: energia solar, eólica, entre outras.

A energia gerada pelo sistema de geração necessita ser distribuída em todo o país e, para isso, existe o Sistema Interligado Nacional (SIN), que inclui a maior parte do território nacional, e é formado por conexões entre as cinco regiões do Brasil. Na figura 2, ilustra-se-se o SIN para o horizonte de 2017.

Figura 2 – Sistema Interligado Nacional para o horizonte de 2017



Fonte: ONS, 2017

As grandes dimensões da rede de transmissão no Brasil são justificadas pela configuração do sistema de geração, formado, em sua maior parte, por usinas hidrelétricas instaladas em locais distantes das centrais consumidoras. A característica principal de tal segmento é a divisão em dois blocos: o Sistema Interligado Nacional (SIN), que corta praticamente todo o território brasileiro, e os Sistemas Isolados, instalados principalmente na região norte do país.

Os sistemas de transmissão e distribuição são conectados através de pontos de fronteira, locais onde existem as subestações que abaixam a tensão para os níveis de subtransmissão. O sistema de distribuição é de suma importância, pois além de ser responsável pela entrega de energia ao usuário final, demanda elevada quantidade de investimentos, assim como qualidade e garantia de serviço destinado aos consumidores. Dessa forma, o planejamento estratégico torna-se indispensável, buscando se adequar ao crescimento de carga e um melhor aproveitamento dos recursos financeiros. Além disso, os

sistemas de Geração e Transmissão possuem excelentes sistemas para aquisição de dados, assim como previsão de carga.

Conforme Kagan *et al.*, (2005) e Andrade *et al.* (2010), o sistema de distribuição pode ser dividido nos seguintes blocos:

- Sistema de subtransmissão: este elo possui função de captar a energia em grosso das subestações de subtransmissão e transferi-la às SEs de distribuição e aos consumidores, em tensão de subtransmissão, através de linhas trifásicas operando em tensões, usualmente, de 138 kV ou 69 kV ou, mais raramente, em 34,5 kV, com capacidade de transporte de algumas dezenas de MW por circuito, usualmente de 20 a 150 MW. Os consumidores em tensão de subtransmissão são representados, usualmente, por grandes instalações industriais, estações de tratamento e bombeamento de água.
- Sistema de distribuição primária: As redes de distribuição primária, ou de média tensão, emergem das SEs de distribuição e operam, no caso da rede aérea, radialmente, com possibilidade de transferência de blocos de carga entre circuitos para o atendimento da operação em condições de contingência, devido à manutenção corretiva ou preventiva. Os troncos dos alimentadores empregam, usualmente, condutores de seção 336,4 MCM ($0.5067mm^2$) permitindo, na tensão de 13,8 kV, o transporte de potência máxima de cerca de 12 MVA, que, face à necessidade de transferência de blocos de carga entre alimentadores, fica limitada a cerca de 8 MVA. Estas redes atendem aos consumidores primários e aos transformadores de distribuição, *estações transformadoras*, ETs, que suprem a rede secundária, ou de baixa tensão. Dentre os consumidores primários destacam-se indústrias de porte médio, conjuntos comerciais ("*shopping centers*"), instalações de iluminação pública, etc. Podem ser aéreas ou subterrâneas, as primeiras de uso mais difundido, pelo seu menor custo, e as segundas, encontrando grande aplicação em áreas de maior densidade de carga, por exemplo zona central de uma metrópole, ou onde há restrições paisagísticas.
- Redes de distribuição secundária: Da ET, deriva-se a rede de baixa tensão, 200/127 V ou 380/220 V, que pode operar em malha ou radial e que supre os consumidores de baixa tensão, consumidores residenciais, pequenos comércios e indústrias. Alcança, por circuito, comprimentos da ordem de centenas de metros. Destaca-se o predomínio, nesta rede, de consumidores residenciais.

Dessa forma, a natureza de cada segmento do sistema irá definir o grau de confiabilidade por ele exigido, dependendo da potência transportada. Evidentemente, nesta hierarquia de confiabilidade, o elemento do topo e a SE de subtransmissão, encarregada da transferência de potência na ordem de centenas de MVA, e o último desta escala é formado pela rede de baixa tensão, onde a potência é na ordem de dezenas de kVA.

2.2 Séries temporais

De forma generalizada, é possível definir uma série temporal como qualquer conjunto de observações feitas no tempo (ABELÉM, 1994), (MAKRIDAKIS *et al.*, 1998), (FAVA, 2000a). Uma vasta quantidade de fenômenos de natureza física, biológica, econômica, entre outras, estão inclusos nesta categoria e possui suas características estudadas através da análise de séries temporais (FAVA, 2000a).

Para ser classificada como série temporal, esta deve ter um requisito básico: os dados deverão possuir uma dependência serial entre si. Para citar como exemplo: se os dados de uma variável aleatória X (consumo energético) num determinado instante t , para t variando de 1 a N , possa, de certa forma, conter informações suficientes para determinar o valor dessa variável no instante $t+1$. Vale salientar que N indica a quantidade de observações da série temporal correspondente. As séries temporais podem ser classificadas como estocásticas, contínuas, determinísticas, discretas, multidimensionais e multivariadas. Segundo (Mendenhall, 1993), conforme abordagem de componentes não observáveis, as séries temporais podem ser vistas como a combinação de quatro fatores:

- Sazonalidade
- Erro
- Ciclo
- Tendência

A sazonalidade está relacionada à repetição de padrões dentro de um período. Tais padrões correspondem a um movimento oscilatório em um curto intervalo de tempo, que irá traduzir a influência de fatores com atuação periódica.

O erro é um movimento instável que indica a influência de fatores casuais.

Ciclo se trata de um movimento oscilatório de longa duração, que irá determinar a influência de aspectos aleatórios.

A tendência exprime o comportamento dos dados em função do tempo, ou seja, se a sequência dos dados é crescente, decrescente ou continua estável, além da velocidade de tais variações.

Para previsão de carga, como consta em (GUIRELLI, 2006), desde a década de 80 que vários métodos têm sido aplicados. Estes podem ser divididos em estatísticos e baseados em inteligência artificial. Entre os métodos clássicos, tem-se:

- Regressão Linear Múltipla;

- ARIMA;
- Alisamento exponencial;
- Análise espectral;

Dos métodos baseados em inteligência artificial, destacam-se:

- Sistemas especialistas;
- Redes Neurais Artificiais;
- Lógica Fuzzy;
- Algoritmos genéticos;

Além disso, existem vários métodos sendo desenvolvidos denominados híbridos, que combinam dois ou mais modelos de previsão de carga.

2.3 Técnica de previsão utilizada neste trabalho

Diante de vários métodos disponíveis para a previsão de séries temporais, este trabalho concentrou-se na utilização das Redes Neurais Artificiais (RNA), devido a vários aspectos, como:

- Muitos anos de estudos publicados na área.
- Capacidade de lidar com modelos complexos e não lineares.
- Por ser uma técnica renomada e, portanto, mais facilmente aceita pelo setor elétrico.
- Implementação relativamente simples.

2.4 Redes Neurais Artificiais

O trabalho em redes neurais artificiais, usualmente denominadas "redes neurais", tem sido motivado desde o começo pelo reconhecimento de que o cérebro humano processa informações de uma forma inteiramente diferente do computador digital convencional (HAYKIN, 2008). O cérebro é um *computador* (sistema de processamento de informação) altamente *complexo, não-linear* e *paralelo* (HAYKIN, 2008). Ele tem a capacidade de organizar seus constituintes estruturais, conhecidos por *neurônios*, de forma a realizar certos processamentos (p.ex., reconhecimento de padrões, percepção e controle motor) muito mais rapidamente que o mais rápido computador digital hoje existente. Considere,

por exemplo, a visão humana, que é uma tarefa de processamento de informação (MARR, 1982; LEVINE, 1985; CHURCHLAND e SEJNOWSKI, 1992). A função do sistema visual é fornecer uma *representação* do ambiente à nossa volta e, mais importante que isso, fornecer a informação de que necessitamos para interagir com o ambiente. Para ser mais específico, o cérebro realiza de forma rotineira tarefas de reconhecimento perceptivo.

Um neurônio em "progressão" corresponde a um cérebro plástico: a *plasticidade* possibilita o sistema nervoso em desenvolvimento se adaptar ao seu meio ambiente. Da mesma forma que a *plasticidade* aparenta ser essencial para o funcionamento dos neurônios como unidades de processamento de informação do cérebro humano, também ela o é com relação as redes neurais constituídas de neurônios artificiais (HAYKIN, 2008). De forma mais geral, uma *rede neural* é uma máquina projetada com o objetivo de *modelar* a forma como o cérebro realiza uma tarefa em particular; a rede geralmente é executada por meio de componentes eletrônicos ou simulada via programação em um computador digital.

Para que as redes neurais tenham um bom desempenho, estas realizam uma interligação maciça de células computacionais denominadas "neurônios" ou "unidades de processamento".

Então pode-se definir uma rede neural do seguinte modo, sendo vista como uma máquina adaptativa (HAYKIN, 2008):

Uma rede neural é um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos:

- *O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.*
- *Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.*

O procedimento realizado para o processo de *aprendizagem* é denominado *algoritmo de aprendizagem*, que tem a função de alterar os pesos sinápticos da rede de uma forma ordenada para alcançar um determinado objetivo.

A modificação dos pesos sinápticos é o método tradicional para o projeto de redes neurais. Esta abordagem é bastante próxima da teoria dos filtros adaptativos lineares, que já está bem estabelecida e foi aplicada com sucesso em diversas áreas (Widrow e Stearns, 1985; HAYKIN, 1996). Porém, para uma rede neural também é possível modificar sua própria topologia, o que é motivado pelo fato de os neurônios no cérebro humano poderem morrer e que novas conexões sinápticas possam crescer.

2.4.1 Benefícios das redes neurais

Uma rede neural extrai seu poder computacional, primeiramente, da sua estrutura maciça e paralelamente distribuída, e de sua habilidade de aprender. A rede neural produz saídas adequadas para entradas que não estavam presentes durante o treinamento. Tais capacidades de processamento de informação possibilitam as redes neurais resolverem problemas extremamente complexos que são intratáveis atualmente. Porém, em termos práticos, as redes neurais não podem fornecer uma solução trabalhando individualmente. Em vez disso, estas devem ser complementadas com uma abordagem consistente no campo de engenharia de sistemas. Mais especificamente, um problema complexo é decomposto em tarefas mais simples e às redes neurais são atribuídos subconjuntos de tarefas que coincidem com suas capacidades próprias. Apesar disso, tem-se um longo caminho a ser percorrido antes de ser construída (se porventura seja possível) uma arquitetura computacional que mimetize um cérebro humano.

A utilização de redes neurais leva em consideração as seguintes propriedades e capacidades:

- *Não-linearidade.* Um neurônio artificial pode ser linear ou não. Uma rede neural formada por conexões de neurônios não lineares é dita não-linear. A não-linearidade é uma propriedade muito importante, principalmente se o mecanismo físico responsável pela geração do sinal de entrada for naturalmente não-linear.
- *Mapeamento de Entrada-Saída.* Uma forma popular de aprendizagem denominada *aprendizagem supervisionada* inclui a alteração dos pesos sinápticos de uma rede neural através da aplicação de um conjunto de *amostras de treinamento*. Cada amostra é formada de um sinal de entrada único e de uma resposta desejada correspondente. É apresentado para a rede um exemplo escolhido ao acaso do conjunto, e os pesos sinápticos da rede são modificados para minimizar a diferença entre a resposta procurada e a real. O treinamento da rede é repetido para muitas amostras até que a rede alcance um estado estável, onde os pesos sinápticos não irão sofrer mais alterações significativas.
- *Adaptabilidade.* As redes neurais possuem uma capacidade natural de *adaptar* seus pesos sinápticos a modificações do meio ambiente. Em específico, uma rede neural treinada para atuar em um certo ambiente pode ser *retreinada* para lidar com as novas condições operativas. Além disso, ao operar em um ambiente não-estacionário (ou seja, onde as estatísticas mudam com o tempo), uma rede neural pode ser projetada para modificar seus próprios pesos em tempo real.
- *Resposta a evidências.* No escopo de classificação de padrões, uma rede neural pode ser projetada para fornecer informações tanto para o padrão a ser selecionado,

como pela confiança e *crença* na decisão tomada. Esta última informação pode ser utilizada para rejeitar padrões que sejam ambíguos, se estiverem presentes, e com isso melhorar o desempenho de classificação da rede.

- *Informação Contextual.* O conhecimento é representado pela própria estrutura e estado de ativação de uma rede neural. Cada neurônio da rede é bastante afetado pela atividade dos demais. Dessa forma, a informação contextual é tratada naturalmente pela rede neural.
- *Tolerância a falhas.* Uma rede neural, implementada na forma física, tem naturalmente a capacidade de ser tolerante a falhas, ou de realizar computação robusta, de maneira a diminuir suavemente seu desempenho em condições adversas de operação. Se, por exemplo, um neurônio ou suas conexões forem danificados, a recuperação de um padrão terá prejuízo em qualidade. Entretanto, devido à natureza distribuída da informação armazenada na rede, o dano deve ser extenso para que a resposta global seja afetada seriamente. Assim, a princípio, uma rede neural exhibe uma degradação suave no desempenho em vez de apresentar uma falha catastrófica. Para garantir que uma rede neural seja verdadeiramente tolerante a falhas, pode ser necessário adotar-se medidas corretivas no projeto do algoritmo utilizado para treinar a rede (Kerlirzin e Vallet, 1993).
- *Implementação em VLSI.* A natureza maciçamente paralela de uma rede neural implica na rapidez potencial para computação de certas tarefas. Tal característica torna uma rede neural apropriada para implementação por meio da tecnologia de integração em escala muito ampla. Uma virtude benéfica particular da tecnologia VLSI (*very-large-scale-integration*) é que ela fornece uma forma de capturar comportamentos realmente complexos de uma forma altamente hierárquica (Mead, 1989).
- *Uniformidade de Análise e Projeto.* As redes neurais usufruem de universalidade como processadores de informação. Isso ocorre no sentido de que a mesma notação é utilizada em todos os domínios que envolvem aplicação desta técnica de inteligência artificial. Esta característica se manifesta de diferentes modos:
 - Os neurônios, de uma forma ou de outra, representam um aspecto comum a todas as redes neurais;
 - Tal uniformidade possibilita o compartilhamento de teorias e algoritmos de aprendizagem para diferentes aplicações de redes neurais;
- *Analogia Neurobiológica.* O projeto de uma rede neural é motivado pela analogia com o cérebro, que é uma prova de que o processamento paralelo e tolerante a falhas

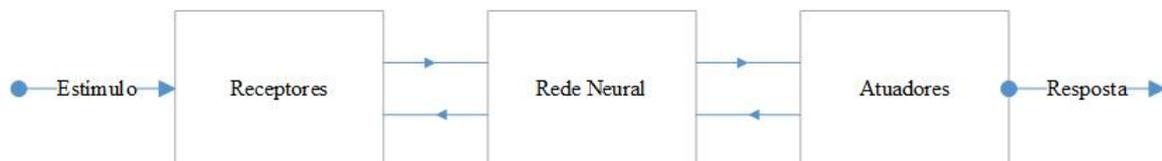
não apenas é possível fisicamente, mas também rápido e poderoso. Os neurobiólogos tratam as redes neurais artificiais como uma ferramenta para a interpretação de fenômenos neurobiológicos. Já os engenheiros procuram na neurobiologia novas ideias para sanar problemas mais complexos em relação àqueles que são baseados em técnicas convencionais de projeto por conexões fixas.

Com toda esta inspiração na neurobiologia, torna-se prudente examinar resumidamente o cérebro humano e seus níveis de organização.

2.5 O cérebro humano

O sistema nervoso humano pode ser visto como um sistema de três estágios, conforme figura 3 (Arbib, 1987). A parte central do sistema é o cérebro, representado pela *rede neural*, que recebe constantemente informação, percebe-a e toma decisões adequadas. Na figura, há dois pares de setas. As que apontam da esquerda para a direita implicam transmissão para frente do sinal portador de informação, por meio do sistema. Os *receptores* irão converter estímulos do corpo humano ou do ambiente externo em impulsos elétricos que transmitem informação para a rede neural (cérebro). Os *atuadores* transformam os impulsos elétricos originados pela rede neural em respostas distinguíveis como saída do sistema.

Figura 3 – Representação do sistema nervoso via diagrama de blocos



Fonte: elaborado pelo autor, 2019

A busca pelo entendimento do cérebro tornou-se mais fácil por meio do trabalho pioneiro de Ramon y Cajál (1911), onde foi introduzida a ideia dos *neurônios* como componentes estruturais do cérebro. Particularmente, os neurônios são de cinco a seis ordens de grandeza mais lentos do que as portas lógicas em silício. Porém, o cérebro compensa a taxa de operação relativamente lenta de um neurônio pelo número enorme de conexões consistentes entre as células nervosas.

As *sinapses* constituem unidades estruturais e funcionais que intermedeiam as interações entre os neurônios. O tipo mais comum de sinapse é dito *sinapse química*, que procede da seguinte forma: um processo pré-sináptico libera uma substância *transmissora* que se difunde através de uma junção sináptica entre neurônios e então age sobre um processo pós-sináptico. Dessa forma, uma sinapse converte um sinal elétrico pré-sináptico

em um sinal químico e então de volta em um sinal pós-sináptico (Shepherd e Koch, 1990). Na terminologia elétrica, um elemento assim é denominado *dispositivo de dois terminais não-recíproco*. Em descrições clássicas de organização neural, assume-se que sinapse é uma conexão simples que poderá determinar *excitação* ou *inibição*, porém não os dois ao mesmo tempo.

