



PAULO ROBERTO MARQUES

**PREDIÇÃO DA GERAÇÃO DE ENERGIA FOTOVOLTAICA
APLICANDO O MODELO *NARX***

LAVRAS – MG

2020

PAULO ROBERTO MARQUES

**PREDIÇÃO DA GERAÇÃO DE ENERGIA FOTOVOLTAICA APLICANDO O
MODELO *NARX***

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas e Automação, para obtenção do título de Mestre.

Prof. Dr. Wilian Soares Lacerda

Orientador

LAVRAS – MG

2020

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca
Universitária da UFLA, com dados informados pelo(a) próprio autor.**

Marques, Paulo Roberto

Predição da Geração de Energia Fotovoltaica Aplicando o
Modelo *Narx* / Paulo Roberto Marques. – Lavras : UFLA,
2020.

60 p. : il.

Dissertação (mestrado acadêmico)–Universidade Federal
de Lavras, 2020.

Orientador: Prof. Dr. Wilian Soares Lacerda.

Bibliografia.

1. Energia Solar. 2. Rede Neural Artificial. 3. Gestão de
Sistema Elétrico. I. Lacerda, Wilian Soares. II. Título.

PAULO ROBERTO MARQUES

**PREDIÇÃO DA GERAÇÃO DE ENERGIA FOTOVOLTAICA APLICANDO O
MODELO *NARX***

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas e Automação, para obtenção do título de Mestre.

APROVADA em 31 de Agosto de 2020.

Prof. Dr Rogério Martins Gomes CEFET-MG
Prof. Dr Joaquim Paulo da Silva UFLA

Prof. Dr. Wilian Soares Lacerda
Orientador

**LAVRAS – MG
2020**

Dedico este trabalho a minha filha Thais L.Marques.

AGRADECIMENTOS

Cada avanço pessoal, é uma oportunidade para agradecimentos.

Agradeço acima de tudo a Deus por revigorar minhas forças a cada instante;

Agradeço a minha família que sempre me apoia e motiva;

Agradeço ao meu orientador professor doutor Wilian Soares Lacerda por permitir e auxiliar na realização dessa pesquisa, e por confiar em meu trabalho;

Agradeço a todos os membros da banca que dedicaram seu tempo na leitura e avaliação desse trabalho;

Agradeço ao professor doutor Joaquim Paulo da Silva pelas valiosas contribuições;

À Universidade Federal de Lavras (UFLA) e ao programa de pós-graduação em Engenharia de Sistemas e Automação, pela minha formação profissional e oportunidade de realização do curso;

A todos os professores do departamento de Automática, exemplos de dedicação e por contribuírem com ensinamentos para meu aprendizado;

A todos que de alguma forma contribuíram para que essa etapa da minha vida fosse especial e inesquecível.

Muito Obrigado!

*A mola propulsora para a conquista é a Fé, acreditar no que não se vê.
(Paulo R. Marques)*

RESUMO

A natureza intermitente da luz solar cria um desequilíbrio entre a geração de energia fotovoltaica e o consumo de eletricidade, dificultando o controle de todo o sistema elétrico. Por essa razão as concessionárias de energia necessitam de uma estimativa altamente precisa para gestão e comercialização de eletricidade quando há geração fotovoltaica. Objetivando propor um método de predição da geração de energia fotovoltaica, aplicou-se nesta pesquisa a rede auto-regressiva não linear com entradas exógenas *NARX*. Para tanto, foram empregados dados climatológicos como temperatura, radiação solar, bem como a energia gerada de uma microestação fotovoltaica particular em Varginha - MG (banco 1) no período entre 08/04/2019 a 20/04/2020. Também foram empregados dados de mais duas microestações distintas (banco 2 e banco 3) para análise comparativa de desempenho da rede *NARX*. Os três bancos de dados foram utilizados como variáveis de entrada na rede *NARX*, onde foram aplicados diferentes números de atrasos e de neurônios, totalizando trinta configurações. Por meio dos erros médios quadráticos de cada configuração, realizou-se a análise de variância e teste de comparação múltipla de Scott Knott, para a seleção das melhores configurações da rede para os três bancos de dados estudados. Concluiu-se que a rede *NARX* é apropriada para predição da geração de energia fotovoltaica com uma hora de antecipação. Os resultados obtidos com base no erro médio quadrático (EMQ = 0,0027) e coeficiente de determinação ($R^2 = 0,979$) mostraram que a configuração de 50 atrasos e 15 neurônios apresentou maior eficiência na predição. Foi aplicada a regressão polinomial, para o banco 1 de dados, obtendo-se o coeficiente de determinação $R^2 = 0,9166$.

Palavras-chave: Energia Solar; Rede Neural Artificial (*RNA*); Modelagem; Gestão de Sistema Elétrico.

ABSTRACT

The intermittent nature of sunlight creates an imbalance between the generation of photovoltaic energy and the consumption of electricity, making it difficult to control the entire electrical system. Therefore, for better controlling its generation, a highly accurate estimate in the next hour or on the business day of power generation, for allowing better management and commercialization of photovoltaic electricity. For this reason the nonlinear autoregressive network with exogenous inputs *NARX* was applied in this research, aiming to select the an effective network configuration for predicting photovoltaic energy generation. Data from the meteorological station, such as temperature and solar radiation, were used in addition to the energy generated from a private photovoltaic microgeneration in Varginha - MG, during the period between 08/04/2019 and 20/04/2020. Data from two other micro-generation plant were compared for network performance analysis. The three databases were used as input variables in the *NARX* network, where different numbers of delays and neurons were applied, totaling thirty configurations. Through the mean squared errors of each configuration, analysis of variance and multiple comparison Scott Knott test were performed to select the most efficient network configuration for all three databases. It was concluded that the *NARX* network is suitable for predicting the generation of photovoltaic energy hour ahead. The results obtained based on the mean quadratic error ($EMQ = 0.0027$) and determination coefficient ($R^2 = 0.979$) showed that the configuration of 50 delays and 15 neurons showed greater efficiency in the prediction. Polynomial regression was applied to database 1, obtaining the coefficient of determination ($R^2 = 0.9166$).

Keywords: Solar energy; Artificial Neural Network *RNA*; Modeling; Electrical System Management.

LISTA DE FIGURAS

Figura 2.1 – Variação dos níveis de corrente e tensão com diferentes valores de irradiância com temperatura fixa em um painel fotovoltaico.	17
Figura 2.2 – Variação dos níveis de corrente e tensão para diferentes valores de temperatura em um painel fotovoltaico.	20
Figura 2.3 – Ângulos de inclinação do módulo e de incidência da radiação solar.	21
Figura 2.4 – Um modelo simplificado de um neurônio biológico.	25
Figura 2.5 – Modelo de um neurônio artificial.	25
Figura 2.6 – Rede Neural Simples.	26
Figura 2.7 – Função Degrau.	27
Figura 2.8 – Função Sigmoidal.	28
Figura 2.9 – Função Semi-linear	28
Figura 2.10 – Processo de treinamento <i>Perceptron</i>	29
Figura 2.11 – Treinamento <i>Perceptron</i> Multicamadas.	29
Figura 2.12 – Estrutura de uma <i>NARX-RNA</i>	32
Figura 3.1 – Dados de Energia Elétrica Fotovoltaica, Temperatura e Radiação.	34
Figura 3.2 – Banco de dados utilizados para predição.	35
Figura 3.3 – Diagrama unifilar do sistema fotovoltaico.	36
Figura 3.4 – Usina particular na cidade de Varginha - MG.	36
Figura 3.5 – Detalhamento da rede <i>NARX</i>	38
Figura 3.6 – Fluxograma das etapas envolvidas no processo da rede <i>NARX</i>	39
Figura 4.1 – Histograma das médias EMQ transformadas via <i>Box-Cox</i> para os diferentes bancos de dados utilizados na etapa de validação da rede <i>RNA-NARX</i> com teste Scott-Knott a 95% de confiança.	43
Figura 4.2 – Histograma das médias EMQ, transformadas via <i>Box-Cox</i> , para as diferentes variações nos atrasos utilizados na rede <i>RNA-NARX</i> com teste <i>Scott-Knott</i> a 95% de confiança.	44
Figura 4.3 – Histograma das médias EMQ transformadas via <i>Box-Cox</i> , para os diferentes números de neurônios utilizados na rede <i>RNA-NARX</i> com teste <i>Scott-Knott</i> a 95% de confiança.	44
Figura 4.4 – Evolução do EMQ sobre os dados de treinamento, teste e validação.	47
Figura 4.5 – Rede <i>RNA-NARX</i>	47

Figura 4.6 – Análise de regressão linear entre a potência medida e predita.	48
Figura 4.7 – Resposta da rede <i>RNA-NARX</i> aos dados de entrada.	48
Figura 4.8 – Autocorrelação dos resíduos (erros) encontrados para a rede <i>RNA-NARX</i> . .	49
Figura 4.9 – Diagrama de dispersão - Regressão polinomial.	49

LISTA DE TABELAS

Tabela 3.1 – Caracterização da estação meteorológica automática de observação de superfície na região de Varginha - MG.	35
Tabela 3.2 – Dados Elétricos do módulo fotovoltaico STC*.	37
Tabela 3.3 – Dados Elétricos do Inversor FRONIUS PRIMO 8.2-1.	37
Tabela 3.4 – Dados da configuração da rede <i>RNA-NARX</i>	40
Tabela 4.1 – Análise de variância para os Erros Médios Quadráticos (EMQ) transformados dos diferentes modelos implementados na rede <i>RNA-NARX</i>	42
Tabela 4.2 – Seleção das configurações que apresentaram menores erros médios quadráticos (EMQ), segundo teste estatístico.	45
Tabela 4.3 – Análise de performance dos modelos selecionados.	46

SUMÁRIO

1	INTRODUÇÃO	11
1.1	Problema	12
1.2	Motivação	13
1.3	Objetivos	14
1.4	Organização do trabalho	15
2	REFERENCIAL TEÓRICO	16
2.1	Fatores que influenciam na geração de energia fotovoltaica	16
2.1.1	Irradiância	16
2.1.2	Temperatura	19
2.1.3	Ângulo de incidência da radiação solar	21
2.1.4	Sombreamento	22
2.2	Predição de geração de energia fotovoltaica	22
2.2.1	Predição de geração com Inteligência computacional - IC	23
2.3	Rede Neural Artificial (RNA)	24
2.3.1	Função de ativação	27
2.3.2	Método <i>backpropagation</i> ou retropropagação	30
2.3.3	Modelo <i>NARX</i> polinomial	30
2.3.4	Estimação de Parâmetros	31
2.3.5	Rede <i>RNA-NARX</i>	31
2.3.6	Métricas de Desempenho	32
3	MATERIAIS E MÉTODOS	34
3.1	Sistema de predição	38
3.2	Análises Estatísticas	40
3.3	Regressão	41
4	RESULTADOS E DISCUSSÃO	42
5	CONCLUSÃO	51
6	TRABALHOS FUTUROS	52
	REFERÊNCIAS	53
	APENDICE A	57
	APENDICE B	59

1 INTRODUÇÃO

O efeito fotovoltaico foi observado pela primeira vez pelo físico francês Alexandre Edmond Becquerel em 1839, em um experimento com eletrodos metálicos de platina ou prata, mergulhados em uma solução ácida que gerava uma corrente elétrica quando exposto a radiação solar (BECQUEREL, 1839).