Anteriormente, foi mencionado que a plasticidade permite o sistema nervoso em desenvolvimento se adaptar ao seu ambiente próprio (Eggermont, 1990; Churchland e Sejnowski, 1992). Em um cérebro adulto, a plasticidade pode ser associada a dois aspectos: formação de novas conexões entre os neurônios, assim como a modificação das já existentes.

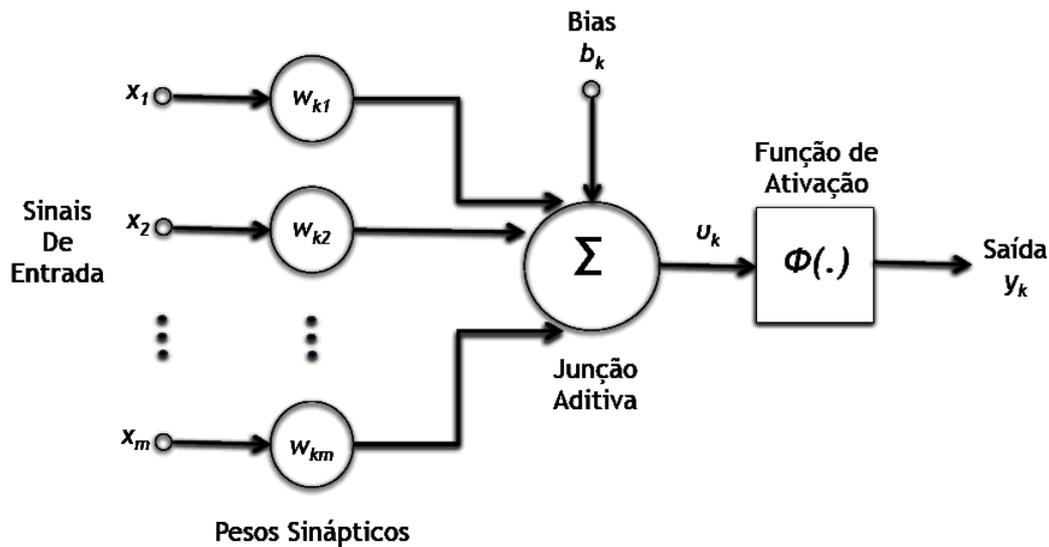
Grande parte dos neurônios criptografam suas saídas como um conjunto de pulsos rápidos de tensão. Tais pulsos, habitualmente conhecidos como *impulsos*, são originados do corpo celular dos neurônios individuais a velocidade e amplitude constantes.

É importante admitir que os níveis estruturais de organização descritos anteriormente são aspectos exclusivos do cérebro. Estes não são de forma alguma encontrados em um computador digital. Os neurônios artificiais que são utilizados para construir as redes neurais são de fato primitivos em comparação aos do cérebro. O que é verdadeiramente gratificante é o progresso alcançado nas últimas duas décadas. Tendo a análise neurobiológica como fonte de inspiração, juntamente com a diversidade de ferramentas teóricas e tecnológicas acumuladas, é certo que a compreensão sobre as redes neurais irá avançar de forma ainda mais substancial nas décadas que estão por vir.

2.6 Modelos de um neurônio

Um neurônio constitui uma unidade de processamento fundamental para a operação de uma rede neural (HAYKIN, 2008). O diagrama de blocos conforme figura 4 ilustra o modelo de um neurônio, que é o cerne do projeto de redes neurais artificiais. Do modelo neuronal, destacam-se três elementos básicos:

Figura 4 – Modelo não-linear de um neurônio



Fonte: adaptado de HAYKIN, 2008

- Um conjunto de *sinapses*, onde cada uma é especificada por um peso ou força própria. Particularmente, um sinal x_j na entrada da sinapse j conectada ao neurônio k é multiplicado pelo peso sináptico w_{kj} . Vale a pena citar a forma como são escritos os índices do peso sináptico. O primeiro índice se refere ao neurônio analisado, e o segundo está atrelado ao terminal de entrada da sinapse do peso em questão. Diferentemente de uma sinapse cerebral, o peso sináptico poderá estar contido em um intervalo onde existem valores negativos e positivos.
- Um somador para somar os sinais de entrada, ponderados pelas devidas sinapses do neurônio; as operações aqui descritas formam uma *combinação linear*.
- Uma *função de ativação* para limitar a amplitude de saída de um neurônio. A função de ativação também é denominada *função restritiva*, já que restringe o intervalo permissível de amplitude do sinal de saída para um valor finito. Particularmente, o intervalo normalizado de amplitude de saída de um neurônio é expresso como um intervalo unitário fechado $[0,1]$ ou, de forma alternativa, $[-1,1]$.

O modelo neuronal mostrado na figura 18 também inclui uma aplicação externa *bias*, denotada por b_k . O *bias* (polarização) tem o efeito de aumentar ou diminuir a entrada função de ativação, dependendo se o valor é positivo ou negativo, respectivamente.

Em termos matemáticos, é possível descrever um neurônio k por meio de um par

de equações:

$$u_k = \sum_{j=1}^m w_{kj}x_j \quad (2.1)$$

e

$$y_k = \varphi(u_k + b_k) \quad (2.2)$$

onde, x_1, x_2, \dots, x_m são sinais de entrada; $w_{k1}, w_{k2}, \dots, w_{km}$ são, respectivamente, os pesos sinápticos do neurônio k ; u_k representa a saída por combinação linear dos sinais de entrada; b_k é o *bias*; $\varphi(\cdot)$ é a função de ativação; e y_k é o sinal de saída do neurônio.

2.6.1 Tipos de função de ativação

A função de ativação, indicada por $\varphi(v)$, define a saída do neurônio em termos do campo induzido local v . Em (HAYKIN, 2008), identificam-se dois tipos básicos de funções de ativação:

- *Função de limite.* Para este tipo de função de ativação, tem-se o seguinte:

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq 0 \\ 0, & \text{se } v < 0 \end{cases} \quad (2.3)$$

Na literatura de engenharia, esta função limite é geralmente citada como *função de Heaviside*. Por consequência, a saída do neurônio k que emprega tal função é definida como:

$$y_k = \begin{cases} 1, & \text{se } v_k \geq 0 \\ 0, & \text{se } v_k < 0 \end{cases} \quad (2.4)$$

onde v_k é o vetor de campo local induzido do neurônio; ou seja,

$$v_k = \sum_{j=1}^m w_{kj}x_j + b_k \quad (2.5)$$

Na computação neural, este neurônio é citado como *modelo de McCulloch-Pitts* na literatura, em reconhecimento ao trabalho pioneiro de McCulloch e Pitts (1943). Neste modelo, a saída do neurônio assume o valor 1, desde que o campo local induzido seja positivo e, caso contrário, valor 0.

- *Função Sigmóide.* A função sigmóide, cujo gráfico possui forma de s, é definitivamente a forma mais comum de função de ativação aplicada na construção de redes neurais artificiais. Esta é definida como uma função estritamente crescente, que exibe um comportamento que se alterna entre linear e não-linear. Um exemplo de função sigmoide é a função logística, expressa por:

$$\varphi(v) = \frac{1}{1 + e^{-av}} \quad (2.6)$$

em que a é o parâmetro de inclinação da função. Assim, alterando-se o parâmetro a , podem ser obtidas funções sigmóides de inclinações diferentes. Quando a tende ao infinito, a função sigmóide se torna uma função de limite. Enquanto a função limite assume apenas os valores 0 ou 1, uma função sigmóide assume valores contínuos no intervalo de 0 a 1. Vale a pena ressaltar que a função sigmóide é diferenciável, ao contrário da função limite.

As funções de ativação definidas nas equações anteriores se estendem em um intervalo de 0 a +1. Em alguns casos, é desejável que a função de ativação se estenda de -1 a +1. Assim, a função limite definida pela equação 2.3 toma a seguinte forma:

$$\varphi(v) = \begin{cases} 1, & \text{se } v > 0 \\ 0, & \text{se } v = 0 \\ -1, & \text{se } v < 0 \end{cases} \quad (2.7)$$

Agora, a função fica denominada *função sinal*. Para a forma correspondente de uma função sigmoide, pode-se utilizar a *função tangente hiperbólica*, definida por

$$\varphi(v) = \tanh(v) \quad (2.8)$$

2.6.2 Modelo estocástico de um neurônio

O modelo neuronal descrito na figura 4 é determinístico, já que a característica entrada-saída é definida precisamente para todas as entradas. Para algumas aplicações em redes neurais, é desejável recorrer ao modelo neuronal estocástico. Em um tratamento analítico, o modelo da função de ativação por McCulloch-Pitts pode receber uma interpretação probabilística. Particularmente, é permitido o neurônio residir em apenas um estado, diante de duas possibilidades: +1 ou -1, por exemplo. A decisão para disparar um neurônio é probabilística. Atribui-se x como o estado do neurônio e $P(v)$ a probabilidade

de disparo, onde v é o vetor de campo induzido local do neurônio. Dessa forma, é possível escrever as seguintes sentenças:

$$x = \begin{cases} +1, & \text{com probabilidade } P(v) \\ -1, & \text{com probabilidade } 1-P(v) \end{cases} \quad (2.9)$$

Para $P(v)$ há uma escolha padrão, e se trata de uma função sigmóide (Little, 1994):

$$P(v) = \frac{1}{1 + e^{-\frac{v}{T}}} \quad (2.10)$$

onde T representa uma *pseudotemperatura* utilizada para o controle do nível de ruído e, conseqüentemente, a incerteza do disparo. Vale salientar que T não constitui uma temperatura física, independentemente se a rede seja biológica ou artificial. Conforme supracitado, deve-se considerar T como apenas um parâmetro que controla as flutuações térmicas que representam os efeitos do ruído sináptico.

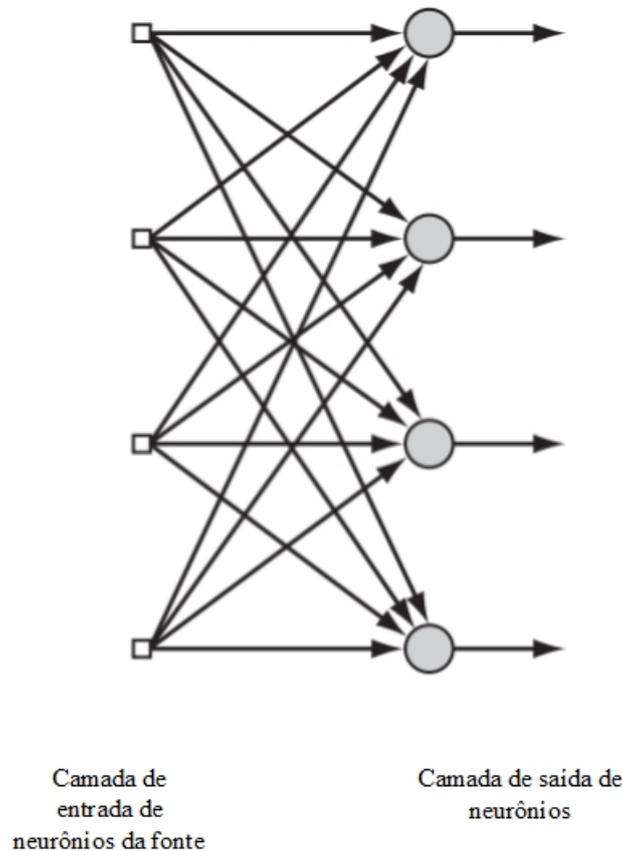
2.7 Arquitetura de redes

A maneira como os neurônios de uma rede neural são estruturados está intimamente ligada ao algoritmo de aprendizagem utilizado para treinar a rede. Portanto, pode-se falar em algoritmos usados no projeto de redes neurais como sendo estruturados.

Geralmente, é possível identificar três classes diferentes das arquiteturas de rede:

- Redes alimentadas adiante com camada única: numa rede neural *em camadas*, os neurônios estão estruturados na forma de camadas. Numa rede em camadas, na forma mais simples, tem-se uma camada de entrada de nós de fonte que se projeta sobre uma camada de saída de neurônios, porém não vice-versa. Este tipo de rede encontra-se ilustrado na figura 5, para o caso com quatro nós nas camadas de entrada e saída. Esta rede é denominada *rede de camada única*, onde tal designação se refere à camada de saída dos neurônios.

Figura 5 – Rede alimentada adiante com neurônios em camada única



Fonte: adaptado de HAYKIN, 2008

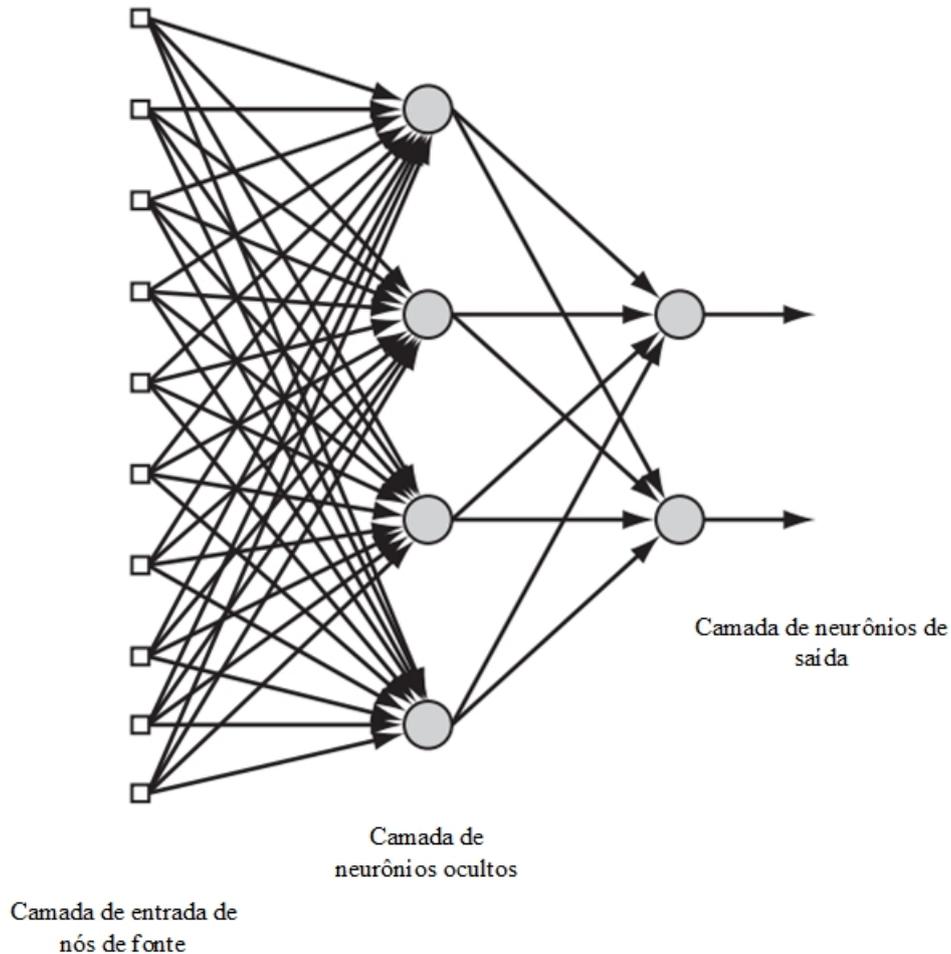
- Redes alimentadas diretamente com múltiplas camadas: a segunda classe de uma rede neural alimentada adiante tem o diferencial da presença de uma ou mais *camadas ocultas*, onde os nós computacionais são respectivamente denominados *neurônios ocultos*. Estes têm a função de intervir entre a entrada externa e a saída da rede. Incluindo duas ou mais camadas ocultas, torna-se possível que a rede obtenha estatísticas de ordem elevada. Em um sentido livre, a rede adquire um panorama *global* apesar da conectividade local, devido ao conjunto extra de conexões extras e da dimensão extra de interações neurais (Churchland e Sejnowski, 1992).

Os nós de fonte da camada de entrada da rede fornecem os devidos elementos do padrão de ativação (vetor de entrada), que representam os sinais de entrada aplicados aos neurônios na segunda camada. Os sinais de saída desta camada serão utilizados como entrada para a terceira camada, e assim por diante. Especificamente, os neurônios em cada camada possuem os das camadas precedentes como entrada. O conjunto dos sinais de saída dos neurônios da camada de saída (final) forma a resposta global do sistema para o padrão de ativação determinados pelos nós de fonte da camada de entrada. A figura 6 mostra a planta de uma rede neural com

múltiplas camadas alimentada adiante para o caso de apenas uma camada oculta.

A rede neural da figura 6 é denominada *totalmente conectada*, no sentido de que cada um dos nós de uma camada encontra-se conectado ao da camada adjacente. Caso algumas conexões sinápticas estejam em falta, diz-se que a rede é *parcialmente conectada*.

Figura 6 – Rede alimentada adiante totalmente conectada com uma camada oculta e uma camada de saída

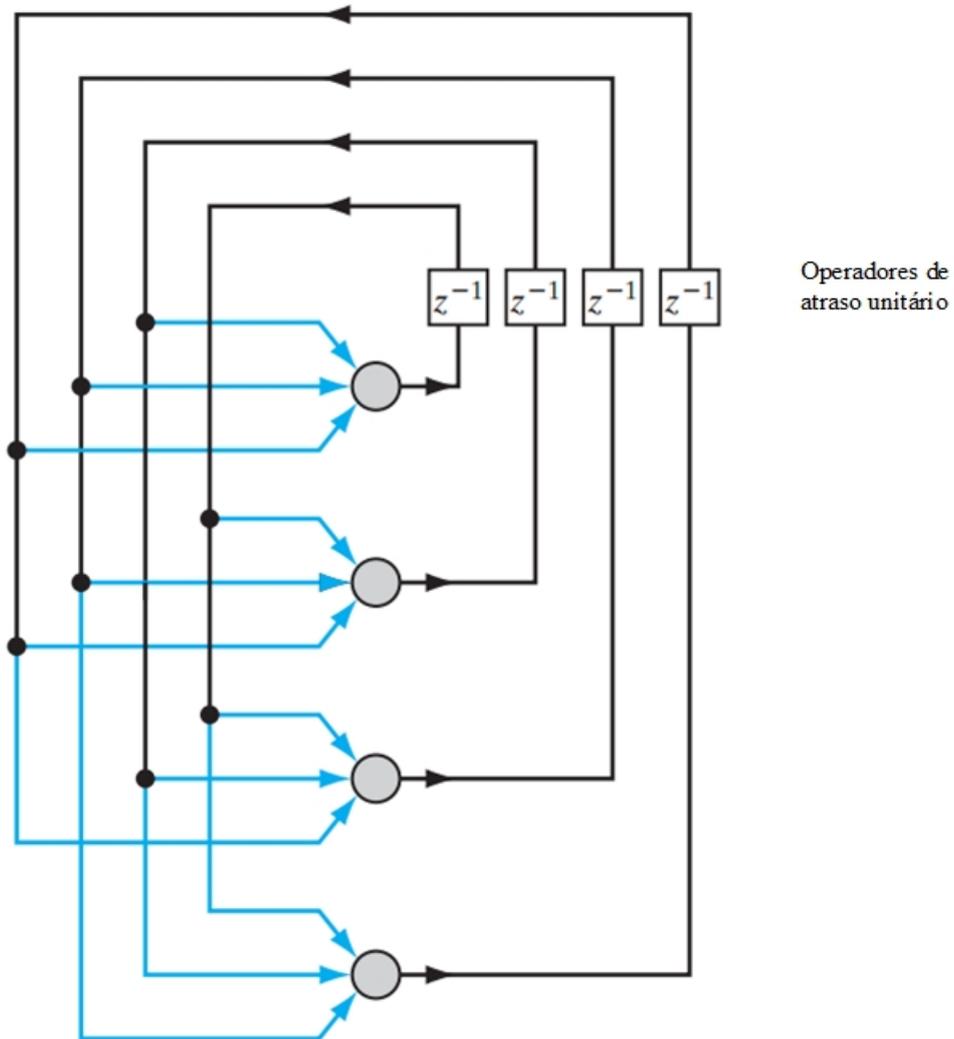


Fonte: adaptado de HAYKIN, 2008

- Redes recorrentes

Uma *rede neural recorrente* é distinguida de uma rede neural alimentada adiante por possuir ao menos um laço de *realimentação*. Uma rede recorrente pode ser constituída, por exemplo, de apenas uma camada de neurônios, onde cada neurônio alimenta seu sinal de saída de volta para as entradas de todos os demais neurônios, conforme figura 7. Nesta figura, a representação não inclui laços de auto-realimentação na rede. A rede recorrente da figura 7 também não possui neurônios ocultos. Na figura 8, é mostrada outra classe de redes recorrentes com neurônios ocultos.

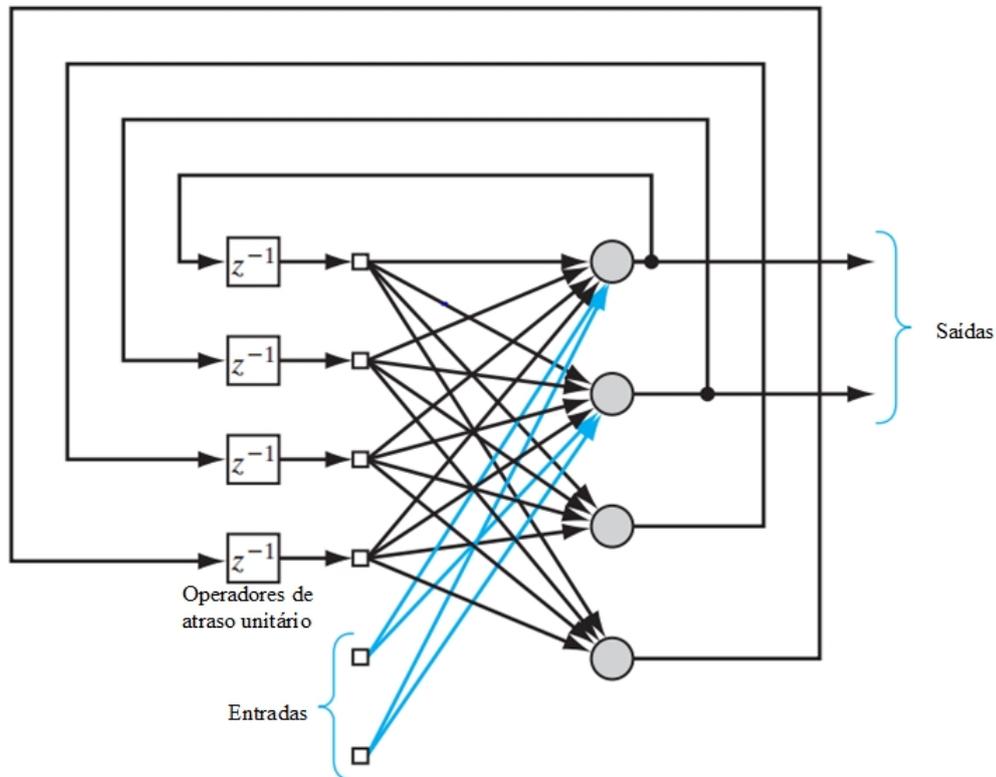
Figura 7 – Rede recorrente sem laços de auto-realimentação e neurônios ocultos



Fonte: adaptado de HAYKIN, 2008

A presença de laços de realimentação, seja na estrutura ilustrada na figura 7 ou naquela da figura 8, impacta significativamente na capacidade de aprendizagem da rede e no seu desempenho.

Figura 8 – Rede recorrente com neurônios ocultos



Fonte: adaptado de HAYKIN, 2008

2.8 Perceptrons de múltiplas camadas

Redes Perceptrons de múltiplas camadas (MLP) constituem uma importante classe de redes neurais artificiais, e possuem diversas aplicações (PAN; LEE, 2012). As redes MLP vêm sendo aplicadas na resolução de diversos problemas difíceis, por meio de um algoritmo conhecido como *algoritmo de retropropagação (back-propagation)*. Os pesos sinápticos são ajustados para que a resposta real da rede se mova para mais próximo da resposta almejada, numa lógica estatística. O processo de *aprendizagem* realizado com o algoritmo é denominado *aprendizagem por retropropagação*.

Segundo (HAYKIN, 2008), um perceptron de múltiplas camadas tem três características distintas:

- O modelo de cada neurônio da rede engloba uma *função de ativação não-linear*. É importante enfatizar o fato de que a linearidade aqui é suave (ou seja, diferenciável em qualquer ponto). Uma forma geralmente utilizada de não-linearidade que cumpre

essa exigência é uma *não-linearidade sigmóide*, expressa pela seguinte função:

$$y_f = \frac{1}{1 + e^{-v_f}} \quad (2.11)$$

onde v_f representa o campo local induzido do neurônio j , e y_f sua respectiva saída. A presença de não-linearidades é importante já que, do contrário, a relação entrada-saída da rede poderia ser reduzida à de um perceptron de camada única.

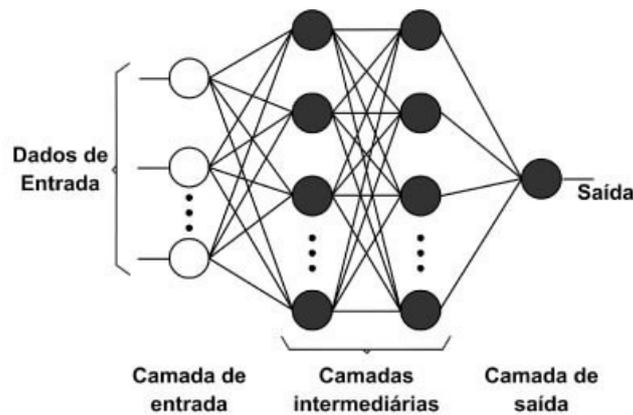
- A rede possui duas ou mais camadas de *neurônios ocultos*, que não fazem parte da entrada ou saída da rede. Tais neurônios ocultos possibilitam a rede aprender tarefas complexas, adquirindo de forma progressiva as características mais importantes dos padrões de entrada.
- A rede exprime um alto grau de *conectividade*, estabelecido pelas sinapses da rede. Uma alteração na conectividade da rede implica necessidade de mudança da população das conexões sinápticas ou dos pesos correspondentes.

Por meio da união de tais características, juntamente com a habilidade de aprender via treinamento, que o perceptron de múltiplas camadas deriva seu grande poder computacional (HAYKIN, 2008). Porém, essas mesmas características são também responsáveis pelas atuais deficiências no atual estado de conhecimento acerca do comportamento da rede. Primeiro, a presença de não-linearidade e alta conectividade de forma distribuída tornam complicada a análise teórica de um perceptron de múltiplas camadas. Segundo, a presença de neurônios ocultos torna o processo de aprendizagem mais difícil de ser visualizado.

O desenvolvimento do algoritmo de retropropagação expressa um marco na teoria de redes neurais, já que fornece um modelo computacional eficiente para treinar perceptrons de múltiplas camadas (HAYKIN, 2008). Apesar de não se poder afirmar que o algoritmo de retropropagação ofereça uma solução ótima para todos os problemas de possível resolução, este acabou com o pessimismo sobre a aprendizagem em máquinas de múltiplas camadas que havia sido causado pelo livro de Minsky e Papert (1969) (HAYKIN, 2008).

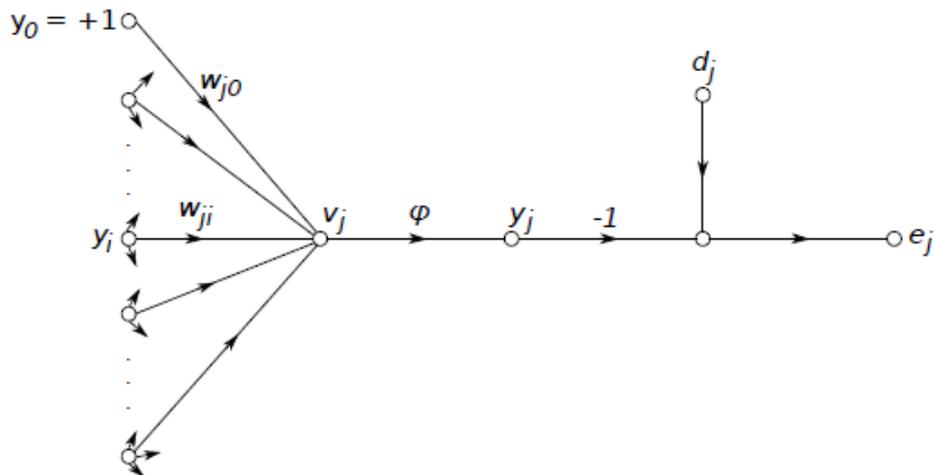
Na figura 9 tem-se a representação da arquitetura de uma rede MLP com duas camadas ocultas ou intermediárias.

Figura 9 – Rede recorrente com neurônios ocultos



Fonte: adaptado de HAYKIN, 2008

Na figura 10, é possível observar o fluxo do sinal em um neurônio j , em que v_j representa a saída do neurônio, e y_j a saída após aplicação da função de ativação φ :

Figura 10 – Fluxo de sinal um neurônio j 

Fonte: adaptado de HAYKIN, 1994

O processo de *aprendizagem* ocorre com a repetição da regra da cadeia do Cálculo, objetivando o cálculo de uma função erro ϵ de todos os parâmetros livres da rede (pesos sinápticos e *bias*). Os pesos são modelados de acordo com a derivada parcial da função erro:

$$\frac{\partial \epsilon}{\partial w_{ij}} = \frac{\partial \epsilon}{\partial e_j} \frac{\partial e_j}{\partial y_j} \frac{\partial y_j}{\partial v_j} \frac{\partial v_j}{\partial w_{ij}} \quad (2.12)$$

Com as derivadas parciais de cada peso, a função do aprendizado é minimizar a função erro via equação 2.13, em que η indica a taxa de aprendizado.

$$w_{ji}(t+1) = w_{ji}(t) - \eta \frac{\partial \epsilon(t)}{\partial w_{ji}(t)} \quad (2.13)$$

A aprendizagem por retropropagação pode ser sintetizada em duas etapas. No decorrer do passo de propagação (para frente) os pesos sinápticos são invariáveis e, durante o passo de retropropagação (para trás), os pesos serão ajustados conforma uma regra de correção de erro. Resumindo, a resposta real da rede é subtraída da resposta desejada para produzir um sinal de erro, que será retropropagado por meio da rede, no sentido contrário das conexões sinápticas.

2.9 Taxa de aprendizado e *momentum*

A taxa de aprendizado (expressa por η) influencia na trajetória percorrida pelo gradiente decrescente. Quanto menor for essa taxa, menores serão as atualizações dos pesos entre iterações e, portanto, a trajetória percorrida será mais suave. Porém, uma maior quantidade de iterações do algoritmo para chegar a uma solução aceitável será necessária. O inverso deste processo poderá deixar a rede instável e, para corrigir isso, é preciso adicionar uma *taxa de momentum*, que tem objetivo de estabilizar o sinal em regiões de instabilidade, acelerando também a convergência (Cerri, 2014).

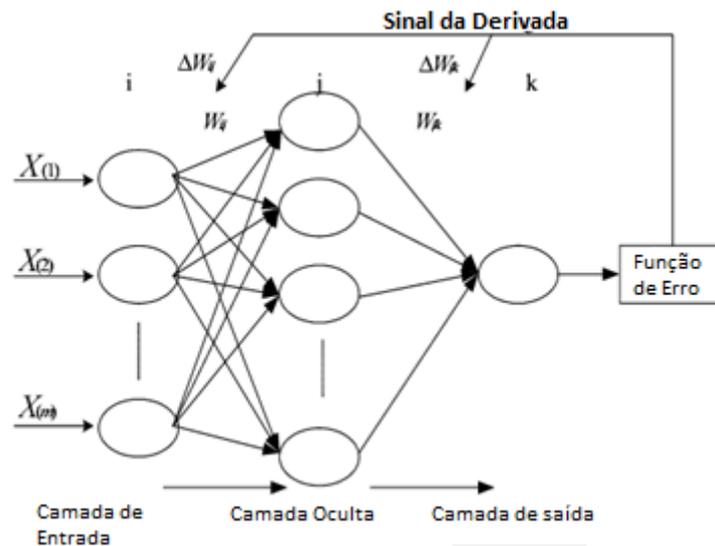
2.10 Retropropagação Resiliente (*Resilient Propagation*)

O algoritmo de treinamento padrão *backpropagation* foi, inquestionavelmente, o mais influente avanço no campo das redes neurais durante a década de 80 (Widrow; Lehr, 1990). A atualização dos pesos sinápticos não dependem unicamente da seleção das taxas de aprendizado e *momentum*, mas também do cálculo da derivada parcial $\frac{\partial \epsilon}{\partial w_{ij}}$. Assim, mesmo que as taxas sejam bem escolhidas, o resultado da derivada parcial pode influenciar na solução.

Objetivando tratar esse problema, Riedmiller e Braun (1993) apresentaram o método de aprendizado intitulado *resilient backpropagation* (Rprop), que possui uma estrutura semelhante ao *backpropagation*, sendo assim considerado como uma otimização deste. Porém, o Rprop pode conduzir uma adaptação local da atualização dos pesos conforme o comportamento da função erro, já que não considera o efeito negativo do valor da derivada parcial para o cálculo de atualização dos pesos, mas apenas o sinal da que indica a direção de atualização dos mesmos (Jin; Feng; Jilai, 2006). Tal mudança implicou em um processo de adaptação bastante eficiente em comparação a outras técnicas, sendo

considerado como das formas de atualização de pesos mais rápidas existente. A arquitetura de uma rede neural artificial com algoritmo Rprop é mostrada na figura 11.

Figura 11 – Arquitetura de uma RNA com algoritmo de retropropagação resiliente



Fonte: adaptado de (Jin; Feng; Jilai, 2006)

Apesar de remover boa parte das limitações do algoritmo *backpropagation*, a utilização do Rprop poderá gerar um novo problema: o sobre-ajuste, ou *overfitting*. Isto ocorre quando o algoritmo se ajusta em excesso aos dados, incorporando desvios provenientes de erros ou fatores aleatórios de amostra, perdendo sua habilidade de generalização (Andrade, 2011). Variações das taxas de aprendizado e *momentum* podem contribuir para que as redes neurais fiquem menos propensas ao *overfitting*.