Com o advento da era espacial, a tecnologia assumiu uma nova importância. Em 1958 as células solares começaram a ser utilizadas como *backup* às pilhas químicas usadas nos satélites. A partir de então, a tecnologia se espalhou para uso residencial, comercial e industrial principalmente devido ao desenvolvimento dos semicondutores que impulsionou o crescimento da indústria fotovoltaica. Sua expansão no mercado mundial foi acelerada devido sua aplicação em sistemas aeroespaciais e militares e, posteriormente, para geração de eletricidade, tanto na forma distribuída como em grandes centrais geradoras (ZILLES et al., 2016). Além disso, a geração fotovoltaica, por ser uma fonte de energia elétrica relevante juntamente com outras matrizes renováveis, tem o importante papel de compensar o esgotamento das matrizes tradicionais fósseis (FAHRENBRUCH; BUBE, 2012).

Geração de energia fotovoltaica em larga escala aumenta a complexidade de operação dos sistemas elétricos, quando injetada na mesma rede que as demais fontes, pois torna necessário estimar e responder aos ciclos de flutuações inerentes a este recurso. Manter o suprimento de energia, sem restringir a geração de energia fotovoltaica, requer: 1 - o acionamento de usinas de apoio, unidades de armazenamento ou mesmo transferir eletricidade entre regiões, durante seus períodos improdutivos; 2 - controlar outras usinas, para que acompanhem a variação das usinas fotovoltaicas, por exemplo, reduzindo a geração nas hidroelétricas nos momentos de maior potencial fotovoltaico; 3 - e ampliar a capacidade geradora em épocas de alta disponibilidade. Entretanto, devido à inerente intermitência e variabilidade a luz do sol que chega à superfície, uma vasta estrutura de geração e controle de operação são necessários (OECD et al., 2016). Com crescimento da parcela de geração fotovoltaica na matriz de energia renovável, torna-se imperativo estimar com precisão a geração e consumo dessa fonte de eletricidade.

Muitas técnicas baseadas em inteligência artificial podem ajudar na previsão de geração da energia fotovoltaica (HEINEN; FERNANDES, 2018). Dentre elas, estão as técnicas de inteligência computacional, como as Redes Neurais Artificiais, que podem realizar tarefas de classificação de dados, previsão e aprendizagem supervisionada e não supervisionada do sistema (TZANAKOU, 2017).

Além das técnicas baseadas em inteligência artificial, existem modelos matemáticos que também executam tarefas de predição baseados na identificação de sistemas, como é o caso dos polinômios *NARX* (*NONLINEAR AUTOREGRESSIVE E EXOGENOUS MODEL*) (AGUIRRE, 2007). O modelo *NARX* pode utilizar uma função não linear, representada por uma rede neural, geralmente uma rede *MLP* (*MULTILAYER PERCEPTRON*), associada ao modelo matemático de regressores *NARX*, formando a rede neural *NARX* ou *RNA-NARX* (AGUIRRE, 2007).

Predições da geração de energia fotovoltaica reduzem as incertezas e auxiliam na operação dos geradores de energia. Assim, estimativas de geração com intervalos de dias à frente, por exemplo, permitem alocar usinas e reservas de energia para suprir a demanda do consumo, assim como, estimativas em horizontes de uma a seis horas alertam para flutuações da produção e permitem que se tome medidas para evitar a interrupção do suprimento.

1.1 Problema

Um dos desafios mais importantes para o fornecimento de energia no futuro próximo será a grande integração de fontes de energia renováveis, particularmente as de geração não previsíveis, como eólica e solar, na matriz de fornecimento de energia elétrica.

O Operador Nacional do Sistema Elétrico (ONS) é uma entidade brasileira de direito privado, sem fins lucrativos, responsável pela coordenação e controle da operação das instalações de geração e transmissão de energia elétrica do Sistema Interligado Nacional (SIN), sob a fiscalização e regulação da Agência Nacional de Energia Elétrica (ANEEL). O ONS foi criado em 26 de agosto de 1998, pela Lei nº 9.648 de 1998, pelo Decreto nº 5.081 de 14 de maio 2004 e alterada pela Lei nº 10.848 de 15 de maio de 2004. Tanto os órgãos quanto a legislação têm por função garantir precisão entre a produção, distribuição e consumo de eletricidade, a qualquer momento.

Portanto, manter o equilíbrio entre as diferentes fontes de geração de energia elétrica e seu consumo é uma das ações do ONS. A confiabilidade do sistema elétrico torna-se, então, dependente da capacidade do sistema em acomodar mudanças, esperadas e inesperadas, na produção e no consumo, mantendo a qualidade e a continuidade de serviços. A integração de energia renovável em uma rede elétrica intensifica a complexidade da gestão dessa rede e a continuidade do equilíbrio entre produção e consumo, devido à natureza intermitente e imprevisível (JAMAL et al., 2017).

A intermitência e as características não controláveis da produção de energia fotovoltaica causam problemas como flutuações de tensão, qualidade da energia local e confiabilidade do sistema (JAMAL et al., 2017). Assim, a capacidade de previsão da geração de energia fotovoltaica, de forma estável, é essencial para a operação efetiva e confiável da rede elétrica.

1.2 Motivação

A busca pela geração de energia por meio de sistemas fotovoltaicos apresentou um expressivo crescimento no Brasil. Essa crescente demanda teve início, provavelmente, em função das normativas publicadas pela ANEEL a partir do ano de 2012, que passaram a regulamentar a geração de mini e microgeradores. O uso de energias renováveis tem aumentado cada vez mais, devido ao fato de suas fontes serem inesgotáveis e os equipamentos mais acessíveis. Apesar desse recurso ser abundante, não é de fácil controle, pois varia significativamente em grande escala e em curto período de tempo, influenciado pelos fatores climáticos (principalmente temperatura e radiação solar). Portanto, a energia fotovoltaica é melhor utilizada por meio de estudos que busquem conhecer a disponibilidade regional, variabilidade temporal e previsibilidade (GUARNIERI, 2006a), uma vez que a energia gerada em parques solares não pode ser agendada e despachada, como ocorre no sentido clássico de geração (LAOUAFI; MORDJAOUI; DIB, 2015).

A predição da geração de energia fotovoltaica contribui para reduzir a incerteza acerca do fornecimento de energia fotovoltaica para a rede, melhorar a confiabilidade do sistema, manter a qualidade da energia e aumentar o nível de penetração dos sistemas fotovoltaicos (DAS et al., 2018).

A predição de geração de energia fotovoltaica é de extrema importância na tomada de decisões referentes ao controle e planejamento do sistema elétrico. Para isto, é indispensável o desenvolvimento de um sistema de predição antecipando a geração em minutos, horas e dias à frente, de forma a se evitar perturbações indesejáveis no sistema elétrico. Para o desenvolvimento de um método de predição que seja confiável, é indispensável o estudo das variáveis climáticas que influenciam nos fatores que afetam na geração desta energia (SILVA; BRITO, 2018).

São poucos os estudos voltados para a predição de geração de energia fotovoltaica no curtíssimo prazo. O monitoramento da geração de energia solar ao longo do dia é de grande importância para tomada de decisões no gerenciamento do complexo de geradoras de energia,

fazendo com que a energia fotovoltaica seja empregada de forma mais eficiente (GUARNIERI, 2006a).

São necessários métodos que empreguem dados de radiação solar e temperatura com suas previsões para que o sistema de geração fotovoltaica seja o mais confiável possível Moreno-Munoz et al. (2008). A escala da radiação solar pode variar muito de uma hora do dia para outra, não podendo ser considerada como uma fonte contínua. Por isso, são necessários métodos eficazes de projeção da geração no curto e curtíssimo prazo, a fim de melhor controlar e monitorar os sistemas de geração fotovoltaica.

Empresas que operam usinas fotovoltaicas utilizam uma variedade de tecnologias de satélites, imagens em nuvem e infravermelho para melhorar previsões em curto prazo e aumentar a receita (SAWIN et al., 2018) .

Pelo que foi exposto, faz-se necessário o estudo e avaliação de uma metodologia que possa ser aplicada na previsão da geração de energia de forma eficiente, para auxiliar nas ações do planejamento de expansão, comercialização e operação, neste ambiente muito incerto e complexo da geração de energia fotovoltaica. Assim, este trabalho propõe um modelo de previsão de curtíssimo prazo (uma hora à frente) da geração de energia fotovoltaica.

Este modelo de previsão uma hora à frente da geração de energia fotovoltaica possibilita com maior exatidão o perfil instantâneo da geração, auxiliando ajustes na programação diária da operação do Operador Nacional do Sistema Elétrico (ONS).

1.3 Objetivos

Como objetivo geral, o presente trabalho visa avaliar o uso da rede neural *NARX* como ferramenta de previsão de geração de energia elétrica de sistemas fotovoltaicos para uma hora à frente (curto prazo).

Como objetivos específicos, este trabalho almeja:

- a) Organizar um banco de dados com variáveis de radiação solar, temperatura e geração de energia fotovoltaica;
- b) Implementar várias configurações de rede *NARX* para previsão e testar com dados de radiação solar, temperatura e geração de energia fotovoltaica;
- c) Comparar o desempenho da rede *NARX* para diferentes números de atrasos de entrada e de neurônios, na tarefa de previsão da energia produzida;

d) Determinar a configuração da rede *NARX* que melhor representa um modelo de previsão de geração de energia elétrica por sistemas fotovoltaicos.

1.4 Organização do trabalho

Este trabalho está organizado da seguinte forma: No Capítulo 1 é descrito o problema e a motivação para resolvê-lo. No Capítulo 2 é apresentado o referencial teórico necessário para a compreensão e desenvolvimento do trabalho. No Capítulo 3 são apresentados os materiais e a metodologia utilizada para o desenvolvimento do sistema de previsão. No Capítulo 4 são apresentados os resultados alcançados e discussão. E finalmente no Capítulo 5 são apresentadas as principais conclusões obtidas e sugestões para trabalhos futuros. A seguir são apresentadas as referências bibliográficas e os apêndices (A e B), contendo o script desenvolvido e a tabela com os resultados dos erros médios quadráticos.

2 REFERENCIAL TEÓRICO

Fatores como irradiância, temperatura, ângulo de incidência da radiação solar e sombreamento interferem na predição de geração de energia fotovoltaica e devem fazer parte de modelos de predição com o uso de inteligência computacional. Assim, neste capítulo são apresentadas estas características e conceitos para compreensão e desenvolvimento do trabalho, além das redes neurais artificiais *MLP* e *NARX*.

2.1 Fatores que influenciam na geração de energia fotovoltaica

Cada fator influenciará, de um modo particular, a geração de energia fotovoltaica. As características elétricas descritas nos painéis fotovoltaicos estabelecem valores de referência de temperatura e irradiância, visto que os valores de tensão e corrente irão variar, consoante ao valor da temperatura e da irradiância em cada instante. É, portanto, necessário o estudo desta dependência para que se consiga determinar o quanto o painel irá produzir a cada instante, com os valores previstos de irradiância e temperatura, fornecidos por estações ou serviços de meteorologia. Além das variáveis meteorológicas, o ângulo de incidência da radiação (BOYLE, 2004), o sombreamento (BUITENHUIS; PEARCE, 2012), a existência de nuvens (GREEN et al., 2017) e o desempenho técnico dos equipamentos influenciam na geração de energia fotovoltaica, ocasionando interferência nos valores de produção. Agoua, Girard e Kariniotakis (2017) em seu estudo demonstraram as variáveis que mais influenciam na geração de energia elétrica, sendo elas irradiância e temperatura.