2.11 O Algoritmo de Levenberg-Marquardt

Conforme (M. T. Hagan; M. B. Menhaj, 1994), enquanto o *back-propagation* padrão faz uso da descida de gradiente como método de aproximação do mínimo da função erro, o algoritmo de Levenberg-Marquardt (LM) utiliza uma aproximação pelo método de Newton. Tal aproximação é obtida por meio da modificação do método de Gauss-Newton introduzindo-se o parâmetro μ , conforme equação 2.14.

$$\Delta x = [J^T(x)J(x) + \mu I]^{-1} J^T(x)e(x) \quad (2.14)$$

onde I representa uma matriz identidade, $e(x)$ o erro e J a matriz Jacobiana. O parâmetro μ é multiplicado por um fator (β) toda vez que um passo resultar num aumento da função erro, que se deseja minimizar. Quando um passo resultar na diminuição da função genébrica $V(x)$, μ é dividido pelo fator β . Isto implica que, caso haja uma convergência para o

mínimo da função, μ é pequeno e o algoritmo se aproxima do método de Newton (passo $\frac{1}{\mu}$); no caso de não haver convergência, o método se aproximará da descida de gradiente. O parâmetro μ funciona como um fator de estabilização de treinamento, ajustando a aproximação de forma a utilizar a rápida convergência do método de Newton e evitando passos muito grandes que possam levar a um erro de convergência.

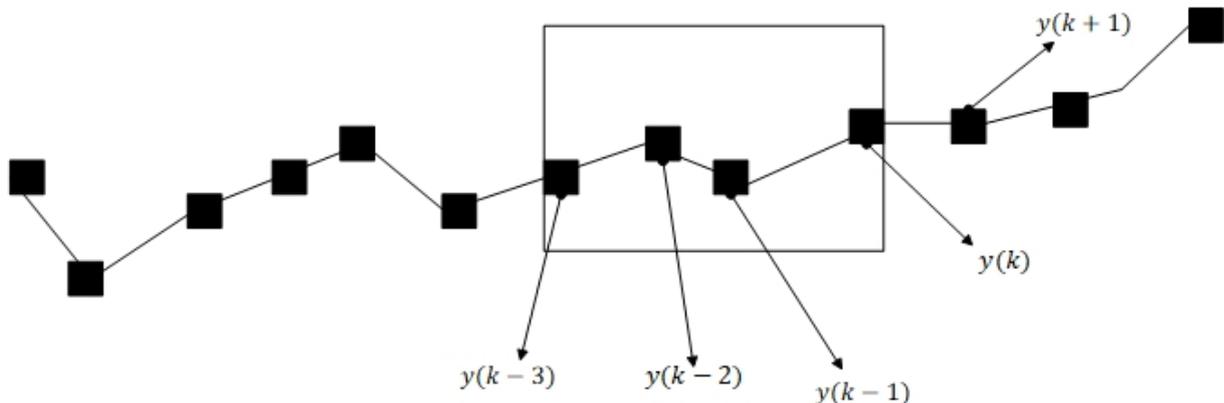
2.12 Previsão de séries temporais utilizando RNA

Seja uma sequência de observações $y(k)$, com $k= 1, 2, 3, \dots$, definindo uma série temporal. O intuito de previsão pode ser sintetizado da seguinte forma: para valores previamente conhecidos $y(k - n + 1), y(k - n + 2), \dots, y(k)$, deseja-se estimar o valor da variável l períodos à frente da origem k , ou seja, $y(k + l)$, onde n e l são, respectivamente, a janela de previsão (passado) e horizonte de previsão (passo à frente). Assim, pretende-se obter o seguinte mapeamento:

$$f : [y(k - n + 1), \dots, y(k - 1), y(k)] \rightarrow y(k + 1) \quad (2.15)$$

Na figura 12 é possível visualizar um exemplo de previsão com uma janela composta de quatro passados valores da variável. Por meio de $y(k - 3), y(k - 2), y(k - 1)$ e $y(k)$, pode-se determinar a medida para um horizonte $y(k + 1)$.

Figura 12 – Exemplo de previsão de séries temporais



Fonte: elaborado pelo autor, 2019

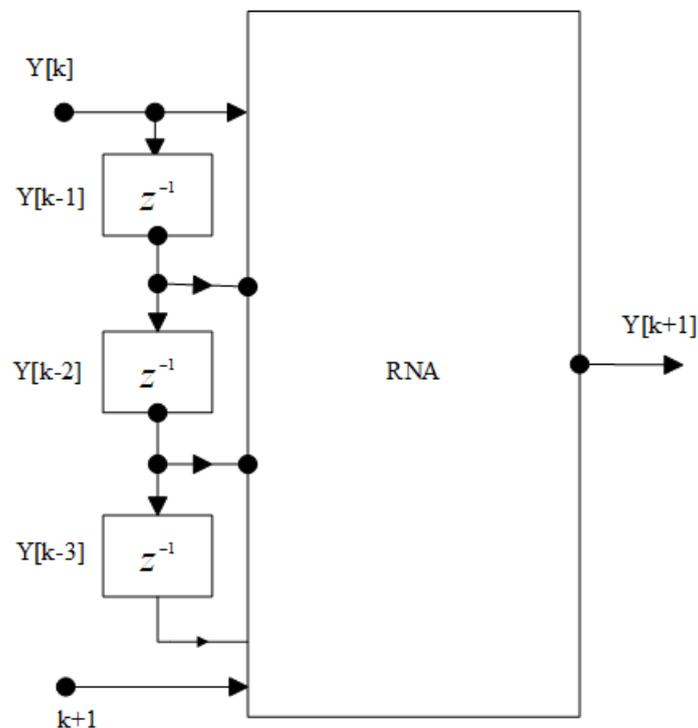
Algumas informações advindas do ambiente externo possuem natureza dinâmica e sequencial, de forma que relações temporais entre padrões consecutivos devem ser

consideradas. O reconhecimento destes padrões é indispensável para a previsão de séries temporais.

Para que uma RNA seja utilizada como ferramenta de previsão de séries temporais, é preciso levar o tempo em consideração, de tal forma que seja possível a modelagem das variações estatísticas de uma série temporal de dados. Conforme (HAYKIN, 1994), este problema pode ser solucionado através da inclusão de um mecanismo denominado *memória de curto prazo* (MCP). Os componentes da série temporal são organizados de maneira que o processo de aprendizagem aconteça em duas vias: tanto nos dados, como na ordem em que ocorreram. A memória tem um objetivo principal de transformar uma rede estática em dinâmica. Assim, RNA's com características unicamente estáticas se tornam dinâmicas. Há, portanto uma divisão de tarefas: a rede estática é responsável pela não-linearidade e a memória, pelo tempo. A forma de MCP mais trivial e utilizada é chamada *memória de linha de atraso*. A rede MLP, com uma memória de linha de atraso derivada, aplicada à entrada, é a rede mais simples e uma das mais aplicadas na previsão de séries temporais.

A figura 13 mostra uma estrutura com rede MLP e previsão com uma janela de tempo. Nesta figura, os blocos formam um operador de atraso (z^{-1}). Pode-se observar que a entrada $k+1$ indica o horizonte de previsão.

Figura 13 – RNA com operadores de atraso



Fonte: elaborado pelo autor, 2019

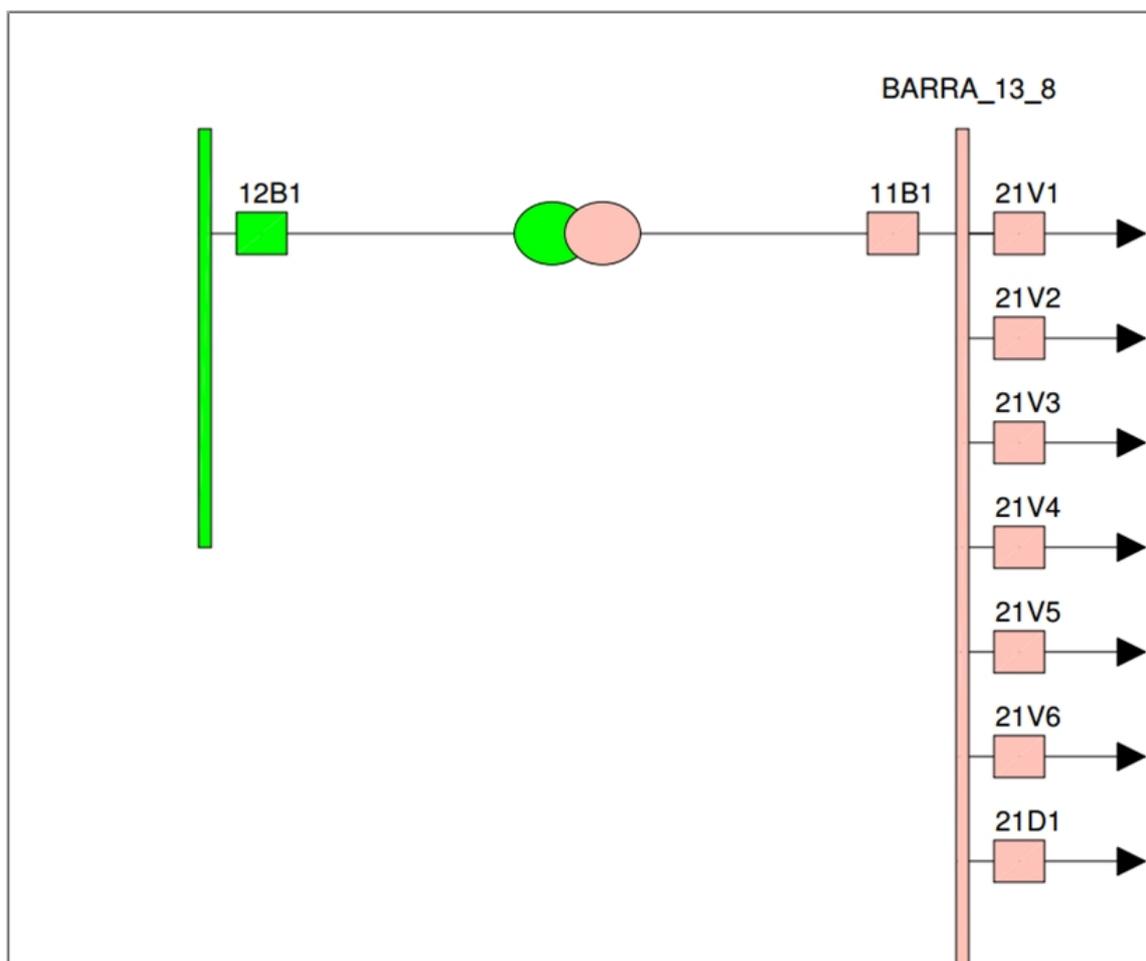
Vale ressaltar que quanto maior for o horizonte de previsão, deverão existir entradas passadas com um maior número de atrasos, de forma a possibilitar a relação entre as entradas e saídas.

3 Metodologia para a previsão de demanda

3.1 Objeto de estudo

Neste trabalho, o objeto de estudo foi a subestação ABR – Alto Branco (CENTRO), localizada em Campina Grande-PB. Seu diagrama unifilar simplificado encontra-se na figura 14.

Figura 14 – Diagrama unifilar simplificado da subestação de Alto Branco, PB



Fonte: Projeto P&D Energisa, 2016

A subestação é do tipo abaixadora (69-13,8 kV) e possui os seguintes pontos de medição:

- Entrada: BARRA13_8 (Barra de 13,8 kV).
- Entrada: 12B1 (Barra de 69 kV).

- Entrada: 11B1 – Complemento da barra 13_8.
- Saída: 21V1.
- Saída: 21V12.
- Saída: 21V3.
- Saída: 21V4.
- Saída: 21V5.
- Saída: 21V6.
- Saída: 21D1.

21D1 identifica um disjuntor de transferência, diferindo das demais saídas, que correspondem aos alimentadores. Este dispositivo não foi considerado neste estudo, e pode ter ocasionado discrepâncias nas medições.

Todos os dados de potência aqui utilizados foram extraídos do alimentador **21V1**, ilustrado no diagrama unifilar da figura 14.

Além dos dados de potência da subestação supracitada, a análise dos dados de temperatura da cidade de Campina Grande-PB é também objetivo deste estudo.

3.2 Visão geral

Para construção do modelo de previsão de demanda, foram utilizados os softwares Microsoft® Excel e MATLAB®, além do histórico de dados fornecidos pela concessionária de energia.

O processo de previsão de demanda ocorre, basicamente, em três etapas: treinamento, validação e teste. A etapa de treinamento consiste em apresentar os dados à rede para que ocorra o aprendizado. Na validação, são realizados testes ao fim de cada iteração de treino. O teste, ou previsão, fornece o resultado desejado pelo usuário.

Como entradas das redes neurais, foi considerada uma janela de valores de demanda passados, assim como dados correspondentes de temperatura. Estudos anteriores indicam maior eficiência no resultado das previsões quando outras variáveis altamente correlacionadas com a demanda são considerados. Dessa forma, este trabalho teve a intenção de incluir a variável de temperatura como entrada, buscando um melhor padrão de previsão.

Para efeito de comparação, será feita a análise incluindo ou não a temperatura, a fim de verificar se esta variável influi positiva ou negativamente nos resultados esperados das redes treinadas.

3.3 Implementação do banco de dados

Os dados de potência ativa foram cedidos pela concessionária de energia. Quanto à temperatura, para todo o intervalo de tempo em que foi feita a análise de potência ativa, foram acrescentados os devidos valores diários de temperatura correspondentes. Os dados de temperatura foram adquiridos via site do INMET (Instituto Nacional de Meteorologia), para a cidade de Campina Grande-PB.

Os dados de natureza elétrica (potência ativa, corrente, tensão etc.) foram obtidos através de um sistema de aquisição de dados (SCADA), que é responsável pelo recebimento nos equipamentos/barramentos da subestação e envio para um banco de dados, ficando acessível para a concessionária.

Uma análise prévia deste banco de dados detectou a presença de inconsistências, tais como: picos, espaços em branco, valores nulos, entre outros. Esses tipos de medições são denominadas *outliers* na literatura formal, e podem ser ocasionadas por erros de leitura, falhas no *SCADA* (*Supervisory Control and Data Acquisition*) e até não se tratarem de erros.

Porém, independentemente da natureza, um *outlier* em uma série temporal deverá ser corrigido para que não haja comprometimento no modelo de previsão, já que a confiabilidade dos dados são indispensáveis para o processo (GUO *et al.*, 2012);(Taylor,2008).

Este trabalho não é direcionado para a correção e identificação de *outliers*, porém deixa claro a necessidade do tratamento prévio dos dados. Dessa forma, assumiu-se a premissa básica de as séries temporais passarem pelo processo de correção.

A tabela 1 possui alguns dados das séries temporais, e descreve a forma como foram organizados, com medições de quinze em quinze minutos. Além da potência ativa, foram fornecidas informações a respeito do dia, mês, ano, horas e minutos.

Tabela 1 – Algumas medidas de potência ativa no primeiro dia de 2008

Dia	Mês	Ano	Hora	Minuto	Potência (MW)
1	1	2008	0	0	1,456
1	1	2008	0	15	1,456
1	1	2008	0	30	1,349
1	1	2008	0	45	1,349
1	1	2008	1	0	1,309
1	1	2008	1	15	1,309
1	1	2008	1	30	1,214
1	1	2008	1	45	1,214
1	1	2008	2	0	1,196
1	1	2008	2	15	1,196
1	1	2008	2	30	1,186
1	1	2008	2	45	1,186
1	1	2008	3	0	1,174
1	1	2008	3	15	1,174
1	1	2008	3	30	1,164
1	1	2008	3	45	1,164
1	1	2008	4	0	1,173
1	1	2008	4	15	1,173
1	1	2008	4	30	1,205
1	1	2008	4	45	1,205
1	1	2008	5	0	1,199
1	1	2008	5	15	1,091
1	1	2008	5	30	1,027
1	1	2008	5	45	1,027
1	1	2008	6	0	1,006
1	1	2008	6	15	1,006
1	1	2008	6	30	1,097
1	1	2008	6	45	1,097
1	1	2008	7	0	1,191
1	1	2008	7	15	1,191

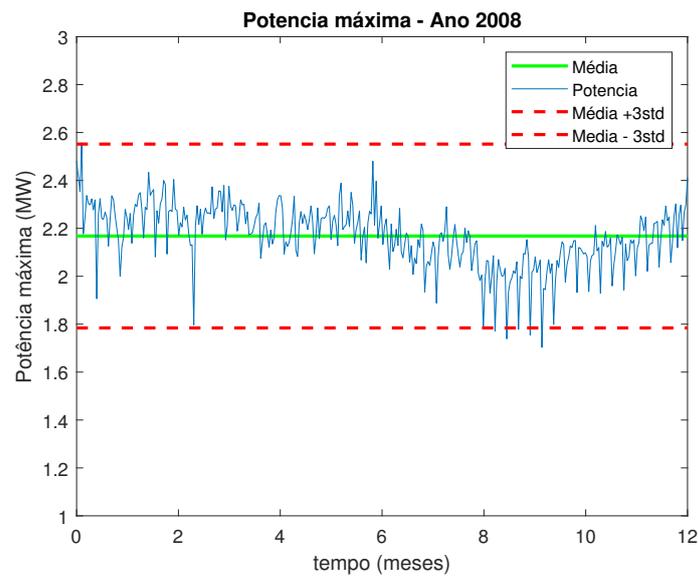
Partindo dos valores de potência obtidos em intervalos de quinze minutos, elaborou-se um algoritmo no MATLAB® para extrair a potência máxima diária. Além disso, também foram encontrados os valores máximos de temperatura diários. Na tabela 2, além dessas informações, os dias da semana são representados da seguinte forma: o número um corresponde ao domingo (primeiro dia da semana), assim como o sábado é identificado pelo número sete (último dia da semana).