2.1.1 Irradiância

A geração de energia fotovoltaica ocorre por meio da radiação solar incidente nas células do painel que é transformada em energia elétrica (CARDADOR, 2011). Assim, torna-se necessário medir a potência incidente nos painéis, em razão da área de incidência, dada pela Equação 2.1.


$$G = \frac{P_{incidente}}{A_{célula}} \quad (2.1)$$

em que G representa a irradiância (J/m^2), $P_{incidente}$ a potência incidente no painel (J) e $A_{célula}$ a área da célula do painel fotovoltaico (m^2).

A Figura 2.1 representa a corrente de curto circuito (I_{sc}) na célula fotovoltaica, corrente esta que a célula solar fornece quando ambos os seus terminais se encontram ligados entre si, enquanto que a tensão corresponde ao circuito aberto (V_{oc}), tensão que a célula solar fornece quando ambos os terminais não estão ligados a uma carga (GREENPRO, 2004). Assim, a corrente varia com a irradiância. Segundo Castaner e Silvestre (2002), a relação entre a corrente I_{sc} (A) e a irradiância G (J/m^2) é dada pela Equação 2.2.

$$I_{sc} = \frac{G.I_{sc}(STC)}{G(STC)} \quad (2.2)$$

Figura 2.1 – Variação dos níveis de corrente e tensão com diferentes valores de irradiância com temperatura fixa em um painel fotovoltaico.



Fonte: CanadianSolar (2017).

Para o cálculo da tensão em função da irradiância é necessário o valor de V_t , que representa a tensão térmica, dada pela Equação 2.3.

$$V_t = k.T/q \quad (2.3)$$

em que V_t representa tensão térmica, k é a constante de *Boltzmann* (J/K), que relaciona a temperatura e a energia das moléculas, T a temperatura da célula (em K) e q a carga dos elétrons em Coulomb (C).

A uma temperatura de $25^\circ C$, ou seja 298K, e a uma irradiância de $1000 W/m^2$, esta tensão é de 25,7 mV, seguindo as condições STC (*Standard Test Conditions*) em um painel fotovoltaico. A tensão em função da irradiância é obtida pela Equação 2.4.

$$V_{oc} = V_{oc}(STC) + V_t \cdot \ln\left(\frac{G}{G(STC)}\right) \quad (2.4)$$

em que V_{oc} representa a tensão de circuito aberto, V_t a tensão térmica e G a irradiância em condições padrão de teste (STC), e a tensão varia logarithmicamente com a irradiância. A variação da tensão, como se pode verificar na Figura 2.1 é pequena, chegando a ser considerada praticamente inexistente (GREENPRO, 2004). O valor da potência produzida pelo painel (W) e o seu rendimento (%) são obtidos, respectivamente, por meio das Equações 2.5 e 2.6.

$$P(STC) = V_m \cdot I_m \quad (2.5)$$

$$\eta = \frac{P(STC)}{G(STC) \cdot A_{panel}} \quad (2.6)$$

em que $P(STC)$ representa a potência produzida pelo painel (W) em condições de teste padrão, V_m e I_m a tensão e corrente máximas do painel, respectivamente, η o rendimento e área do painel A_{panel} (m^2), os demais fatores são definidos nas equações anteriores (CARNEIRO, 2010).

A radiação solar, ao atravessar a atmosfera terrestre é atenuada pela reflexão e pela absorção ou dispersa por parte de gases, tais como: o dióxido de carbono, vapor de água, oxigênio, ozônio. A dispersão pode ser dividida em dispersão de *Rayleigh*, quando relativa à dispersão provocada pela existência de moléculas e em dispersão de *Mie*, quando relativa à dispersão por partículas de pó e pela poluição do ar.

O fenômeno de reflexão por parte das nuvens, apesar de ser um problema transitório, é o mais impactante. A intensidade da reflexão depende, fundamentalmente, da espessura e da estrutura das nuvens, podendo atingir valores na ordem dos 90%. Já o componente de absorção pelas nuvens é relativamente menos impactante, atingindo no máximo 7% (LIMA; FERNANDEZ, 2011). O fato das nuvens refletirem significativa parte da radiação reduz o rendimento da geração fotovoltaica cerca de 20% em dias parcialmente nublados, e de 75% em dias de céu encoberto pelas nuvens (SURI et al., 2014). Essa taxa de redução é em comparação ao potencial máximo de geração.

Ainda segundo Suri et al. (2014), a existência de nuvens pode causar “saltos” (períodos em que não há produção) ou até mesmo rampas, que representam subidas ou descidas muito

acentuadas na geração, em razão da simples passagem de nuvens. Tais fenômenos, se não forem mitigados, podem causar surtos, geração anormal e flutuações, que representam sérios problemas de operação para o ONS.

Pesquisas científicas buscam soluções para suavizar os impactos do efeito das nuvens na geração fotovoltaica. Suri et al. (2014) concluem que o armazenamento da energia gerada pelo sol é uma maneira de suavizar as flutuações devido a passagem de nuvens, sendo esta momentânea ou durante dias, por meio da energia armazenada em baterias, como forma de mitigar a perda nos dias nublados.

2.1.2 Temperatura

Os valores de corrente de curto circuito (I_{sc}) e tensão de circuito aberto (V_{oc}) são fornecidos nas características elétricas dos painéis fotovoltaicos, como mostrado na Figura 2.2. Estes valores são apenas válidos para a temperatura nominal de funcionamento da célula, principalmente em condições especiais de temperatura ambiente e irradiância, em um dia típico de verão (temperatura ambiente de $T_a = 25^\circ\text{C}$ e irradiância $G = 1000\text{W}/\text{m}^2$). A correção da temperatura da célula (CARNEIRO, 2010) se realiza de acordo com a Equação 2.7.

$$T_c = T_a + G \cdot \frac{TNOC - 20}{800} \quad (2.7)$$

em que T_c é a temperatura da célula e T_a a temperatura ambiente, TNOC representa a temperatura nominal da célula, e G representa a irradiação.

Depois de corrigida a temperatura da célula é necessário recalcular o valor de I_{sc} e de V_{oc} de acordo com esta nova temperatura, dada pela Equação 2.8.

$$V_{oc} = V_{oc}(25^\circ\text{C}) + \beta_T(T_C - 25^\circ\text{C}) \quad (2.8)$$

em que β_T corresponde ao coeficiente de correção de temperatura da tensão. Procede-se da mesma forma para o valor de corrente pela Equação 2.9.

$$I_{sc} = I_{sc}(25^\circ\text{C}) + I_{sc}(25^\circ\text{C})(\alpha_T(T_C - 25^\circ\text{C})) \quad (2.9)$$

em que, α_T corresponde o coeficiente de correção da temperatura na corrente.

Analisando as equações 2.8 e 2.9, conclui-se que um aumento da temperatura resultará numa diminuição do valor da tensão e num aumento do valor da corrente. Existe, de fato,

uma variação mais acentuada no valor da tensão em circuito aberto do que na corrente de curto circuito, que sofre apenas um pequeno aumento. Teixeira (2008) afirma que este aumento se deve ao fato de que, quando a temperatura do silício (material empregado como semicondutor presente na célula) aumenta, há redução do valor da banda de energia do material, facilitando a geração de pares de “elétrons-lacuna” por fótons. Os valores da potência de saída, em função da temperatura (BUITENHUIS; PEARCE, 2012), assim como o rendimento do painel, são dados, respectivamente, pelas Equações 2.10 e 2.11.


$$P = P_{ref}[1 + (\alpha_T - \beta_T)\Delta T] \quad (2.10)$$

$$\eta(T) = \eta(T_{ref})[1 + (\alpha_T - \beta_T)\Delta T] \quad (2.11)$$

em que, P_{ref} é o valor da potência de saída para a temperatura de referência $T_{ref}(25^\circ\text{C})$ e T_a a temperatura (ambiente) em que se quer calcular o rendimento.

Visto que o valor da potência produzida pelo painel depende de I_{sc} e de V_{oc} , como consequência a potência altera o seu valor com a variação da temperatura, como mostra na Equação 2.10 e Figura 2.2.

Figura 2.2 – Variação dos níveis de corrente e tensão para diferentes valores de temperatura em um painel fotovoltaico.



Fonte: CanadianSolar (2017).


2.1.3 Ângulo de incidência da radiação solar

O ângulo de incidência da radiação solar na superfície da placa fotovoltaica depende da posição do sol no céu e da posição da placa. A posição solar varia ao longo do dia e do ano, sendo determinada pelos ângulos azimutal, zenital e pela altura solar (VILLALVA, 1983). A radiação solar incide sobre a superfície do módulo com o ângulo de inclinação β , definido em relação à reta perpendicular à superfície do módulo. Em cada dia do ano, conforme a altura solar, o ângulo da altura (γ_s) varia, e o módulo recebe a radiação solar com uma inclinação β diferente. O melhor aproveitamento da energia solar ocorre quando a radiação solar incide perpendicularmente ao módulo, com ângulo $\beta = 0$. Isso significa que, idealmente, para maximizar a captação da energia solar, a inclinação do módulo deve ser ajustada diariamente para adequar-se ao ângulo solar (γ_s).

A Figura 2.3 mostra como incidem os raios solares em um módulo fotovoltaico. O mesmo é instalado com ângulo de inclinação α em relação ao solo e tem sua face voltada para o norte geográfico, seguindo os ângulos:

- α - ângulo de inclinação do painel;
- β - ângulo de incidência do raio solar;
- γ_s - ângulo da altura solar.

Figura 2.3 – Ângulos de inclinação do módulo e de incidência da radiação solar.



Fonte: adaptado de (VILLALVA; GAZOLI, 2012).

2.1.4 Sombreamento

O módulo fotovoltaico sujeito a uma sombra pode deixar de gerar energia, mesmo se apenas uma de suas células estiver recebendo menos luz do que as demais, pois a intensidade da corrente elétrica gerada é diretamente proporcional à intensidade da radiação que incide na célula. Por estarem conectados em série, as células de um módulo fotovoltaico dependem umas das outras para produzir corrente elétrica.

O principal problema decorrente do sombreamento é quando um módulo fotovoltaico é parcialmente sombreado. Neste caso, algumas de suas células podem trabalhar em função reversa, ou seja, funcionar como carga ao invés de funcionar como geradoras de energia. Quando a função reversa supera a tensão de ruptura da célula solar sombreada, a célula toda será prejudicada (GAROUDJA et al., 2017). BALFOUR, SHAW e NASH (2016) relatam que o sombreamento pode provocar perdas de 75% a 100 % do rendimento na geração de energia fotovoltaica.

O impacto do sombreamento pode ser minimizado na fase de elaboração do projeto fotovoltaico e da escolha da forma como serão ligadas as *strings*. Assim, é necessário um estudo prévio para a definição do local de instalação dos módulos fotovoltaicos.

2.2 Predição de geração de energia fotovoltaica

A predição da geração de energia fotovoltaica é de grande importância para o planejamento do sistema elétrico, pois permite que várias ações de gestão da energia sejam realizadas. Nesta seção são apresentados alguns trabalhos recentes que abordam a questão de previsão da radiação solar ou a previsão da produção de energia solar no curto e curtíssimo prazo.

A escala da radiação solar pode variar consideravelmente de uma hora para outra do dia, não podendo ser considerada como algo contínuo. Portanto, a energia fotovoltaica a ser produzida apresenta uma característica aleatória devido aos fatores variáveis como o ambiente e o clima. A radiação solar é a principal variável que afeta a energia gerada.

A produção da energia fotovoltaica é proporcional à incidência de radiação solar nos painéis, que pode variar durante o dia, devido ao movimento, formação e dissipação das nuvens, e também depende da posição geográfica dos painéis (PIRES et al., 2016). Lopes et al. (2010) afirmam que apesar de existirem várias metodologias para previsão da radiação solar, não há uma definição padrão exata em relação aos horizontes temporais para cada tipo de previsão.

Porém, os autores consideram, a classificação para a predição da radiação solar em quatro horizontes de tempo, sendo eles:

Predição de curtíssimo prazo: como sendo a predição que possui um horizonte que pode variar de alguns segundos até uma hora. São predições feitas com o auxílio de dados recolhidos no local a ser analisado.

Predição de curto prazo: como sendo o horizonte de predição que compreende o período entre 1 hora e 7 dias.

Predição de médio prazo: que possui um horizonte de tempo entre 7 dias, podendo chegar a vários anos. Este horizonte de predição é basicamente utilizado para simulação do recurso energético.

Predição de longo prazo: esse tipo de predição abrange um horizonte para dezenas de anos à frente, e é usualmente aplicado em estudos sobre alterações climáticas.

Moreno-Munoz et al. (2008) afirmam que as variações de irradiação solar afetam de forma significativa a produção da energia elétrica em sistemas de energia solar. Assim, é indispensável a realização da predição da radiação para o curto prazo, a fim de controlar e monitorar sistemas de geração fotovoltaica, já que a radiação solar pode variar muito de uma hora para outra durante o dia em determinados períodos do ano.

Guarnieri (2006b) afirma que estudos de aperfeiçoamento de métodos de predição da radiação solar podem possibilitar melhor aproveitamento da energia elétrica fotovoltaica para projetos de exploração e comercialização, para otimizar processos de despacho da carga elétrica nas linhas de transmissão. Neste sentido, as Redes Neurais Artificiais são capazes de simular melhor as não-linearidades e reconhecer padrões específicos da geração de energia.

2.2.1 Predição de geração com Inteligência computacional - IC

Há diversas ferramentas de IC empregadas para predição. Trabalhos sobre predições solar e eólica utilizando modelos matemáticos *NARX*, para prever a saída futura do sistema podem ser encontrados em (PIAZZA; PIAZZA; VITALE, 2016). Predição da irradiância solar global para curtos intervalos de tempo, baseado em processos de Markov, e predição de geração fotovoltaica para curto espaço de tempo, usando *Support Vector Machines*, podem ser encontrados em (LOSCHI et al., 2017).

Trabalhos como o de Olatomiwa et al. (2015) utilizaram um sistema de inferência neuro-fuzzy adaptável (ANFIS) para prever a radiação solar com base em uma série de dados meteorol-


lógicos medidos, como temperaturas mínima, média, máxima mensal e duração do sol obtidas de uma estação meteorológica localizada em Iseyin, na Nigéria. Autores como Abedinia, Amjady e Ghadimi (2018) usaram uma rede híbrida *RNA* e algoritmos genéticos para predição de energia solar.

2.3 Rede Neural Artificial (*RNA*)

A rede neural artificial (*RNA*) é um dos principais ramos da inteligência artificial. É um modelo adequado, especificamente para tarefas que envolvam conjuntos de dados incompletos, informação distorcida e para situações bastante complexas e mal definidas, em que normalmente os seres humanos decidem intuitivamente. As *RNAs* podem “aprender” a partir de exemplos e são capazes de lidar com problemas não lineares. Esses modelos apresentam, entretanto, algum vigor e alguma tolerância a falhas (BILGILI; SAHIN; YASAR, 2007). Com isso, podem ser aplicadas em inúmeras situações, como o caso de predições meteorológicas (ABHISHEK et al., 2012).

As *RNAs* baseiam o seu principio de funcionamento na analogia com o cérebro humano, sendo este composto por 100 bilhões de neurônios interligados (KUBAT, 1999). A Figura 2.4 ilustra um modelo simplificado de um neurônio biológico. No cérebro existe um fluxo de informações codificadas (usando meios eletroquímicos, os chamados neurotransmissores) das sinapses no sentido do axônio. O axônio de cada neurônio transmite informação para um certo número de outros neurônios, que recebem informações nas sinapses de um grande número de outros neurônios. Estima-se que cada neurônio pode receber até 10.000 estímulos de outros neurônios. Grupos de neurônios são organizados em subsistemas. A integração desses subsistemas forma o cérebro.

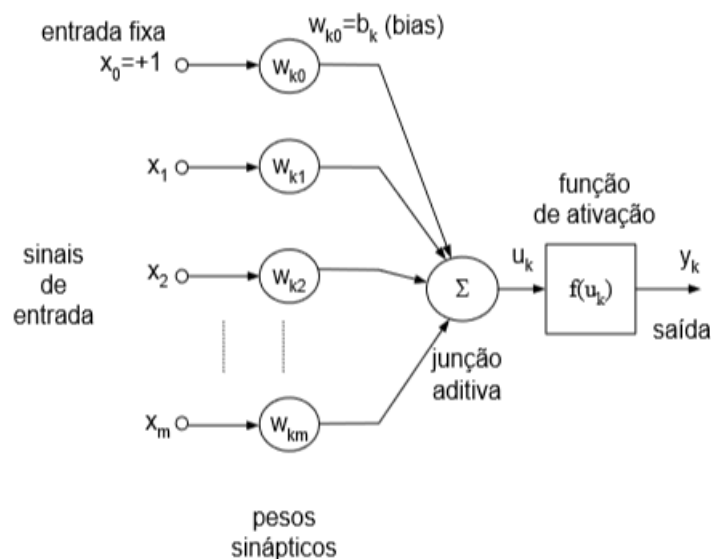
Figura 2.4 – Um modelo simplificado de um neurônio biológico.



Fonte: adaptado de (HAYKIN, 2001).

A Figura 2.5 representa um modelo altamente simplificado de um neurônio artificial, que pode ser utilizado para ilustrar alguns aspectos importantes do neurônio biológico real. Uma *RNA* é um grupo de neurônios artificiais interligados, interagindo uns com os outros de uma forma ordenada. Neste sistema, a excitação é aplicada à entrada da rede. A realização de uma operação adequada resulta numa saída desejada. Nas sinapses, existe uma acumulação de algum potencial, o que no caso dos neurônios artificiais é modelada como uma ligação ponderada. Os pesos associados às ligações são continuamente modificados com base em regras de aprendizagem adequadas (KALOGIROU, 2001).

Figura 2.5 – Modelo de um neurônio artificial.



Fonte: adaptado de (HAYKIN, 2001).

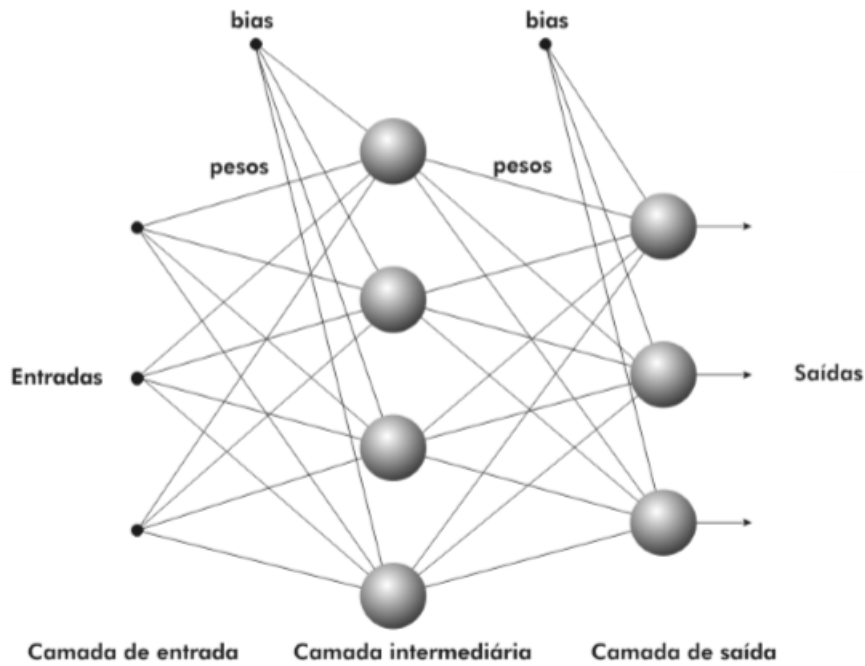
A expressão matemática dos neurônios artificiais, pode ser expressa por meio da Equação 2.12.

$$y_k = f(\mu_k) = f\left(\sum_{j=1}^m w_{kj}x_j + b_k\right) \quad (2.12)$$

em que, y_k representa a saída da RNA; X_1, X_2, \dots, X_j são os sinais de entrada; $W_{k1}, W_{k2}, \dots, W_{kj}$ são os pesos sinápticos do neurônio; b_k é o bias; e Y_k é a saída (resultado).

As RNAs são compostas por uma ou mais entradas, uma saída e uma ou mais camadas ocultas (Figura 2.6). Cada neurônio é ligado a partir da camada de entrada para um neurônio a partir da camada oculta. Na camada oculta, cada nó é ligado a um neurônio da camada de saída.

Figura 2.6 – Rede Neural Simples.



Fonte: adaptado de (HAYKIN, 2001).

Uma camada de entrada representa a informação que é alimentada para dentro da rede. Cada valor único de entrada para a rede é duplicado e enviado para baixo, para os nós na camada oculta. A RNA usa o valor de entrada, modifica esse valor, e o envia para a camada de saída, mas esse valor também será modificado por algum peso de ligação entre a camada oculta e de saída. Esta saída é processada pela função de ativação (CILIMKOVIC, 2015).


2.3.1 Função de ativação

A função de ativação é responsável por definir a ativação de saída do neurônio em termos do seu nível de ativação interna. Normalmente o sinal de ativação do neurônio pertence ao intervalo $(0, 1)$ ou $(-1, 1)$.

- Função Degrau

A função degrau é uma das funções mais utilizadas no neurônio artificial do tipo *Perceptron*, e determinada como apresentado na Figura 2.7.

Figura 2.7 – Função Degrau.



Fonte: adaptado de (HAYKIN, 2001).