Tabela 2 – Alguns valores de potências máximas diárias em 2008

Dia da semana	Potência máxima diária (MW)	Temperatura máxima diária (C°)
3	2,480999947	31
4	2,417999983	31,8
5	2,355000019	31,8
6	2,556999922	31,3
7	2,177000046	31,1
1	2,243999958	31,7
2	2,336999893	31,8
3	2,303999901	32,1
4	2,298000097	32,1
5	2,322999954	31,5
6	2,27699995	30,3
7	2,319000006	31,4
1	1,906294164	30,2
2	2,256999969	27,4
3	2,323999882	29,3
4	2,240999937	28,2
5	2,237999916	26,5
6	2,267999887	29,4
7	2,244999886	30
1	2,125999928	31,5
2	2,236999989	31,2
3	2,335999966	31,5
4	2,319999933	29,6
5	2,253999949	30,4
6	2,200000048	31,7
7	2,147000074	31

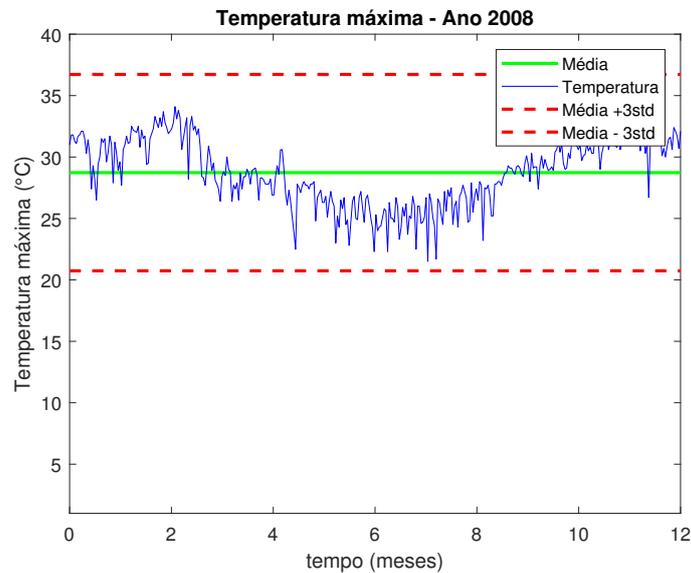
Ainda, neste tratamento inicial, foram gerados os gráficos referentes às potências e temperaturas máximas diárias ao longo do ano de 2008. Nas figuras 15 a 16, além da representação dos comportamentos dessas variáveis, há também a média correspondente a cada gráfico, assim como a delimitação do triplo do desvio padrão, a fim de detectar medidas anômalas.

Figura 15 – Potências máximas diárias em 2008



Fonte: elaborado pelo autor, 2019

Figura 16 – Temperaturas máximas diárias em 2008



Fonte: elaborado pelo autor, 2019

3.4 Treinamento da RNA

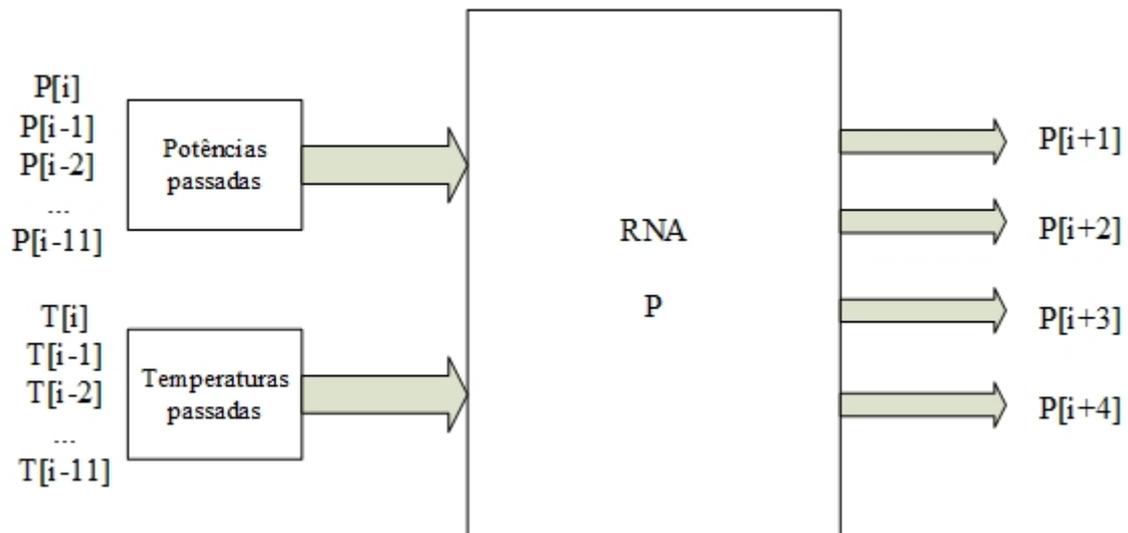
Para o treinamento da rede neural artificial, foi proposto um horizonte de previsão fixo, para potência e temperatura, de quatro dias à frente, considerando-se como entradas doze amostras passadas de ambas as variáveis (janela de previsão), ambos escolhidos

arbitrariamente. Logo, este trabalho se enquadra na classificação de previsão a curto prazo.

Como já foi citado nos objetivos deste estudo de caso, serão feitas duas considerações: a previsão incluindo as variáveis de potência e temperatura como entradas, e outra considerando apenas as amostras de potência na entrada da rede. Além disso, na janela de saída só estarão presentes valores de potência previstos.

Na figura 17, é apresentado um fluxograma sintetizando o modo de como será feita a previsão incluindo amostras de temperatura e potência nas entradas da rede.

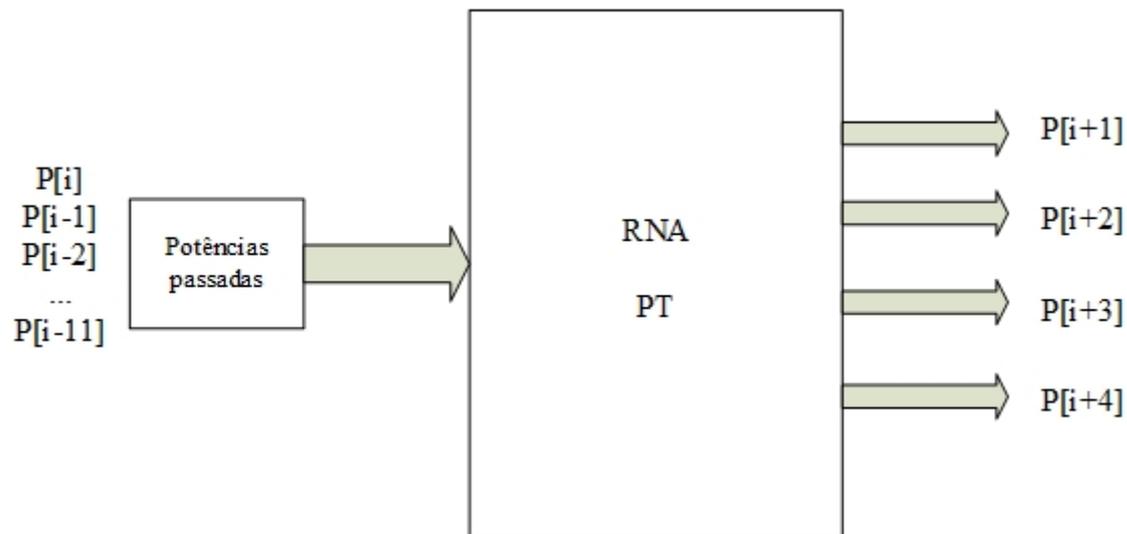
Figura 17 – Entradas e saídas da RNA e janelamento



Fonte: elaborado pelo autor, 2019

Já na figura 18, o fluxograma representa o modelo de previsão sem a inclusão dos dados de temperatura como entradas.

Figura 18 – Entradas e saídas da RNA e janelamento



Fonte: elaborado pelo autor, 2019

Em ambas as figuras, é possível observar as doze amostras passadas que definem a janela de previsão, com o objetivo de prever quatro valores de potência adiante (horizonte de previsão). Estes últimos irão definir a janela de saída da rede.

3.5 Parâmetros de treinamento

O ambiente computacional para realização de todas as simulações foi o Matlab[®], e os parâmetros foram definidos da seguinte forma:

- Número de camadas: 2.
- Número de neurônios: para o treinamento da rede, foram variadas e combinadas as quantidades de neurônios de 1 a 40 para cada camada, afim de encontrar a melhor rede neste intervalo.
- Algoritmo de aprendizado: Algoritmo de Levenberg-Marquardt (LM). No desenvolvimento da RNA, utilizou-se a *toolbox* ou biblioteca NEURAL NETWORK TOOLBOX do MATLAB[®](2018). O algoritmo utilizado no estudo *Levenberg Marquardt* é definido neste *software* como *trainlm*, como aperfeiçoamento do tradicional algoritmo *Backpropagation*. O algoritmo LM faz uso do erro quadrático médio para corrigir os pesos da rede quando sua saída diferir da desejada (Meirelles, 2005).

Para treinamento, processamento dos dados e análise, foi utilizado um computador cujas características estão presentes na tabela 3.

Tabela 3 – Especificações técnicas da máquina utilizada

Fabricante	Dell
Modelo	Inspiron 15 7569
Processador	Intel® Core™ i5-6200U CPU @2.30 GHz
Memória RAM	8 GB

3.6 Teste e validação da RNA

Foram elaborados algoritmos para que, ao final do treinamento de todas as redes, fossem obtidas as melhores RNAs no quesito de menor erro relativo e MAPE durante a fase de testes.

O MAPE (*Mean Absolute Percentage Error*) corresponde à média do erro relativo, e é uma técnica bastante utilizada na avaliação de acurácia em métodos de previsão estatística. Matematicamente, o *MAPE* é definido conforme equação 20:

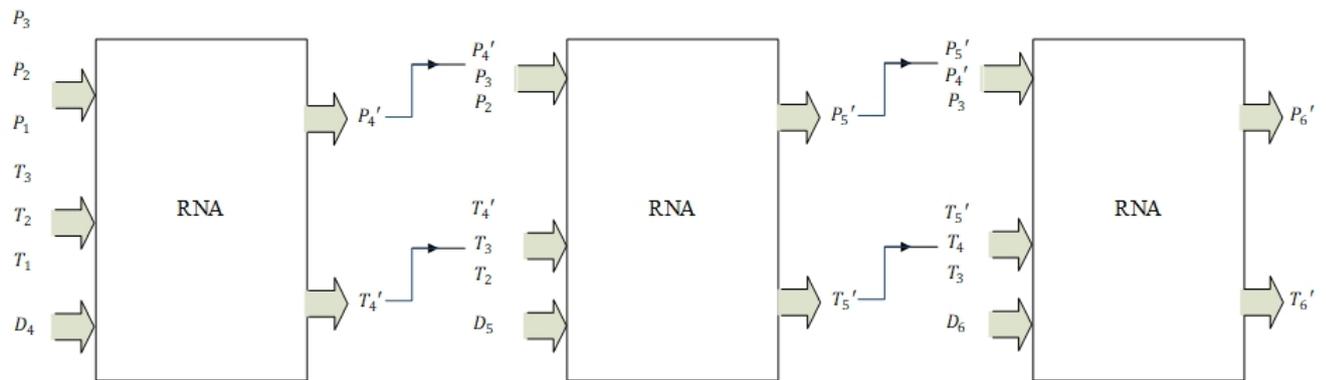
$$MAPE = \frac{1}{N} \sum_{j=1}^N \left| \frac{P_j - T_j}{P_j} \right| * 100 \quad (3.1)$$

Onde,

- N : tamanho do conjunto de validação;
- P_j : previsão (simulação dos dados), para $j= 1,2,3, \dots, N$;
- T_j : teste (banco de dados), para $j= 1,2,3, \dots, N$;

A validação está atrelada a simulação da rede para o conjunto de dados que não foram aplicados no treinamento. A cada passo, o valor previsto será realimentado para o grupo de entradas, de forma que os valores a serem previstos sofram influência da previsão anterior. Na figura 19, é possível visualizar um exemplo da forma como as entradas e saídas se comportam no processo de validação. Observa-se na imagem que os valores previstos ($P'_4, P'_5, P'_6, T'_4, T'_5, T'_6\dots$) são transferidos para as entradas seguintes, substituindo os valores reais ($P_4, P_5, P_6, T_4, T_5, T_6\dots$).

Figura 19 – Realimentação da previsão no processo de validação e teste



Fonte: elaborado pelo autor, 2019

3.7 Correlação da potência com temperatura

Buscando verificar o nível de relação entre a temperatura e demanda neste trabalho, foi feito um código em MATLAB para obter um coeficiente de correlação, que irá definir a sincronia de comportamento entre essas duas variáveis.

Dessa forma, foram extraídas as informações do banco de dados previamente construído para o ano de 2008, além de uma leitura completa dos dados. Por fim, foi utilizado o comando *corrcoef* (A, B), em MATLAB, onde A e B representam os vetores dos valores de potência e temperatura, respectivamente. Este comando irá exibir uma matriz de coeficientes de correlação, da seguinte forma:

$$\begin{pmatrix} \rho(A, A) & \rho(A, B) \\ \rho(B, A) & \rho(B, B) \end{pmatrix}$$

Vale salientar que a matriz é do tipo simétrica.

Quando executada, a função *corrcoef* (A, B) resultou na matriz abaixo:

$$\begin{pmatrix} 1 & 0,1385 \\ 0,1385 & 1 \end{pmatrix}$$

Como A e B estão sempre diretamente correlacionados a si mesmos, as entradas A e B resultam em coeficientes de correlação unitários na diagonal principal. Já na diagonal secundária, estão presentes os coeficientes para a correlação feita entre as variáveis de potência e temperatura.

Informalmente, a correlação é sinônimo de dependência. Assim, como o coeficiente de correlação entre temperatura e potência resultou em um valor baixo (para um valor positivo, considera-se baixa a correlação no intervalo de 0 a 0,5 (Mukaka, M.M; 2012)), é

possível concluir que, para esse estudo de caso, a temperatura não afetou significativamente os valores de demanda. Isto, por sua vez, pode ser esperado devido à baixa variação de temperatura na cidade de Campina Grande para o ano de 2008.

4 Resultados

Neste capítulo, serão expostos os resultados do trabalho em detalhes. Desse modo, serão levadas em consideração as topologias de RNA propostas na seção anterior, para a previsão de demanda. O desempenho das redes foram avaliados na etapa de teste, considerando o *MAPE* e erro relativo como métricas de avaliação.

4.1 Redes considerando temperatura e potência como entradas

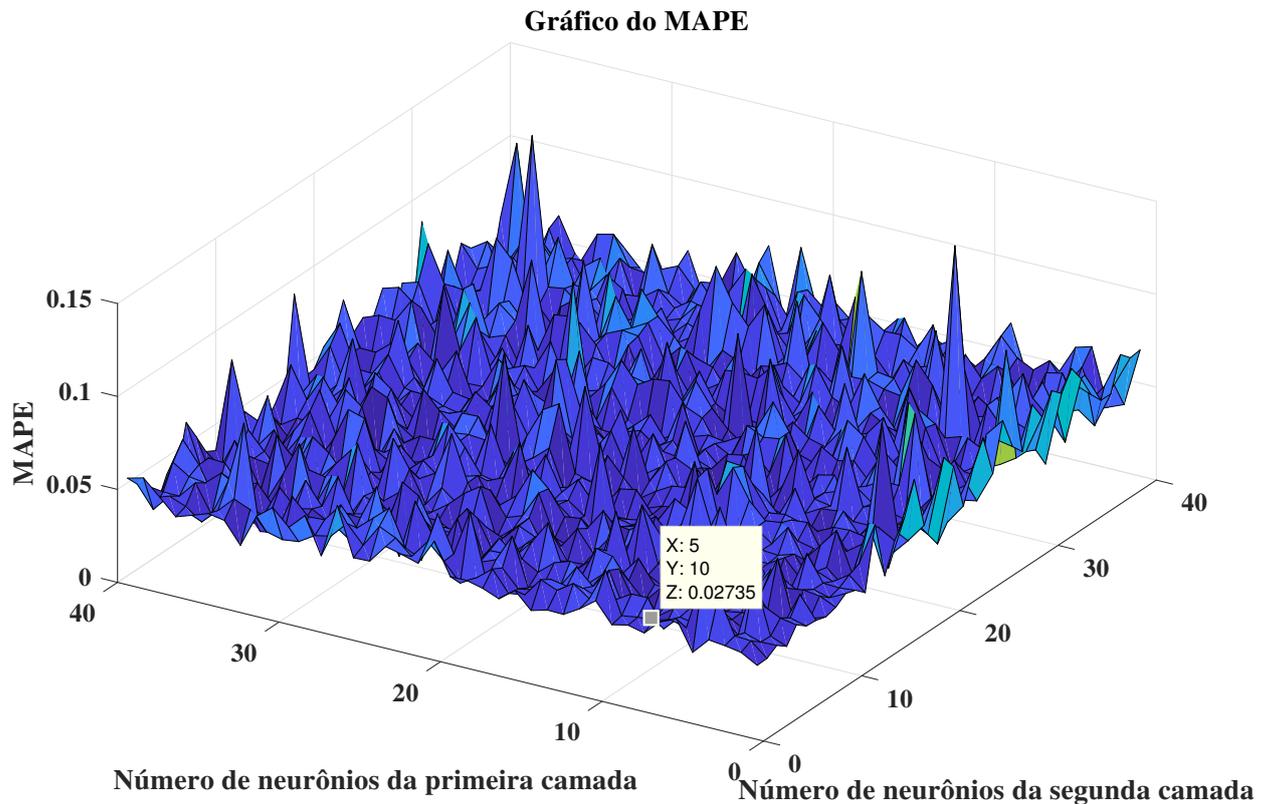
Com a topologia da RNA apresentada na figura 17, tendo como entradas temperatura e potência, para a previsão da demanda, foi inicialmente realizado o procedimento de treinamento. Para isso, os parâmetros utilizados foram os presentes na seção 3.5.