- Função Sigmoidal

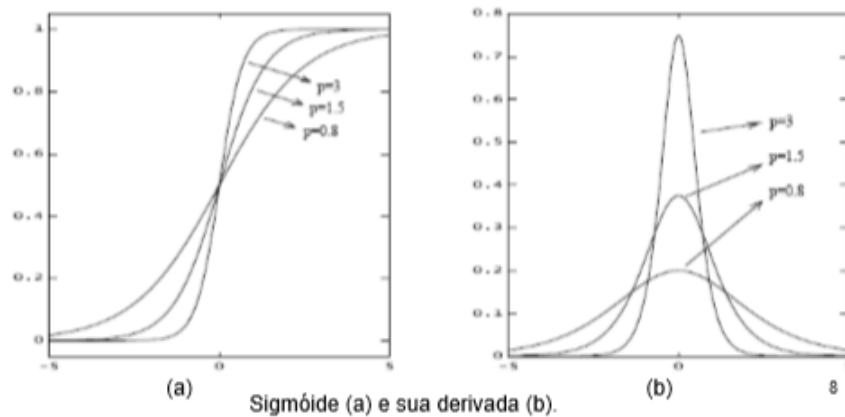
A função sigmoideal é uma das funções de ativação não-linear mais utilizadas em redes do tipo *Perceptron* Multicamadas. Ela é definida como uma função crescente que apresenta propriedades assintóticas e de suavidade. Um exemplo de função sigmoideal é a chamada função logística (Figura 2.8), definida por meio das Equações 2.13 e 2.14.

$$f(u_k) = \frac{e^{pu_k}}{e^{pu_k} + 1} = \frac{1}{1 + e^{-pu_k}} \quad (2.13)$$

$$\frac{\partial f}{\partial u_k} = pu_k(1 - u_k) > 0 \quad (2.14)$$

em que: u é a soma ponderada das entradas mais o limiar de ativação (bias).

Figura 2.8 – Função Sigmoidal.



Fonte: adaptado de (HAYKIN, 2001).


- Função Semi-linear.

A função de ativação semi-linear é representada na Figura 2.9.

Figura 2.9 – Função Semi-linear

$$f(u_k) = \begin{cases} 1 & \text{se } pu_k \geq 1 \\ pu_k & \text{se } 0 < pu_k < 1 \\ 0 & \text{se } pu_k \leq 0 \end{cases}$$

p constante e positivo



Função de ativação semi-linear (a) e sua derivada (b).

Fonte: adaptado de Haykin (2001).

- *PERCEPTRON*

O *Perceptron* é um modelo de neurônio artificial que utiliza um algoritmo de aprendizado de classificadores binários. Ele é capaz de resolver apenas problemas linearmente separáveis por meio do processo de treinamento, ou seja, o algoritmo aprende a classificar as entradas em dois grupos diferentes separados por uma reta (considerando dados de

duas dimensões). O *Perceptron* só é capaz de solucionar problemas que são linearmente separáveis.

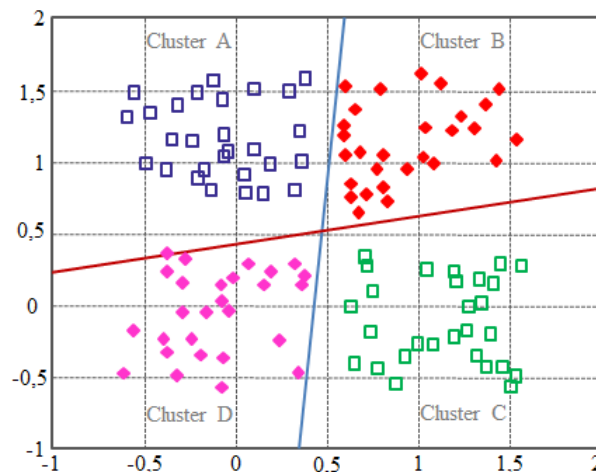
Figura 2.10 – Processo de treinamento *Perceptron*.



Fonte: adaptado de (HAYKIN, 2001).

O *Perceptron* Multicamadas (*MLP*) é uma rede neural semelhante ao *Perceptron* simples, porém possui mais de uma camada de neurônios. Em casos em que não há a possibilidade de uma única reta separar os elementos, há o uso da *MLP* que, gera mais de uma reta classificadora. Na Figura 2.11 é representado o treinamento de um *Perceptron* Multicamadas. O aprendizado nesse tipo de rede é geralmente feito através do algoritmo de retropropagação do erro (ou de algoritmos derivados como o *Levenberg-Marquardt (LM)*, (LEVENBERG, 1944) mas existem outros algoritmos para este fim.

Figura 2.11 – Treinamento *Perceptron* Multicamadas.



Fonte: adaptado de (HAYKIN, 2001).

2.3.2 Método *backpropagation* ou retropropagação

O método *backpropagation* é um algoritmo de treinamento supervisionado, funciona com a apresentação de um padrão à camada de entrada da rede, onde ele é processado camada por camada até que a saída forneça uma resposta. A resposta obtida no processamento é comparada com a resposta desejada e, em seguida, o erro médio quadrático (EMQ) é calculado.

O algoritmo *backpropagation* começa com os pesos aleatórios. O objetivo é ajustá-los para reduzir o erro médio quadrático até que a rede neural aprenda os dados de treinamento, possibilitando o critério de parada da rede. A retropropagação padrão é um algoritmo de gradiente descendente, no qual os pesos da rede são movidos ao longo do negativo do gradiente da função de desempenho. A combinação de pesos que minimiza a função de erro é considerada uma solução para o problema de aprendizagem. Para tanto, o algoritmo de retropropagação utiliza a função de ativação tan-sigmóide ou log-sigmóide.

Redes *feed-forward* geralmente têm uma ou mais camadas ocultas de neurônios sigmóides, seguidas por uma camada de saída de neurônios lineares. Essa estrutura permite que a rede aprenda relações não-lineares e lineares entre vetores de entrada e saída.

Para o processo de aprendizado, os dados são divididos em dois conjuntos: o conjunto de dados de treinamento, usado para calcular os gradientes de erro e atualizar os pesos, e o conjunto de dados de validação, que permite selecionar o número ideal de iterações para evitar o sobreparametrização da rede. À medida que o número de iterações aumenta, o erro de treinamento diminui, enquanto o erro do conjunto de dados de validação começa a diminuir e atinge o mínimo, quando o erro começa a subir. Tal ponto de inflexão, indica, possivelmente, um início de sobreparametrização da rede, sendo importante a finalização da etapa de ajuste de seus parâmetros. Depois que o processo de aprendizado é concluído, outro conjunto de dados, conjunto de testes, é usado para validar e confirmar a precisão da predição.

Haykin (2007) afirma graficamente que é possível observar outro critério de parada para uma rede neural, por exemplo, utilizando a estagnação do erro médio quadrático durante o treino da rede.

2.3.3 Modelo *NARX* polinomial

O modelo *NARX* (*Non-linear Auto Regressive With Xogenous Inputs*) tem características determinísticas nos quais a saída do sistema, representada por y , é obtida por meio dos atrasos no sinal de entrada e no de saída, formando um conjunto de dados chamados de séries

temporais. O uso de valores em diferentes instantes de tempo fazem do modelo *NARX* um modelo discreto em relação ao tempo (AGUIRRE; CORREA; CASSINI, 2002). A Equação 2.15 descreve matematicamente o modelo *NARX* polinomial.

$$y(k) = f^l[y(k-1), \dots, y(k-n_y), u(k-d), \dots, u(k-d-n_u)] + e(k). \quad (2.15)$$

em que, $u(k)$, $y(k)$, $e(k)$ representam a entrada, a saída e o ruído, respectivamente; n_u , n_y e n_e indicam os n -ésimos atrasos de u , y e e ; o tempo morto do modelo é representado pela variável d ; e f representa a função não linear, que geralmente está ligada a técnica de seleção de regressores nos sinais de entrada e saída do modelo *NARX*. Por fim, l representa o grau de não-linearidade da função f .

2.3.4 Estimação de Parâmetros

Para a estimação dos parâmetros em um modelo *NARX* polinomial, é comum na literatura a recomendação do estimador de mínimos quadrados. Nesse método, o vetor de parâmetros Θ é calculado minimizando a soma do quadrado dos erros de predição. Considerando X a matriz de regressores e X^T sua transposta, o modelo matemático do estimador dos mínimos quadrados corresponde ao inverso do produto de X^T por X , multiplicados por X^T e pelo vetor dos dados do problema y , conforme a Equação 2.16 (AGUIRRE, 2007).

$$\Theta_{MQ} = [X^T X]^{-1} X^T y. \quad (2.16)$$

Para simplificar a nomenclatura das variáveis da equação, os termos $[X^T X]^{-1} X^T$ formam a matriz pseudo-inversa de X .

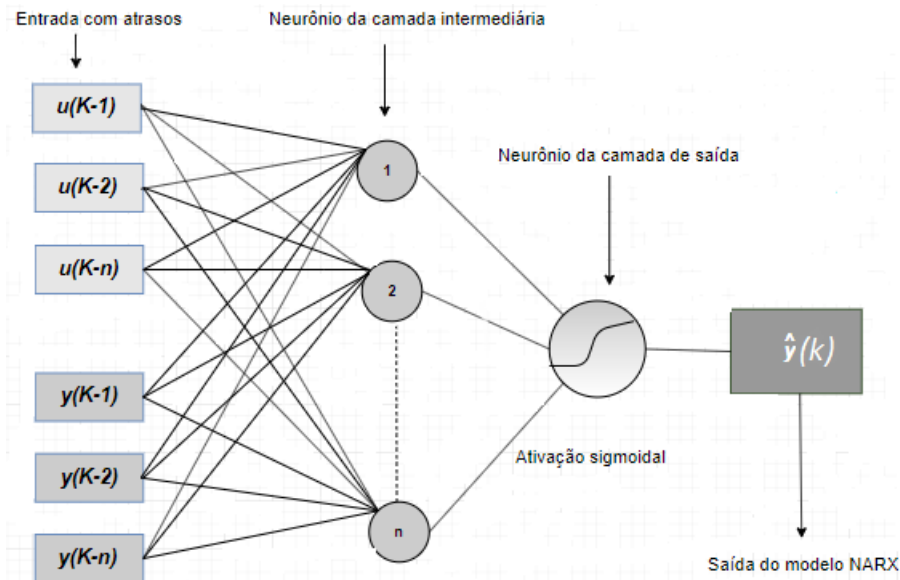
2.3.5 Rede RNA-NARX

A rede *RNA-NARX* é capaz de lidar com problemas não lineares, o que as favorece na seleção de parâmetros que é feito pela função estática da própria rede neural *MLP*, possuindo maior capacidade de não linearidade se comparadas aos modelos *NARX* polinomiais (AGUIRRE, 2007). A representação da rede *RNA-NARX* é descrita na Equação 2.17.

$$y(k) = f[u(k-1), \dots, u(k-n_u), y(k-1), \dots, y(k-n_y)], \quad (2.17)$$

em que $u(k - n_u)$ corresponde a entrada; e $y(k - n_y)$ indicam os estados passados do sinal de saída y , sendo n_u e n_y os maiores atrasos respectivo representado na Figura 2.12.

Figura 2.12 – Estrutura de uma *NARX-RNA*.



Fonte: Do autor (2020).

2.3.6 Métricas de Desempenho

O desempenho de uma máquina de aprendizado (como a *RNA*) é avaliado por meio de indicadores. A métrica de erro mais comumente avaliada pela literatura (ATSALAKIS; VALAVANIS, 2009) é o erro médio quadrático (EMQ) e o coeficiente de correlação (R ou r) (HAYKIN, 2007). O EMQ de uma rede neural artificial é expresso pela Equação 2.18.

$$EMQ = \frac{1}{N} \sum_{i=1}^N (y(i) - \hat{y}(i))^2 \quad (2.18)$$

em que o erro quadrático representa a subtração entre o valor de saída y real e o valor predito \hat{y} , sendo N igual ao número de amostras.

Um método para encontrar o melhor ajuste é calcular o coeficiente de determinação R^2 , é uma medida de quão bem um modelo pode prever os dados e fica entre zero e um. Quanto mais alto o valor de R^2 , melhor é o modelo em prever os dados, demonstrado pela Equação 2.19.

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (2.19)$$

em que os valores de y_i e \hat{y}_i representam respectivamente os valores reais e os valores previstos, enquanto \bar{y} a média dos valores reais (DROSSU; OBRADOVIC, 1996).

3 MATERIAIS E MÉTODOS

Para a realização deste trabalho foram utilizados dados de energia produzida coletados do inversor da marca Fronius¹, de uma microestação fotovoltaica particular em Varginha – MG (banco 1). Além disso, foram utilizados séries históricas de temperatura e radiação solar da estação meteorológica da região, com observação de superfície, disponíveis publicamente pelo Instituto Nacional de Meteorologia (INMET) (Tabela 3.1). Os dados de energia, radiação e temperatura estão representados nas Figuras 3.1 e 3.2, para um período de observação entre 08/04/2019 e 20/04/2020.

Figura 3.1 – Dados de Energia Elétrica Fotovoltaica, Temperatura e Radiação.

Horário UTC	Data	Horario arredondado	Fonte: Base Geração de Energia		Fonte: Base UTC		Temp e Radiação		Temp		Radiacao		Temperatura		Produção		Radiacao	
			Soma de Produção Refinado (Madrugada sem prod)	Temp Inst	Temp Máx	Tempo Min	Radiação (kJ/m²)	Temp Média	Radiacao Normalizada	Temperatura Normalizada	Produção Normalizada	Radiacao Normalizada						
14	08/04/19	11	1312,63	21,4	21,7	20,5	991,8	21,2	0,09918	0,00217	0,131263	0,1057						
15	08/04/19	12	4603,55	22,3	22,3	21,4	1057	22	0,1057	0,00223	0,460355	0,169						
16	08/04/19	13	4658,57	23,1	23,1	22,3	1690	22,83333	0,169	0,00231	0,465857	0,1581						
17	08/04/19	14	5929,54	23,4	23,9	23	1581	23,43333	0,1581	0,00239	0,592954	0,1008						
18	08/04/19	15	3100,82	23	23,6	23	1008	23,2	0,1008	0,00236	0,310082	0,05171						
19	08/04/19	16	710,76	22,3	23,1	22,3	517,1	22,56667	0,05171	0,00231	0,071076	0,0253						
20	08/04/19	17	244,62	21,4	22,4	21,4	253	21,73333	0,0253	0,00224	0,024462	0,004866						
21	08/04/19	18	0	20,2	21,4	20,1	48,66	20,56667	0,004866	0,00214	0	0						
22	08/04/19	19	0	19,7	20,2	19,4	-3,54	19,76667	-0,000354	0,00202	0	0						
23	08/04/19	20	0	19,7	19,7	19,5	-3,16	19,63333	-0,000316	0,00197	0	0						
24	08/04/19	21	0	21,6	22,1	21,5	-3,42	21,73333	-0,000342	0,00221	0	0						
25	08/04/19	22	0	21,5	21,7	21,4	-3,44	21,53333	-0,000344	0,00217	0	0						
26	08/04/19	23	0	21,4	21,7	21,1	-3,54	21,4	-0,000354	0,00217	0	0						
4	09/04/19	1	0	18,8	18,9	18,7	-1,63	18,8	-0,000163	0,00189	0	0						
5	09/04/19	2	0	18,7	18,8	18,7	-1,52	18,73333	-0,000152	0,00188	0	0						
6	09/04/19	3	0	18,7	18,8	18,5	-1,68	18,66667	-0,000168	0,00188	0	0						
7	09/04/19	4	0	18,6	18,7	18,5	-1,91	18,6	-0,000191	0,00187	0	0						
8	09/04/19	5	0	18,7	18,8	18,6	-0,47	18,7	-0,000047	0,00188	0	0						
9	09/04/19	6	96,52	18,7	18,8	18,6	-1,02	18,7	-0,000102	0,00188	0,009652	0,007643						
3	19/04/20	0	0	17,5	17,5	17,2	-3,1	17,4	-0,00031	0,00175	0	0						
4	20/04/20	1	0	15,7	16,7	15,7	-3,54	16,03333	-0,000354	0,00167	0	0						
5	20/04/20	2	0	15,9	16	15,5	-3,54	15,8	-0,000354	0,0016	0	0						
6	20/04/20	3	0	15,9	16,3	15,7	-3,07	15,96667	-0,000307	0,00163	0	0						
7	20/04/20	4	0	14,8	15,9	14,4	-3,54	15,03333	-0,000354	0,00159	0	0						
8	20/04/20	5	0	14,5	15,3	14,5	-3,31	14,76667	-0,000331	0,00153	0	0						
9	20/04/20	6	119,78	14,4	14,5	14,4	-2,19	14,43333	-0,000219	0,00145	0,011978	0,01815						
10	20/04/20	7	1441,78	15,7	15,9	14,4	181,5	15,33333	0,01815	0,00159	0,144178	0,07888						
11	20/04/20	8	2901,16	16,8	16,8	15,7	788,8	16,43333	0,07888	0,00168	0,290116	0,1882						
12	20/04/20	9	5268,21	20,2	20,2	16,8	1882	19,06667	0,1882	0,00202	0,526821	0,2325						
13	20/04/20	10	6540,81	20,5	21,5	20,2	2325	20,73333	0,2325	0,00215	0,654081	0,2668						
14	20/04/20	11	5814,29	22,1	22,9	20,6	2668	21,86667	0,2668	0,00229	0,581429	0,2963						
15	20/04/20	12	4782,81	23,8	24,1	22,1	2963	23,33333	0,2963	0,00241	0,478281	0,2824						
16	20/04/20	13	4455,97	24	25,2	22,3	2824	23,83333	0,2824	0,00252	0,445597	0,2001						
17	20/04/20	14	5184,39	24,1	25,1	22,8	2001	24	0,2001	0,00251	0,518439	0,154						
18	20/04/20	15	3854,49	24,7	25,4	23,3	1540	24,46667	0,154	0,00254	0,385449	0,1301						
19	20/04/20	16	1580,53	24,3	25,3	24,3	1301	24,63333	0,1301	0,00253	0,158053	0,05759						
20	20/04/20	17	177,89	22,8	24,3	22,8	575,9	23,3	0,05759	0,00243	0,017789	0,001513						
21	20/04/20	18	0	19,6	22,8	19,6	15,13	20,66667	0,001513	0,00228	0	0						
22	20/04/20	19	0	19,2	20,1	19,1	-3,54	19,46667	-0,000354	0,00201	0	0						
23	20/04/20	20	0	18,4	19,2	18,1	-3,54	18,56667	-0,000354	0,00192	0	0						
24	20/04/20	21	0	18	18,1	17,8	-3,54	17,96667	-0,000354	0,00181	0	0						
25	20/04/20	22	0	17,6	18,2	17,5	-3,54	17,76667	-0,000354	0,00182	0	0						

1

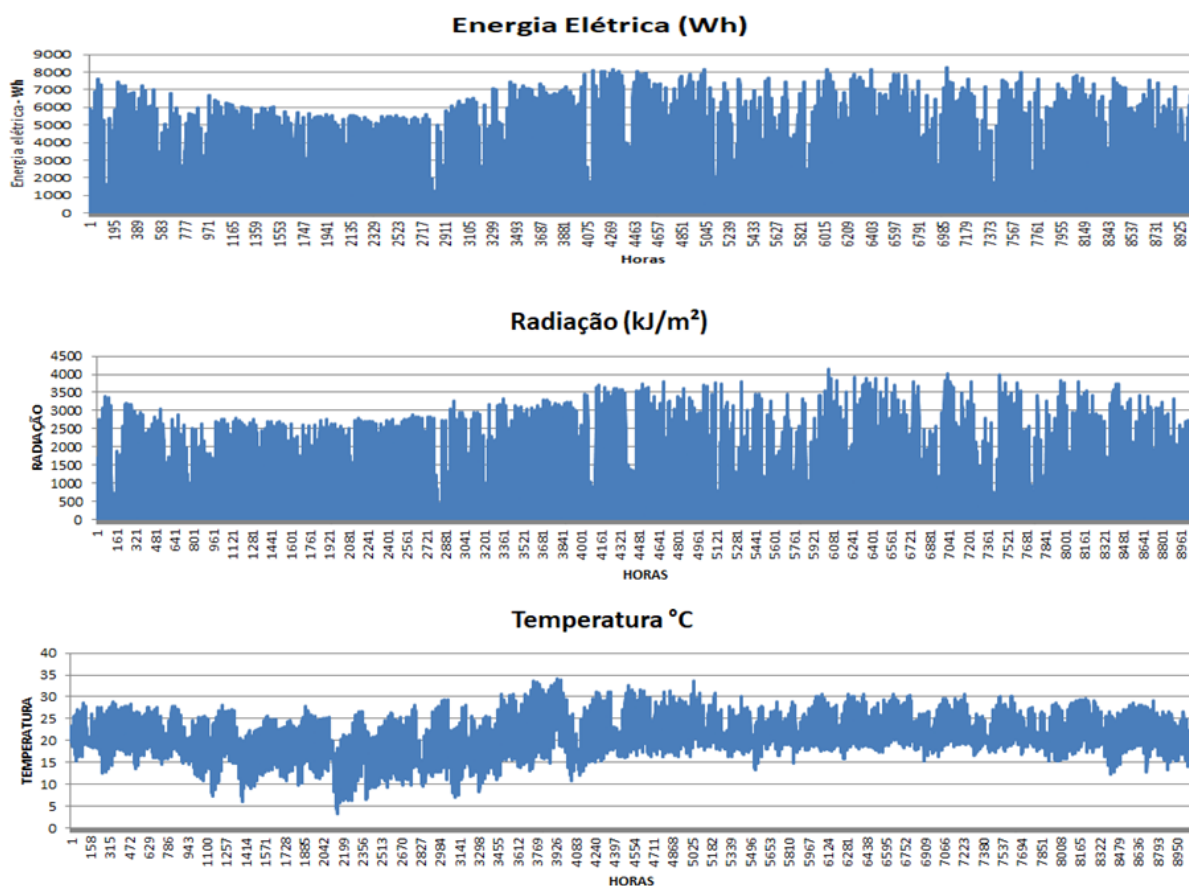
¹ <https://www.solarweb.com>

Tabela 3.1 – Caracterização da estação meteorológica automática de observação de superfície na região de Varginha - MG.