Buscando explorar e encontrar a melhor RNA, as redes foram treinadas utilizando duas camadas ocultas, onde cada uma poderia comportar no máximo 40 neurônios. Portanto, foram obtidas 1600 redes no total.

4.1.1 Cálculo do MAPE

Uma vez realizado o treinamento de todas as redes, estas foram avaliadas utilizando os dados de teste, considerando um período de 106 dias. Dessa forma, foi feito um código em MATLAB® para percorrer os arquivos das redes obtidas via treinamento, e computar os respectivos valores do MAPE. Conforme figura 20, foi esboçado o comportamento do MAPE para todas as redes encontradas. Ainda nesta figura, observa-se um ponto em destaque, identificado pela posição nas coordenadas x , y e z . O eixo y representa o número de neurônios da primeira camada, assim como o eixo x a quantidade de neurônios da segunda camada. O valor no eixo z indica o menor valor encontrado para o MAPE (2,73%) dentre todas as redes treinadas. Portanto, a rede com 10 e 5 neurônios na primeira e segunda camadas, respectivamente, foi a que obteve menor MAPE.

Figura 20 – Comportamento do MAPE



Fonte: elaborado pelo autor, 2019

4.1.2 Cálculo do erro relativo

De forma análoga ao MAPE, utilizou-se o comando *min* no MATLAB® para percorrer todos os valores dos erros relativos previamente calculados, e mostrar o valor mínimo entre eles, a fim de encontrar a melhor rede possível considerando esta métrica de avaliação. Assim, a rede com 31 e 5 neurônios na primeira e segunda camadas, respectivamente, foi a que exibiu mínimo erro relativo, igual a 8,7197%.

4.1.3 Teste da RNA

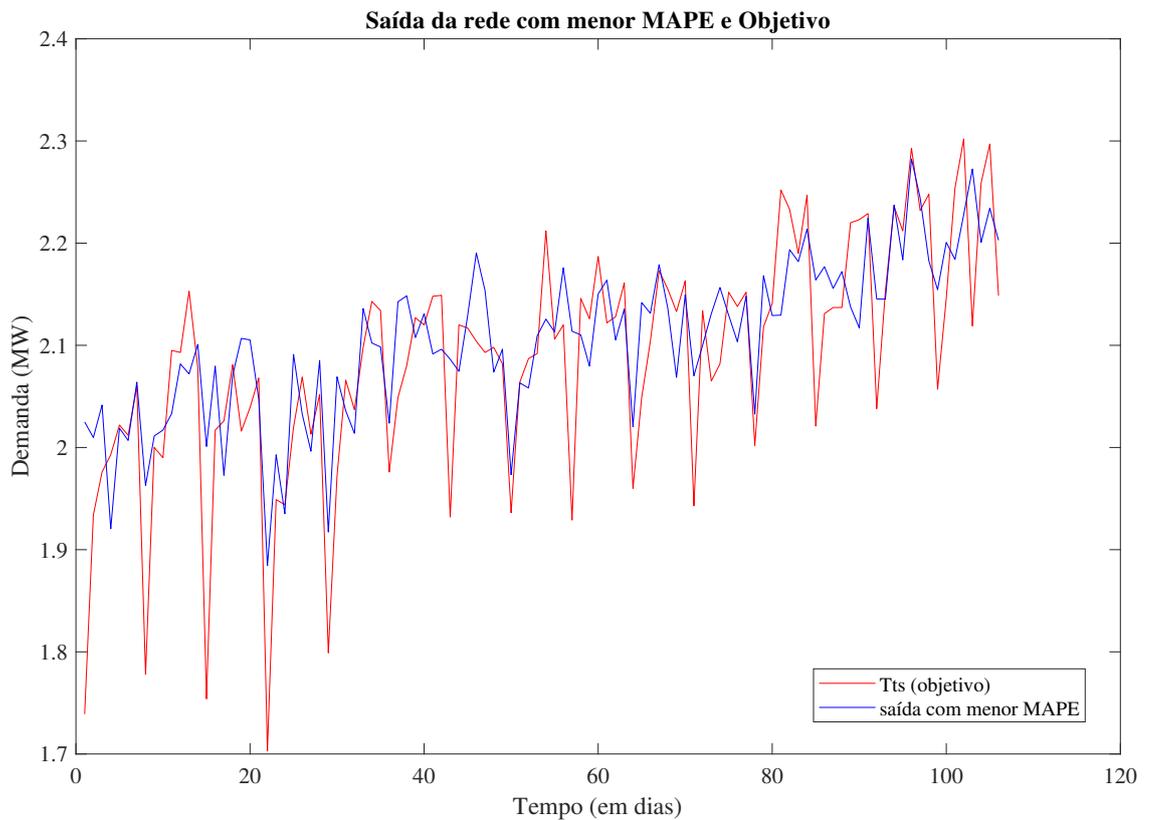
Tendo posse das redes com menor MAPE e mínimo erro relativo, tornou-se possível comparar o desempenho entre elas.

Nas figuras 21 e 22, foram ilustrados os resultados dos testes com as redes de menor MAPE e erro relativo mínimo, respectivamente. A partir disso, foi possível constatar uma maior fidelidade nos resultados obtidos da rede com menor MAPE, já que esta acompanha melhor a tendência do objetivo.

Porém, buscando uma melhor fundamentação, foi utilizada a técnica de *regressão*

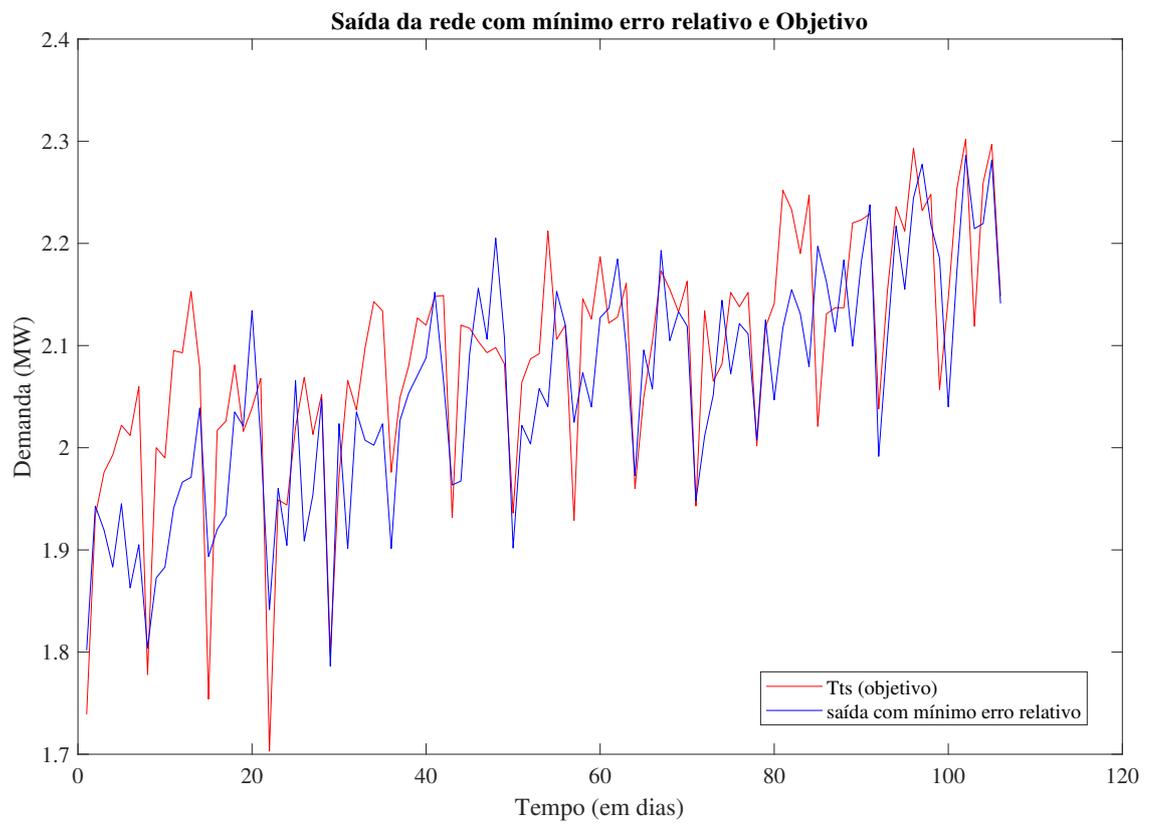
linear para estimar a tendência das previsões com menor MAPE e erro relativo. Assim, utilizando o comando **polyfit** no MATLAB®, foram traçadas curvas lineares para obter a rede que mais se aproxima do objetivo, conforme ilustrado nas figuras 23 e 24. A partir destes resultados, percebe-se que a tendência da previsão com menor MAPE tende a se alinhar mais precisa e rapidamente com os dados de teste (objetivo). As retas obtidas via regressão linear, a partir de um certo tempo, se aproximam, indicando uma melhor afinidade nos resultados.

Figura 21 – Curvas com a saída da rede de menor MAPE e objetivo



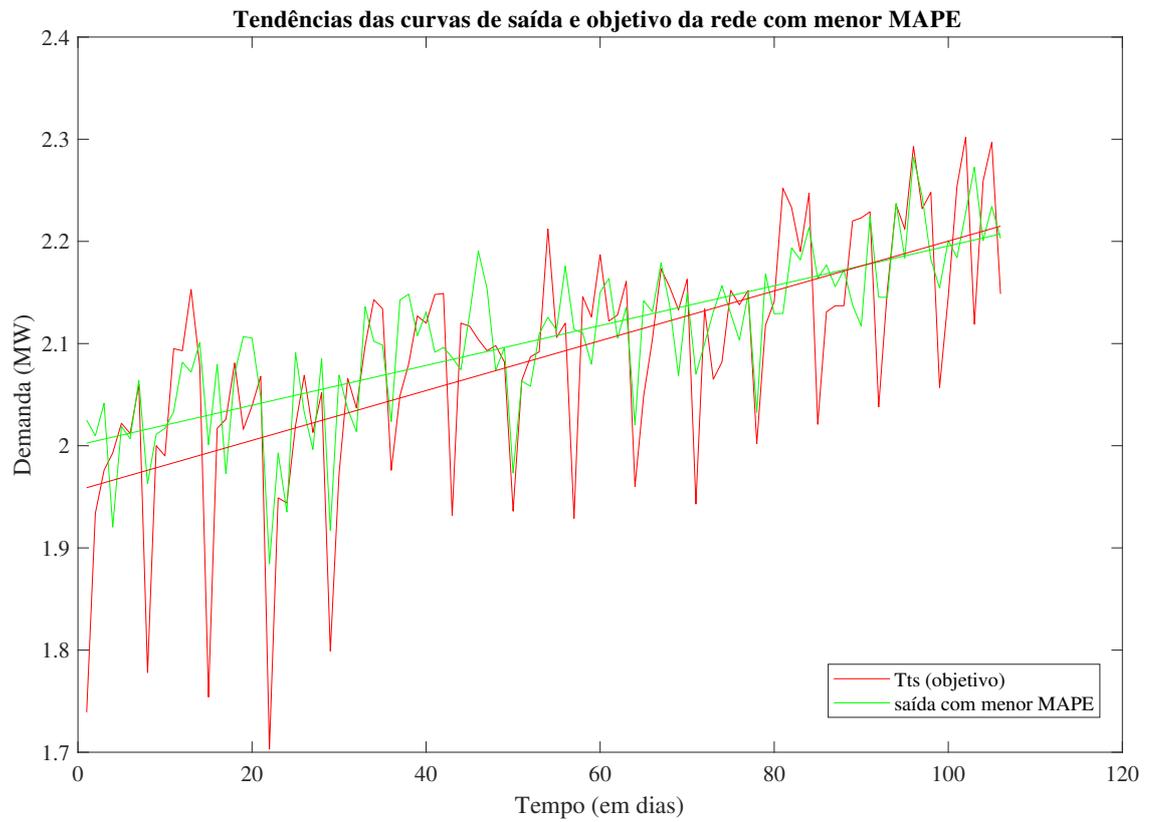
Fonte: elaborado pelo autor, 2019

Figura 22 – Curvas com a saída da rede de menor erro relativo e objetivo



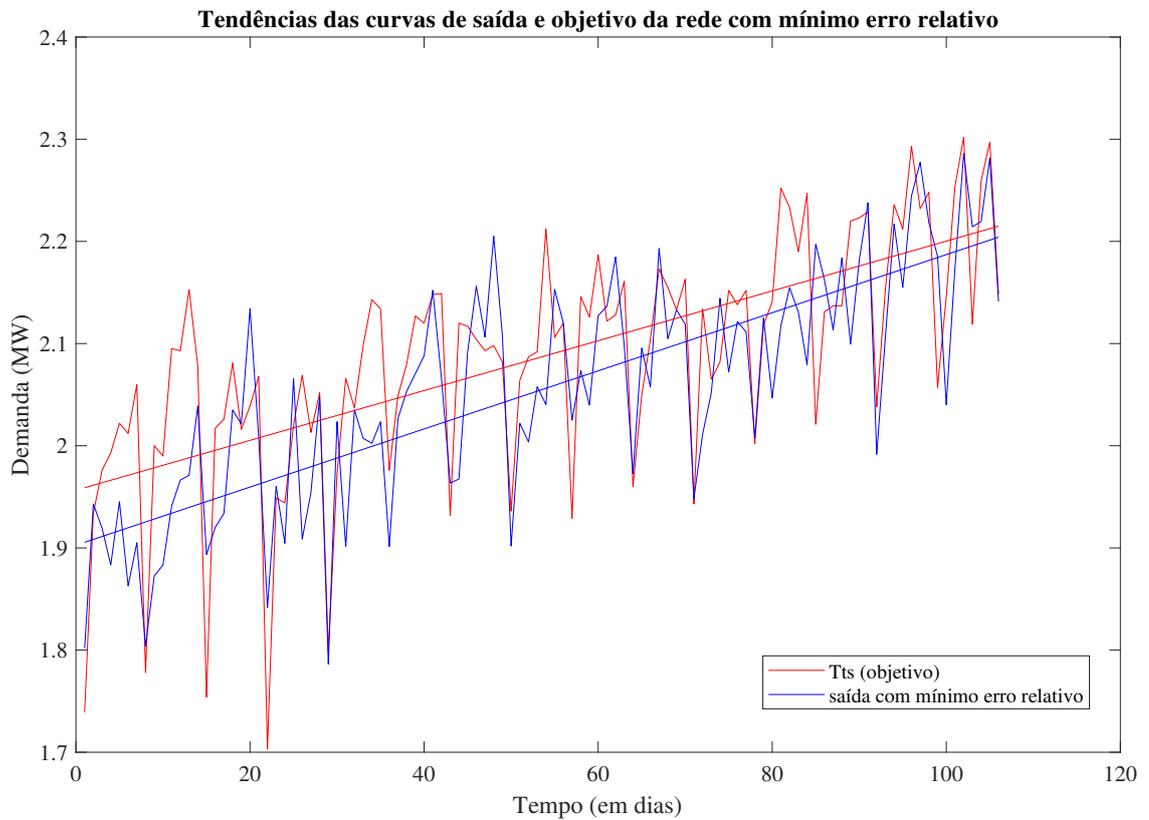
Fonte: elaborado pelo autor, 2019

Figura 23 – Curvas com a saída da rede de menor erro relativo e objetivo



Fonte: elaborado pelo autor, 2019

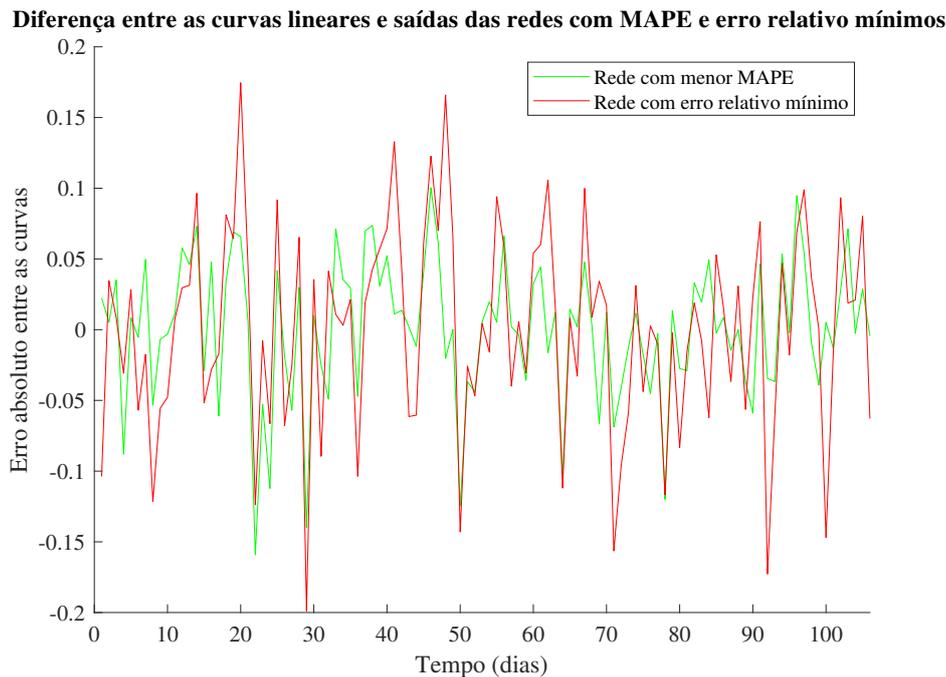
Figura 24 – Curvas com a saída da rede com mínimo erro relativo e objetivo



Fonte: elaborado pelo autor, 2019

Complementando as análises anteriores, foi elaborado um gráfico (figura 25) contendo a diferença existente entre as saídas das redes com mínimo MAPE e erro relativo e suas curvas lineares correspondentes, obtidas via técnica de regressão linear.

Figura 25 – Diferença entre as curvas lineares obtidas via regressão linear e saídas das redes com MAPE e erro relativo mínimos



Fonte: elaborado pelo autor, 2019

É possível observar que a rede com MAPE mínimo exibe valores predominantemente mais próximos à origem, indicando melhor desempenho para esta forma de avaliação.

4.2 Redes considerando apenas os dados de potência como entradas

Com a topologia da RNA apresentada na figura 18, tendo como entradas as potências atrasadas, para a previsão da demanda, foi inicialmente realizado o procedimento de treinamento. Para tal, os parâmetros utilizados foram os definidos anteriormente, na seção 3.5.

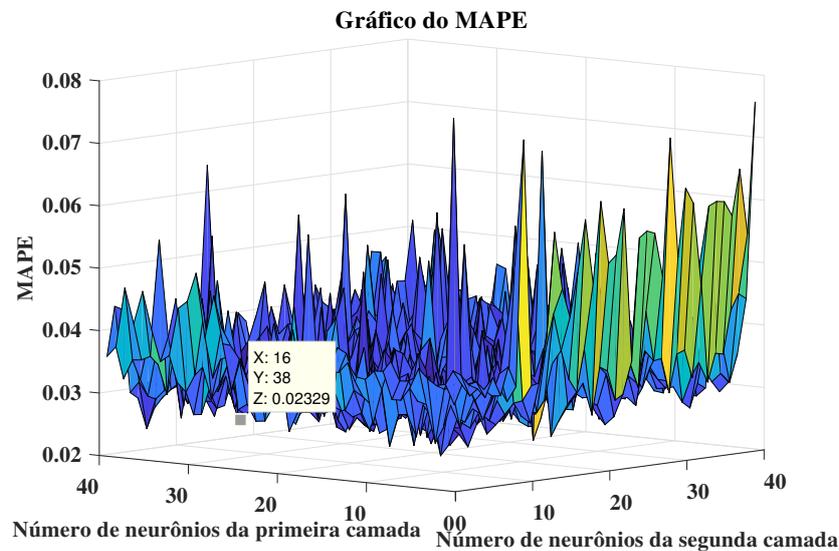
Conforme realizado na seção anterior, no intuito de explorar e encontrar a melhor RNA, os treinamentos das redes foram realizados utilizando duas camadas ocultas, onde cada uma poderia comportar no máximo 40 neurônios. Dessa forma, foram obtidas 1600 redes no total.

4.2.1 Cálculo do MAPE

Na figura 26, é ilustrado o comportamento do MAPE para todas as redes treinadas. Além disso, no gráfico foi destacado valor mínimo desta variável, igual a 2,33%. A rede

com tal MAPE possui 38 e 16 neurônios na primeira e segunda camadas, respectivamente.

Figura 26 – Comportamento do MAPE



Fonte: elaborado pelo autor, 2019

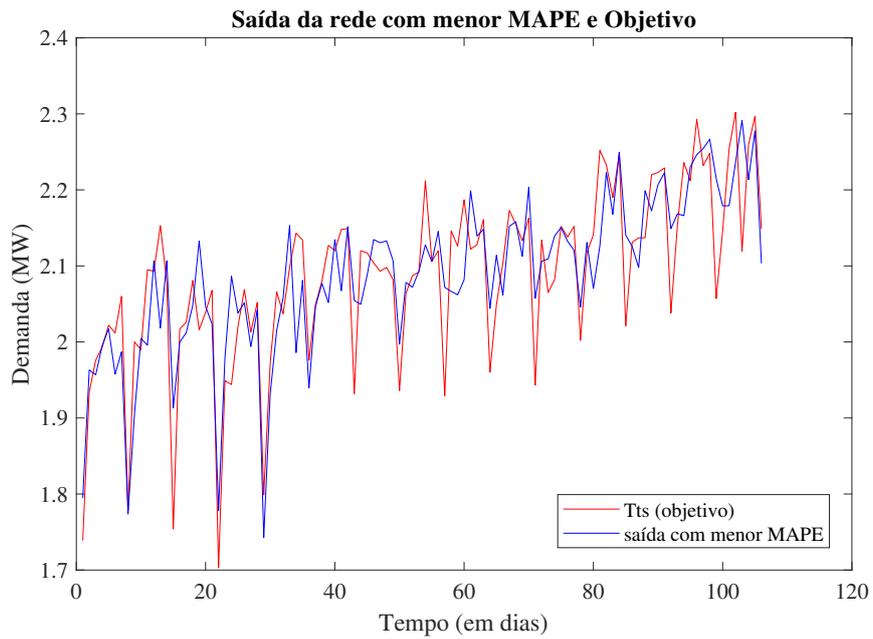
4.2.2 Cálculo do erro relativo

De forma análoga ao MAPE, utilizou-se o comando *min* no MATLAB® para percorrer todos os valores dos erros relativos previamente calculados, e mostrar o valor mínimo entre eles, afim de encontrar a melhor rede possível considerando esta métrica de avaliação. Assim, a rede com 31 e 5 neurônios na primeira e segunda camadas, respectivamente, foi a que exibiu mínimo erro relativo, igual a 6.8076%.

4.2.3 Teste da RNA

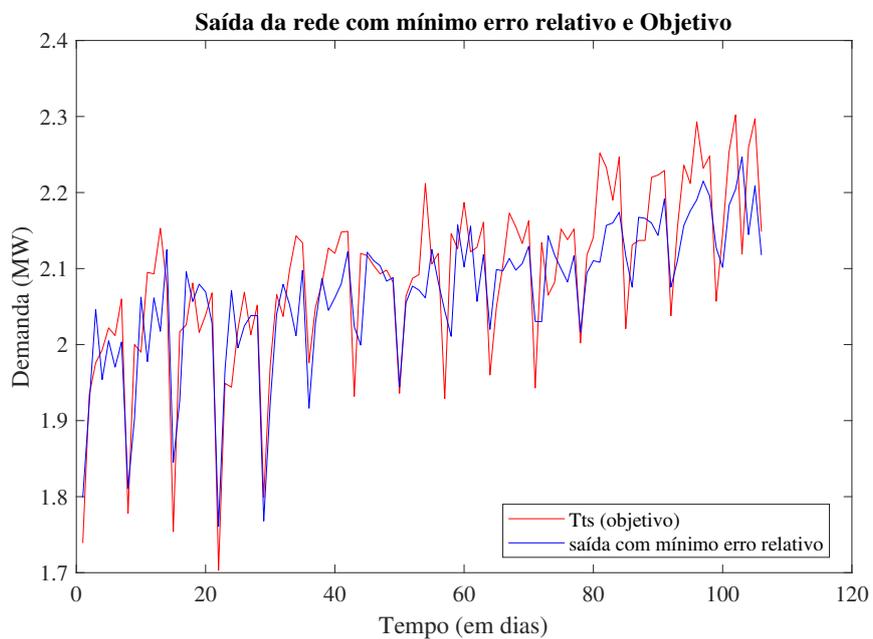
Nas figuras 27 e 28, são ilustrados os resultados das previsões de demanda obtidos das topologias que exibiram menor MAPE e mínimo erro relativo, respectivamente. A partir disso, foi possível observar que a saída da rede com menor MAPE acompanhou a tendência do objetivo de forma mais precisa. Porém, assim como na seção anterior, foram geradas curvas lineares (figuras 29 e 30) por meio da técnica de *regressão linear*, para estimar a saída que melhor representa os dados do objetivo.

Figura 27 – Saída da RNA com menor MAPE e Objetivo



Fonte: elaborado pelo autor, 2019

Figura 28 – Saída da RNA com menor erro relativo e Objetivo

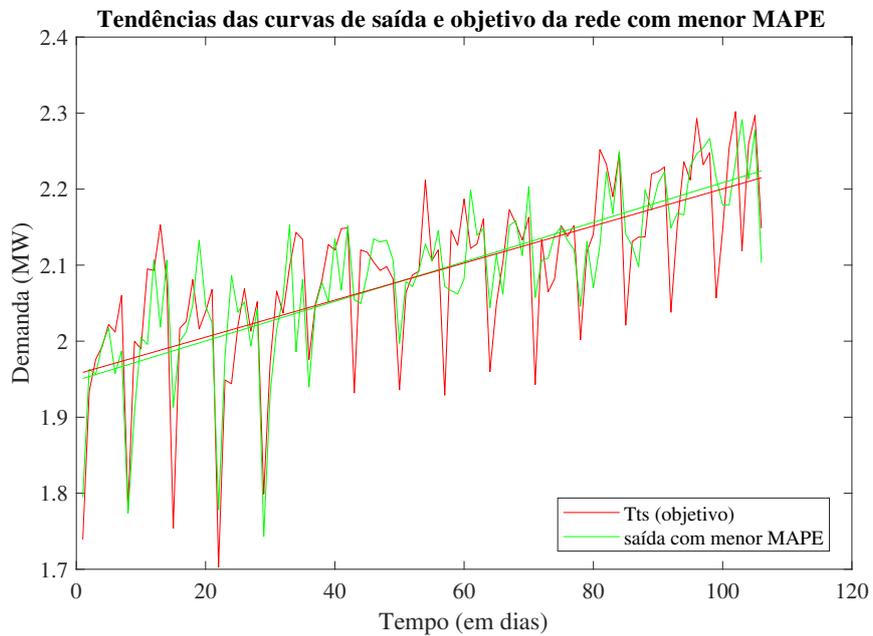


Fonte: elaborado pelo autor, 2019

De posse das curvas de regressão linear, foi observado que a saída com menor MAPE apresenta um comportamento consideravelmente fiel ao objetivo, de forma que as

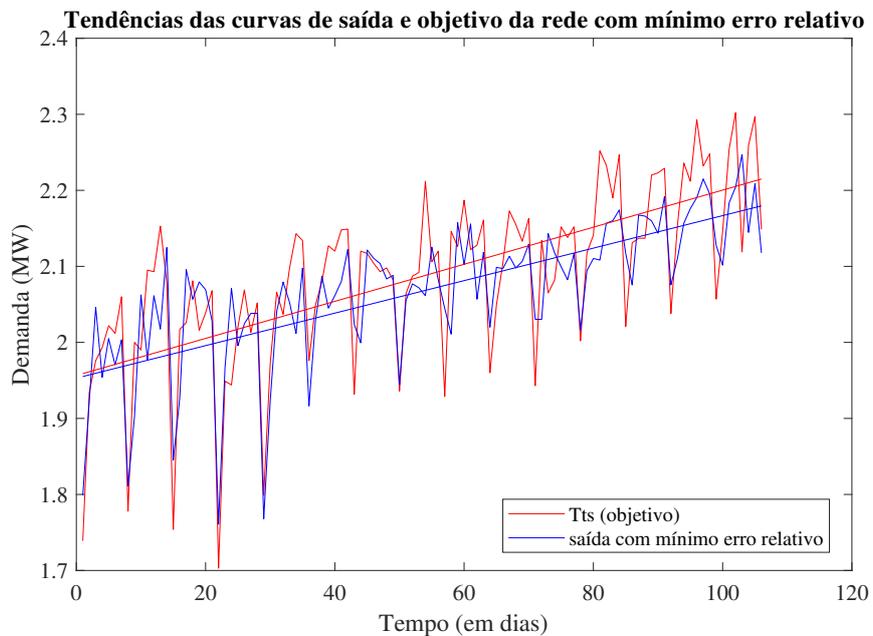
retas estão praticamente superpostas. Quanto à saída com erro relativo mínimo, a reta de saída e do objetivo divergem, indicando menor confiabilidade nos resultados de previsão.

Figura 29 – Tendências das curvas de saída e objetivo com menor MAPE



Fonte: elaborado pelo autor, 2019

Figura 30 – Tendências das curvas de saída e objetivo com menor erro relativo

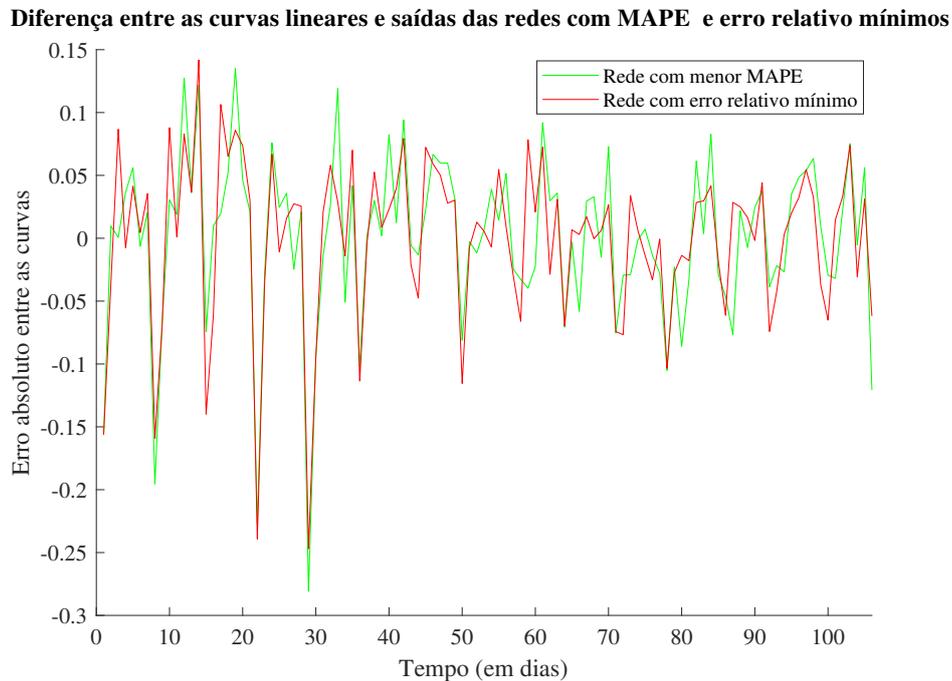


Fonte: elaborado pelo autor, 2019

Conforme executado na seção anterior, aqui também foi esboçado um gráfico (figura

31) para ilustrar a diferença existente entre as curvas lineares obtidas via regressão linear e as respectivas saídas das redes com erro relativo e MAPE mínimos.

Figura 31 – Tendências das curvas de saída e objetivo com menor erro relativo



Fonte: elaborado pelo autor, 2019

Visualmente, as curvas possuem comportamentos bem próximos, porém, a rede com menor MAPE exprimiu uma média de valores igual a -1.6758^{-16} , em comparação ao número -1.9691^{-16} , correspondente à de erro relativo mínimo. Assim, a rede com mínimo MAPE exibiu melhor resultado (maior proximidade à origem) segundo esta forma de avaliação.