Estação: Varginha	A515
Código OMM:	848
Registro:	16 UTC
Aberta em:	13/07/2006
Latitude:	-21.566513°
Longitude:	-45.404300°
Altitude:	950 metros

Fonte: www.inmet.gov.br

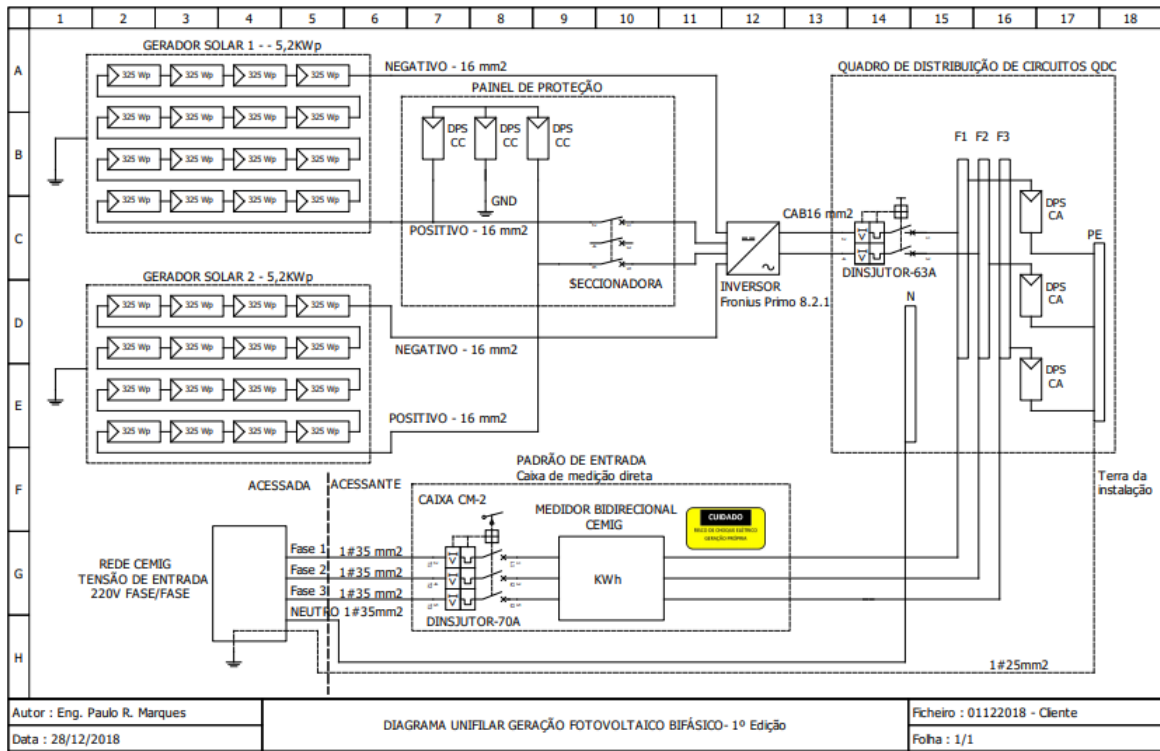
Figura 3.2 – Banco de dados utilizados para predição.



Fonte: Do autor (2020)

Na Figura 3.3 é apresentado o diagrama unifilar do sistema fotovoltaico da microestação e na Figura 3.4 o local onde foram instalados 32 módulos fotovoltaicos fornecidos pela Canadian Solar e um inversor Fronius Primo 8.2.1. As especificações técnicas dos módulos fotovoltaicos e do inversor estão apresentadas nas Tabelas 3.2 e 3.3.

Figura 3.3 – Diagrama unifilar do sistema fotovoltaico.



Fonte: Do autor (2020) - QEletroTech V07

Figura 3.4 – Usina particular na cidade de Varginha - MG.



Fonte: Do autor (2020)

Tabela 3.2 – Dados Elétricos do módulo fotovoltaico STC*.

Modelo	CS6U - 325P
Potencia nominal máxima (P_{max})	325W
Tensão de operação (V_{mp})	37,0 V
Corrente de operação (I_{mp})	8,78 A
Tensão de circuito aberto (V_{oc})	45,5 V
Corrente de curto circuito (I_{sc})	9,34 A
Eficiência do módulo	16,72%
Temperatura de operação	-40°C à +85°C
Tensão máxima do sistema	1000 V (IEC)* ou 1000 V (UL)*
Desempenho de incêndio do módulo	TYPE 1 (UL 1703) ou CLASS C (IEC 61730)
Máxima corrente do fusível em série	15 A
Classificação de aplicação	Class A
Tolerância de potência	0 à +5W
Irradiância de 1000 W/m ²	Sob condições de teste padrão (STC) Sob a condição de massa de ar padrão (espectro AM) 1,5 e temperatura de 25°C.

Fonte: Canadian Solar inc.

* (IEC) - *International Electrotechnical Commission*.

* (UL) - *Underwriters Laboratories Inc.*

Tabela 3.3 – Dados Elétricos do Inversor FRONIUS PRIMO 8.2-1.

Modelo	FRONIUS PRIMO - 8.2-1
MPP faixa de tensão ($U_{mpp-min} - U_{mpp-max}$)	270 - 800 V
Número de conexões de corrente contínua	2 + 2
Potência máxima de geração fotovoltaica na saída (P_{dc-max})	12,3 KW _p
Potência nominal na saída de AC ($P_{ac,r}$)	8200 W
Corrente nominal de saída AC (I_{ac-nom})	35,7 A
Ligação a rede elétrica (faixa de tensão)	1-NPE 220 V / 230 V (180 V - 270 V)
Faixa de frequência	50 Hz / 60 Hz (45 - 65 Hz)
Distorção harmônica total	< 5%
Fator de potência ($\cos\phi_{ac,r}$)	0.85 - 1 ind. / cap.
Eficiência máxima	98,1%

Fonte: Fronius do Brasil Ltda.

Outras duas microestações fotovoltaicas, situadas na cidade de Lavras - MG (banco 2) e outra na cidade de Varginha (banco 3) foram utilizados nesse trabalho. Esses dois bancos de dados adicionais se referem a duas microestações particulares, com especificações técnicas

distintas. Em termos de capacidade de geração, as microestações dos bancos 1, 2 e 3 possuem as potências de 8kVA, 15kVA e 3kVA, respectivamente, todas do mesmo fabricante (Fronius). Os dados dos bancos 2 e 3 foram coletados em um menor período de tempo, de seis meses.

3.1 Sistema de predição


O sistema de predição de energia fotovoltaica foi implementado utilizando um computador tipo *Notebook* com as seguintes especificações:

- a) Processador: *Intel Core i7 5500U*
- b) Geração do Processador: 7^a Geração
- c) Velocidade do Processador: 2,4 GHz
- d) Memória instalada (*RAM*): 16 GB
- e) Sistema Operacional: *Windows 10*
- f) *HD*: 1TB

O sistema foi implementado utilizando uma Rede Neural Artificial *RNA-NARX* no ambiente *MATLAB/SIMULINK/SIMPOWERSYSTEM®*, como mostra a Figura 3.5. A rede foi implementada com uma única camada escondida, função de ativação do tipo sigmóide, e um único nó de saída. O algoritmo utilizado para o treinamento da rede foi o *Bayesian Regularization (BR)*.

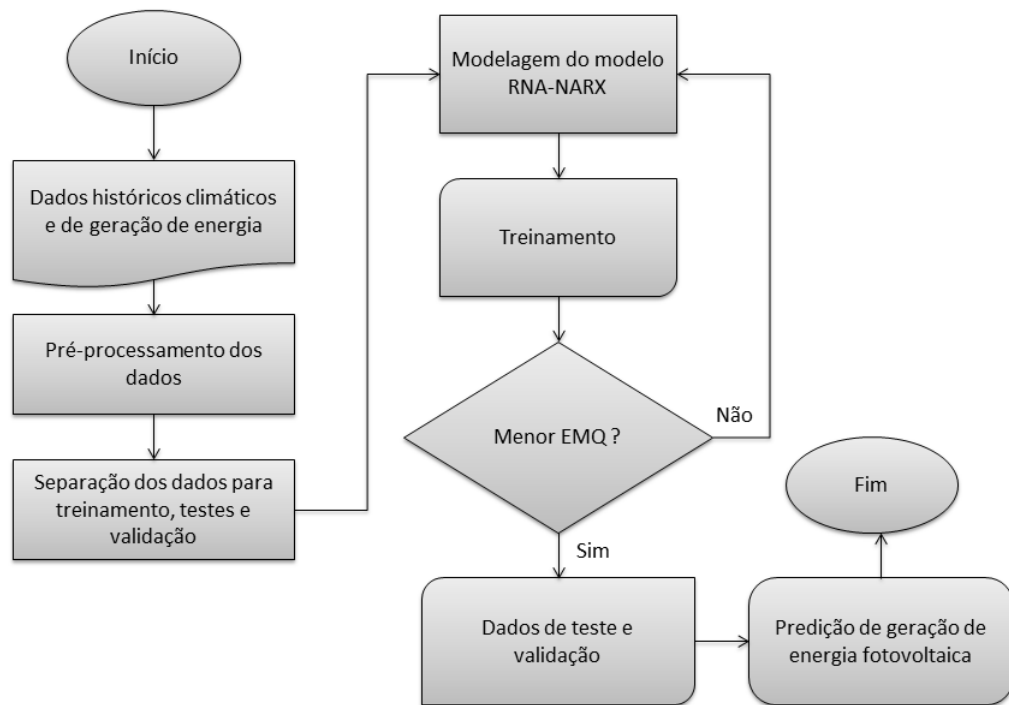
O fluxograma das etapas envolvidas no processo de implementação e treinamento da rede *NARX* é mostrado na Figura 3.6.

Figura 3.5 – Detalhamento da rede *NARX*.



Fonte: Adaptado do Matlab R2017a (2020).

Figura 3.6 – Fluxograma das etapas envolvidas no processo da rede *NARX*.



Fonte: Do autor (2020).

Rodrigues et al. (2016) em seu trabalho, comprovou que o melhor algoritmo de treinamento, dentre os que foram utilizados Levenberg-Marquardt (LM), Bayesian Regularization (BR) e Scaled Conjugate Gradient (SCG), foi o Bayesian Regularization (BR), que conseguiu prever com eficácia, a potência gerada pelo sistema fotovoltaico estudado.

Para a configuração da rede *RNA-NARX*, foram utilizados os parâmetros conforme Tabela 3.4. A rede foi treinada com os dados do banco 1: energia gerada, temperatura e radiação. Os valores dos dados de entrada e saída de treinamento primeiramente foram normalizados entre 0 e 1.

Tabela 3.4 – Dados da configuração da rede *RNA-NARX*.

Critérios	Valores definidos
Número de entradas	(2)
Número de atrasos	(5,10,20,30,40,50)
Número de neurônios na camada escondida	(5,10,15,20,25)
Número de neurônios na camada de saída	(1)
Função de ativação	Função sigmoide
Função de ativação na saída	Linear
Algoritmo da rede	Bayesian Regularization
Critério de parada	Número máximo de ciclos, taxa de EMQ e capacidade de generalização.
Medida de erro adotada	Erro médio quadrático (EMQ)
Correlação	$R > 0,95$

Fonte: Do autor (2020).

A rede *RNA-NARX* foi treinada com 70% de um total de 9084 dados disponíveis do banco 1. Os 30% dos dados restantes foram utilizados para testar (10%) e validar (20%) a capacidade de predição da *RNA-NARX*. Na etapa de validação, além do banco 1, foram utilizados os bancos 2 e 3. Os dados de entrada para treinamento, testes e validação foram apresentados à rede de forma aleatória, (Apêndice A). Sendo assim, todas as vezes que a rede neural foi colocada a treinamento, teste ou em validação, utilizou-se um conjunto de dados diferentes (randomizados).