4.3 Média dos erros relativos em ambas as configurações

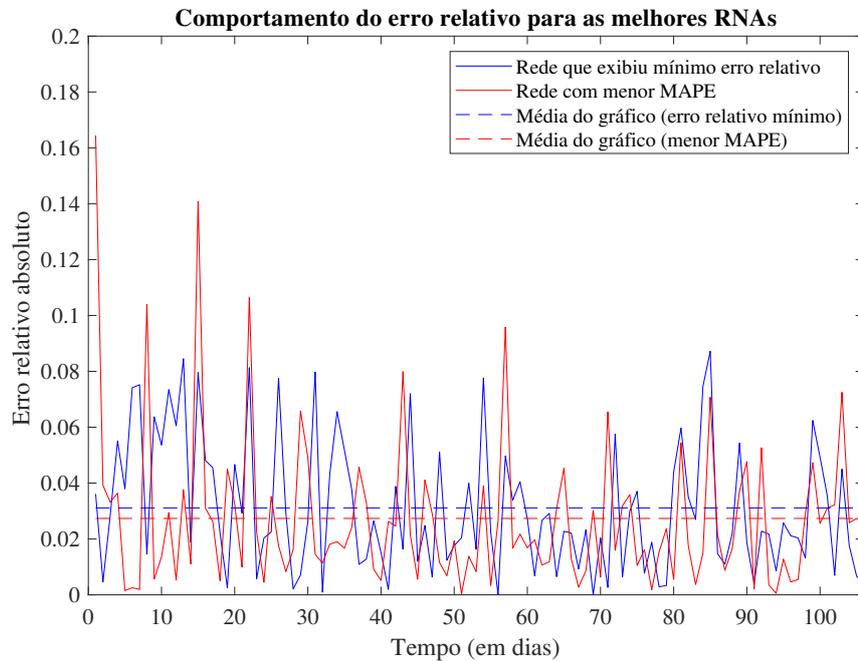
Tencionando complementar os resultados já obtidos, tanto para as redes tendo potência e temperatura como entradas, assim como potência apenas, foi realizado um estudo para avaliar o comportamento do erro relativo absoluto entre as melhores RNAs, segundo as duas métricas utilizadas neste trabalho.

4.3.1 Redes com entradas em potência e temperatura

A fim de realizar as análises citadas acima, foi elaborado um trecho de código para calcular e esboçar graficamente o erro relativo absoluto ponto a ponto, considerando as diferenças existentes entre as saídas das melhores redes e os respectivos objetivos.

A figura 32 ilustra o comportamento do erro relativo para as redes durante todo o período de testes (106 dias).

Figura 32 – Comportamento do erro relativo considerando potência e temperatura como entradas



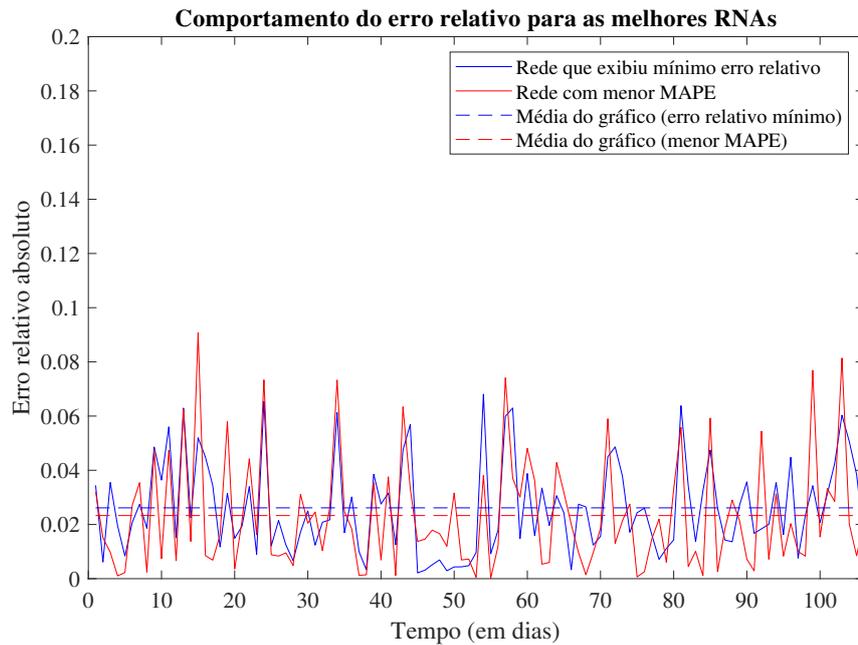
Fonte: elaborado pelo autor, 2019

Com as curvas traçadas, foi feita a média de cada gráfico, indicadas pelas linhas tracejadas, facilitando uma visão global dos resultados. Assim, o gráfico deixa claro que a rede de menor MAPE apresentou um erro relativo absoluto médio inferior.

4.3.2 Redes com entradas apenas em potência

Analogamente à subseção anterior, o mesmo código foi aplicado para as redes com entradas apenas em potência, calculando o erro relativo absoluto e exibindo um gráfico correspondente, conforme figura 33.

Figura 33 – Comportamento do erro relativo considerando apenas entradas em potência



Fonte: elaborado pelo autor, 2019

Observando os patamares tracejados (médias dos respectivos gráficos), é fácil observar que a rede com menor MAPE resultou em um erro relativo médio inferior.

4.4 Conclusão

Após as análises envolvendo MAPE e erro percentual correspondentes às redes treinadas, os resultados apontam que as redes com entradas apenas em potência são mais efetivas em ambas as métricas de avaliação. Isto pode ser explicado pela baixa correlação entre os dados de temperatura e potência, como foi desenvolvido no capítulo anterior.

5 Considerações finais

Neste trabalho, foi apresentado um estudo de caso para subestação de Alto Branco (Centro), localizada em Campina Grande-PB. O objetivo ficou concentrado em elaborar modelos de previsão de demanda, visando criar uma ferramenta de tomada de decisões para os setores de planejamento estratégico de energia. Inicialmente, buscando melhores resultados, além de dados de potência, considerou-se a temperatura como fator externo.

Diante do que foi proposto, foram utilizadas Redes Neurais Artificiais, que constituem técnicas computacionais de inteligência artificial. Assim, com os dados de potência passados, fornecidos pela concessionária de energia, e valores de temperatura locais obtidos pelo Instituto Nacional de Meteorologia (INMET), ambos para o ano de 2008, as redes foram devidamente treinadas. Observou-se que a inclusão dos valores de temperatura como entradas afetou negativamente os resultados para este estudo de caso, já que foi apontada uma baixa correlação entre as variáveis de potência e temperatura no período avaliado (ano de 2008). Porém, as saídas das redes considerando apenas valores de potência passados nas entradas exibiram resultados satisfatórios, com um MAPE mínimo de 2,33%.

As atividades aqui realizadas foram estruturadas através da construção de um banco de dados envolvendo informações passadas de potência e temperatura, correção de *outliers*, correlação de variáveis, e treinamento baseado em Redes Neurais Artificiais do tipo MultiLayer Perceptron. Para o banco de dados, foram extraídos os valores máximos diários de potência e temperatura e, mediante algoritmos de detecção de *outliers*, eles foram corrigidos. A correlação de variáveis teve como objetivo determinar o nível de dependência existente entre os dados de potência e temperatura. O treinamento foi desde a elaboração da metodologia de previsão, estabelecimento de parâmetros, definição do algoritmo, até a fase de testes para, por fim, gerar os resultados finais.

Diante das métricas aqui aplicadas para verificar o desempenho dos resultados das topologias de RNA estudadas, as respostas foram satisfatórias. Apesar de os resultados obtidos com a inclusão da temperatura não terem sido os melhores, para um trabalho futuro podem ser realizados estudos em locais cuja variação de temperatura seja maior ao longo do ano, de forma que a correlação entre a potência e temperatura seja considerável.

6 Referências bibliográficas

ALEXANDRINO, J. L.; ZANCHETTIN, C.; CARVALHO FILHO, E. **A hybrid intelligent system clonart for short and mid-term forecasting for the Brazilian Energy Distribution System.** In: IEEE International Joint Conference on Neural Networks, 2008.

ANDRADE, L. N. de. **Redes neurais artificiais aplicadas na identificação automática de áreas cafeeiras em imagens de satélite.** 2011. UFMG, Belo Horizonte - MG, 2011.

ANDRADE, L. C. M. D. **Abordagem neurofuzzy para previsão de demanda de energia elétrica no curtíssimo prazo.** 2010. Biblioteca Digital de Teses e Dissertações da USP, 2010.

ANEEL. **Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST Módulo 2 – Planejamento da Expansão do Sistema de Distribuição, 2005.** Disponível em: <http://www.aneel.gov.br/arquivos/PDF/Modulo2_V2.pdf>. Acesso em: 10 mar. 2019.

ANEEL. **Atlas de energia elétrica do Brasil** Agência Nacional de Energia Elétrica, 2008.

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time series analysis: forecasting and control.** 4 edition ed. Hoboken, N.J: Wiley, 2008.

CARMONA, D.; JARAMILLO, M. A.; GONZALEZ, E.; ALVAREZ, J. A. **Electric energy demand forecasting with neural networks.** In: IECON 2002.

CERRI, R. **Redes neurais e algoritmos genéticos para problemas de classificação hierárquica multirrótulo.** 2014. USP, São Carlos - SP, 2014.

CHARYTONIUK, W.; CHEN, M.-S. **Neural network design for short-term load forecasting.** In: International Conference on Electric Utility Deregulation and

Restructuring and Power Technologies, 2000.

CHARYTONIUK, W.; CHEN, M.-S. **Very short-term load forecasting using artificial neural networks**. IEEE Transactions on Power Systems, v. 15, n. 1, p. 263–268, fev. 2000b.

COMITÊ DE DISTRIBUIÇÃO, E. **Planejamento de sistemas de distribuição (coleção distribuição de energia elétrica volume 1)**. Rio de Janeiro: Campus/Eletróbrás, 1982. v. 1

DE AQUINO, R. R. B.; FERREIRA, A. A.; LIRA, M. M. S.; SILVA, G. B.; NETO, O. N.; OLIVEIRA, J. B.; DINIZ, C. F.; FIDELES, J. **A Hybrid Intelligent System for Short and Mid-term Forecasting for the CELPE Distribution Utility**. In: International Joint Conference on Neural Networks, 2006. IJCNN '06.

DE AQUINO, R. R. B.; NETO, O. N.; LIRA, M. M. S.; FERREIRA, A. A.; CARVALHO, M. A.; SILVA, G. B.; DE OLIVEIRA, J. B. **Development of an Artificial Neural Network by Genetic Algorithm to Mid-Term Load Forecasting**. In: International Joint Conference on Neural Networks, 2007. IJCNN 2007,

FISCHER, S. **séries univariantes de tempo — metodologia de box & jenkins**. 1981. Universidade Federal do Rio Grande do Sul, Porto Alegre, 1981.

FONSECA, E. T.; VELLASCO, P. C. G. S.; VELLASCO, M. M. B. R.; DE ANDRADE, S. A. L. **A neuro-fuzzy system for steel beams patch load prediction**. In: Fifth International Conference on Hybrid Intelligent Systems, 2005. HIS '05.

FRANCO JUNIOR, E. F. **Modelo para previsão de demanda ativa usando rna**. 2013. Universidade Estadual de Campinas, 2013.

GHIASSI, M.; ZIMBRA, D.; SAIDANE, H. **Medium Term System Load Forecasting with a Dynamic Artificial Neural Network Model**. Electric Power Systems Research, v. 76, n. 5, p. 302–316, 2006.

GONCALVES, L. B.; VELLASCO, M. M. B. R.; PACHECO, M. A. C.; SOUZA, F. J. de. **Inverted hierarchical neuro-fuzzy BSP system: a novel neuro-fuzzy model**

for pattern classification and rule extraction in databases. IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews, v. 36, n. 2, p. 236–248, mar. 2006.

GUIRELLI, C. R. **Previsão da carga de curto prazo de áreas elétricas através de técnicas de inteligência artificial.** 2006. Biblioteca Digital de Teses e Dissertações da USP, 2006.

GUO, Z.; LI, W.; LAU, A.; INGA-ROJAS, T.; WANG, K. **Detecting X-Outliers in Load Curve Data in Power Systems.** IEEE Transactions on Power Systems, v. 27, n. 2, p. 875–884, maio 2012.

HAYKIN, S. **Neural networks: a comprehensive foundation.** [s.l.] MacMillan Publishing Company, 1994.

HAYKIN, S. S. **Redes neurais - principios e prática.** 2 edition ed. Porto Alegre: Bookman, 2001.

HEBB, D. O. **The organization of behavior.** New York: Wiley, 1949.

JARNDAL, A. **Load forecasting for power system planning using a genetic-fuzzy-neural networks approach.** In: 2013 7th IEEE GCC Conference and Exhibition (GCC).

JIN, L.; FENG, Y.; JILAI, Y. **Peak Load Forecasting Using Hierarchical Clustering and RPROP Neural Network.** In: 2006 IEEE PES.

KAGAN, N.; OLIVEIRA, C. C. B. de; ROBBA, E. J. **Introdução aos sistemas de distribuição de energia.** Edição: 1 ed. São Paulo: Edgard Blucher, 2005.

KARAYIANNIS, N. B.; BALASUBRAMANIAN, M.; MALKI, H.; OTHERS. **Evaluation of cosine radial basis function neural networks on electric power load forecasting.** In: Neural Networks, 2003.

MACRINI, J. L. R. **Modelo de previsão de carga utilizando redes neurais: otimização camada a camada.** 2000. PUC-Rio, 2000.

MCCULLOCH, W. S.; PITTS, W. **A logical calculus of the ideas immanent in nervous activity**. Bulletin of Math. Biophys, v. 5, p. 115–133, 1943.

MINSKY, M. **The society of mind**. New York: Simon and Schuster, 1986.

MORI, H.; KURATA, E. **Graphical Modeling for Selecting Input Variables of Short-term Load Forecasting**. In: Power Tech, jul. 2007.

NORVIG, P.; RUSSELL, S. **Inteligência artificial**. Edição: 2a ed. [s.l.] Elsevier Acadêmico, 2004.

PAN, X.; LEE, B. **A comparison of support vector machines and artificial neural networks for mid-term load forecasting**. mar. 2012.

PARK, D. C.; EL-SHARKAWI, M. A.; MARKS, R. J.; ATLAS, L. E.; DAMBORG, M. J.; OTHERS. **Electric load forecasting using an artificial neural network**. Power Systems, IEEE Transactions on, v. 6, n. 2, p. 442–449, 1991.

RIBEIRO, P. M.; GARRIDO, D. A.; VELÁSQUEZ, R. M. G.; FALCÃO, D. M.; DA SILVA, A. P. A. **Sistema computacional para previsão de demanda por energia em pontos de suprimento e subestações da COELBA**. XVII Seminário Nacional de Distribuição de Energia Elétrica–SENDI. Belo Horizonte, 2006.

RIEDMILLER, M.; BRAUN, H. **A direct adaptive method for faster backpropagation learning: The RPROP algorithm**. In: Neural Networks, 1993., IEEE International Conference On.

ROSENBLATT, F. **The perceptron: a probabilistic model for information storage and organization in the brain**. Psychological review, v. 65, n. 6, p. 386, 1958.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. **Learning representations by back-propagating errors**. Nature, v. 323, p. 533–536, 1986.

SAGE, A. P.; SINGH, M. G. **Concise encyclopedia of information processing in systems & organizations**. [s.l.] Pergamon Press, 1990.

SANTOS, A. H. M.; HADDAD, J.; CRUZ, R. A. P. da. **Planejamento da Expansão da Distribuição: Considerações Técnicas e Regulatórias**. 2008.

SZKOŁA, J.; PANCERZ, K.; WARCHOŁ, J. **Recurrent Neural Networks in Computer-Based Clinical Decision Support for Laryngopathies: An Experimental Study**. Computational Intelligence and Neuroscience, 2011. Disponível em: <<http://www.hindawi.com/journals/cin/2011/289398/abs/>>. Acesso em: 15 mar. 2019.

TAYLOR, J. W. **An evaluation of methods for very short-term load forecasting using minute-by-minute British data**. International Journal of Forecasting, v. 24, n. 4, p. 645–658, 2008.

TEPCO. Disponível em: <<http://www.tepco.co.jp/index-j.html>>. Acesso em: 30 mar. 2016.

TURING, A. M. **Computing machinery and intelligence**. Mind, v. 59, n. 236, p. 433–460, 1950.

VELLASCO, M. M. B. R. **Redes Neurais Artificiais**. Rio de Janeiro, Brasil, PUC, notas de Aula, Brasil, 2007. Disponível em: <<http://www.ica.ele.puc-rio.br/Downloads%5C33/ICA-introdu%C3%A7%C3%A3o%20RNs.pdf>>. Acesso em: 25 mar. 2019.

VIGLIONI, G. M. C.; CURY, M. V. Q.; DA SILVA, P. A. L. **Comparação entre Redes Neurais e Técnicas Clássicas para Previsão de Demanda de Transporte Ferroviário**. 2006.

WIDROW, B.; LEHR, M. A. **30 years of adaptive neural networks: perceptron, madaline, and backpropagation**. Proceedings of the IEEE, v. 78, n. 9, p. 1415–1442, 1990.

ZANINI, A. **Redes neurais e regressão dinâmica: um modelo híbrido para previsão de curto prazo da demanda de gasolina automotiva no brasil**. 2000. PUC-Rio, 2000. Disponível em: <<http://www.maxwell.vrac.puc-rio.br/7457/7457.PDF>>. Acesso em: 16 mar. 2019.

ZHANG, L. D.; JIA, L.; ZHU, W. X. **Overview of traffic flow hybrid ANN forecasting algorithm study.** In: **Computer Application and System Modeling (ICCA SM)**, IEEE, 2010.

Mukaka, M M. **“Statistics corner: A guide to appropriate use of correlation coefficient in medical research.”** Malawi medical journal : the journal of Medical Association of Malawi vol. 24,3 (2012): 69-71.

MEDEIROS, Romero Álamo Oliveira de. **Previsão de demanda no médio prazo utilizando redes neurais artificiais em sistemas de distribuição de energia elétrica.** 2016. 85f. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal da Paraíba, João Pessoa, 2016.