Para determinar a melhor configuração da rede *NARX*, foram aplicados seis variações (5, 10, 20, 30, 40 e 50) de atrasos nos dados de entrada e também cinco variações (5, 10, 15, 20 e 25) de neurônios na camada oculta da rede. Quanto a parada da rede, utilizou-se o critério por erro generalização ou quando o valor do erro médio quadrático (EMQ) foi próximo de zero. O resultado obtido foi a predição de geração de energia fotovoltaica para a próxima hora. O desempenho da rede foi estimado por meio dos erros médios quadráticos (EMQ) e dos coeficientes de determinação (R^2). Os EMQ foram estimados três vezes, de forma a obter repetições para a realização das análises estatísticas.

3.2 Análises Estatísticas

Foi realizada análise de variância dos erros médios quadráticos (EMQ), obtidos de cada modelo implementado na rede de cada banco de dados (Apêndice B). Em seguida, foi realizado teste de comparação múltipla de *Scott-Knott* a nível de 95% de confiança (SCOTT; KNOTT, 1974), visando comparar os diferentes EMQ de cada caso. Os dados de EMQ não apresentaram

normalidade (curva de Gauss) e visando atender tal pressuposto, transformou-se os dados via Box-Cox (BOX; COX, 1964).

Com os resultados obtidos pelo teste de *Scott-Knott*, foi possível selecionar as configurações, números de atrasos e neurônios na camada oculta, que apresentaram o menor EMQ. Visando identificar a de melhor desempenho, realizou-se novamente a predição com os dados do banco 1, utilizando as configurações selecionadas. As análises estatísticas foram realizadas no ambiente R (R Core Team, 2020) e utilizado o pacote *ScottKnott* (JELIHOVSCHI; FARIA; ALLAMAN, 2014).

3.3 Regressão

Visando a comparar a eficiência da rede *RNA-NARX* com outra metodologia, foi realizado a predição da energia via modelo de regressão. A regressão utilizada foi a Polinomial Múltipla, em que o valor da variável Y dependente foram os dados de energia e o valor da variável independente X foram os dados de temperatura e radiação. Todos os dados utilizados foram do banco 1.

A eficiência da predição da regressão foi obtida por meio do coeficiente de determinação (R^2). Toda a análise foi implementada no *software KNIME*.

4 RESULTADOS E DISCUSSÃO

Foram utilizados nesse trabalho os bancos de dados 1, 2 e 3, pois são de microestações recém instaladas em propriedades particulares e autorizadas pelos proprietários para fins acadêmicos. Além disso, é conhecido todo o processo da elaboração do projeto, aprovação junto à Concessionária CEMIG, implantação e ativação dos sistemas de geração de energia fotovoltaica das três microestações.

O modelo da rede *RNA-NARX* depende do número de atrasos na entrada e do número de neurônios na camada oculta para a configuração. Visando conhecer a influência desses elementos na eficiência do modelo, foi realizada análise estatística, por meio da análise de variância dos EMQ (Tabela 4.1).

Tabela 4.1 – Análise de variância para os Erros Médios Quadráticos (EMQ) transformados dos diferentes modelos implementados na rede *RNA-NARX*.

Fonte de Variação	GL	SQ	QM	F
Bancos de Dados	4	2879503	719876	2419,755**
Atraso	5	102714	20543	69,0514**
Número de neurônios	4	965	241	0,8116 ^{ns}
Erro	436	129710	000297	-

**significativo a 1% de significância, pelo teste F.


^{ns} não significativo a 1% de significância, pelo teste F.

GL: Graus de liberdade - SQ: Soma de quadrado - QM: Quadrado médio.

Foi possível observar, que as fontes de variação bancos de dados e atrasos foram significativas, a 1% de probabilidade pelo teste F. Tais significâncias indicam que os diferentes bancos utilizados na rede (bancos 1, 2 e 3) apresentaram diferentes EMQ entre eles e que também, houve diferença quanto aos EMQ nas diferentes variações de atraso. Já a fonte de variação número de neurônios não apresentou significância a 1% de probabilidade pelo teste F, isto é, as diferentes variações de neurônios utilizados não apresentaram diferenças quanto ao EMQ obtido.

O teste de média realizado para os diferentes bancos de dados utilizados na etapa de validação, é apresentado na Figura 4.1. Como os valores de EMQ não apresentaram normalidade, foram transformados via *Box-Cox*. Após a transformação, os menores valores de EMQ apresentaram maiores médias transformadas e o maiores valores de EMQ apresentaram as menores médias transformadas.

Figura 4.1 – Histograma das médias EMQ transformadas via *Box-Cox* para os diferentes bancos de dados utilizados na etapa de validação da rede *RNA-NARX* com teste *Scott-Knott* a 95% de confiança.




Fonte: Do autor (2020).

Foi observado, por meio do teste *Scott Knott*, que o banco 1 apresentou maior média transformada, portanto menor EMQ, em relação aos demais bancos. Isso foi observado, pois o banco de dados 1 foi utilizado para o treinamento e teste da rede e também, por possuir maior número de dados coletados (um ano), abrangendo todas as estações do ano. Nesse trabalho não considerou a temperatura do módulo fotovoltaico e também a pressão do vento, como no trabalho apresentado por Das et al. (2017), além desses dois dados foram aplicados para o treinamento e teste do modelo de previsão generalizado para o dia seguinte, os dados históricos de produção de energia FV e dados meteorológicos (ou seja irradiância solar, temperatura atmosférica).

Os bancos 2 e 3 apresentaram os maiores valores de EMQ, sendo maior para o banco 2. Uma possível explicação para o banco 2 ter apresentado o maior EMQ em relação aos demais, é por estar situada em outra cidade.

Com relação as diferentes variações de atrasos utilizados na rede *RNA-NARX*, observou-se diferença significativa entre os EMQ de cada atraso (Figura 4.2). As variações de atraso 30, 40 e 50 apresentaram os menores EMQ em relação as variações 5, 10 e 20.


Figura 4.2 – Histograma das médias EMQ, transformadas via Box-Cox, para as diferentes variações nos atrasos utilizados na rede *RNA-NARX* com teste *Scott-Knott* a 95% de confiança.



Fonte: Do autor (2020).

Para as diferentes variações no número de neurônios empregados na rede *RNA-NARX*, não foi observado diferença significativa entre eles (Figura 4.3). Isto é, os EMQ obtidos para cada número de neurônios não foram diferentes estatisticamente entre si. Essa observação, portanto, viabiliza a aplicação de menor número de neurônios na configuração da rede, reduzindo o tempo de processamento na análise dos dados.

Figura 4.3 – Histograma das médias EMQ transformadas via *Box-Cox*, para os diferentes números de neurônios utilizados na rede *RNA-NARX* com teste *Scott-Knott* a 95% de confiança.



Fonte: Do autor (2020).

Posteriormente, visando a seleção das melhores configurações da rede para os três bancos de dados, avaliou-se os EMQ de cada configuração, por meio do teste *Scott Knott* (Tabela 4.2). As células marcadas pelo X representam as configurações que apresentaram menores EMQ pelo teste estatístico. E as linhas destacadas na cor cinza representam as configurações com menores EMQ em todos os três bancos de dados.

Tabela 4.2 – Seleção das configurações que apresentaram menores erros médios quadráticos (EMQ), segundo teste estatístico.

Atraso	Nº neurônio	Banco 1	Banco 2	Banco 3
5	5			
5	10			
5	15			
5	20			
5	25			
10	5			
10	10	X		
10	15	X		
10	20	X		
10	25	X		
20	5			
20	10	X		
20	15	X		
20	20	X		
20	25	X		
30	5	X	X	
30	10	X	X	
30	15	X		
30	20	X	X	X
30	25	X	X	X
40	5	X		
40	10	X		
40	15	X		
40	20	X		
40	25	X		
50	5	X		X
50	10	X		X
50	15	X	X	X
50	20	X		X
50	25	X	X	X

Observou-se que para o banco de dados 1, 23 configurações apresentaram os menores EMQ, no entanto, essas configurações não apresentaram diferença significativa entre elas. Para o banco 2, seis configurações apresentaram os menores EMQ, e sete configurações para o banco

3. Tal resultado indica a variação em relação aos EMQ obtidos nos bancos 2 e 3, isto é, os dois bancos apresentaram diferentes EMQ nas diferentes configurações utilizadas.

Foi possível observar, que as configurações 30/20, 30/25, 50/15 e 50/25 (atrasos e n^o de neurônios) foram as que apresentaram menores EMQ para os três bancos de dados. Sendo, portanto, analisadas as performances das mesmas para o banco 1, visando selecionar a configuração com a melhor predição.

Os desempenhos das quatro configurações são apresentadas na Tabela 4.3. Em relação ao tempo de processamento, a configuração 30/20 apresentou o menor tempo (00:03:54) e a configuração 50/25 o maior (00:21:28). No entanto, o tempo de processamento foram consideravelmente baixos, uma das características da *RNA-NARX*, apresenta alto desempenho em termos de tempo de processamento (MOSAVI et al., 2019).

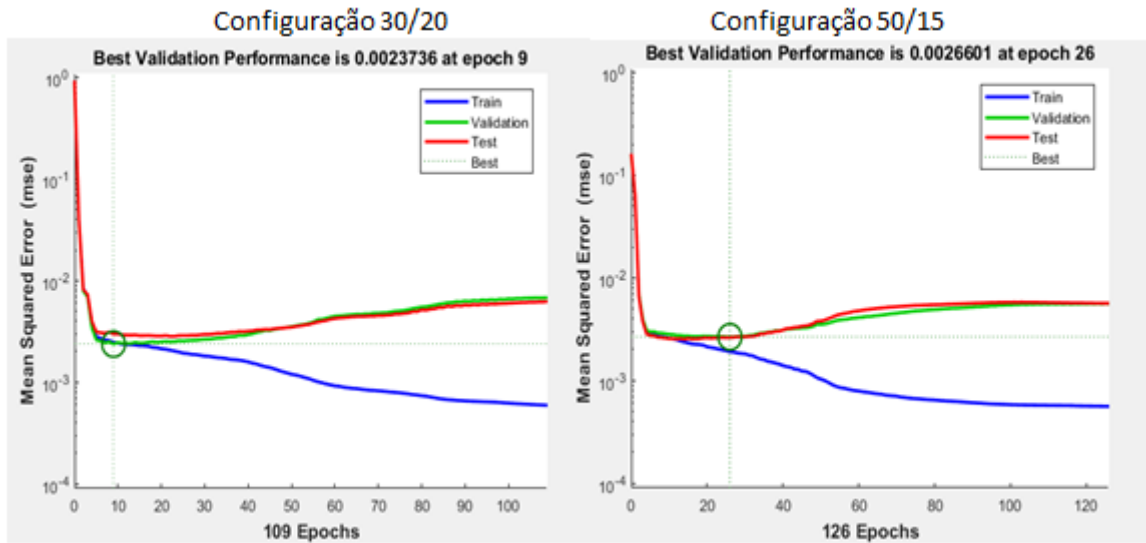
Tabela 4.3 – Análise de performance dos modelos selecionados.

Cofig.da rede	EMQ	R^2	Epocas	Tempo de Treina.
50/25	0,0030	0,976	20	00:21:28
50/15	0,0027	0,979	26	00:07:26
30/25	0,0028	0,978	20	00:07:11
30/20	0,0023	0,975	9	00:03:54

Com relação aos R^2 , estes foram bastante similares entre si. Já com relação aos valores de EMQ, essa diferença não é significativa, estatisticamente entre si, as configurações 30/20 e 50/15 apresentaram os menores erros médios quadráticos, conforme Tabela (4.3).

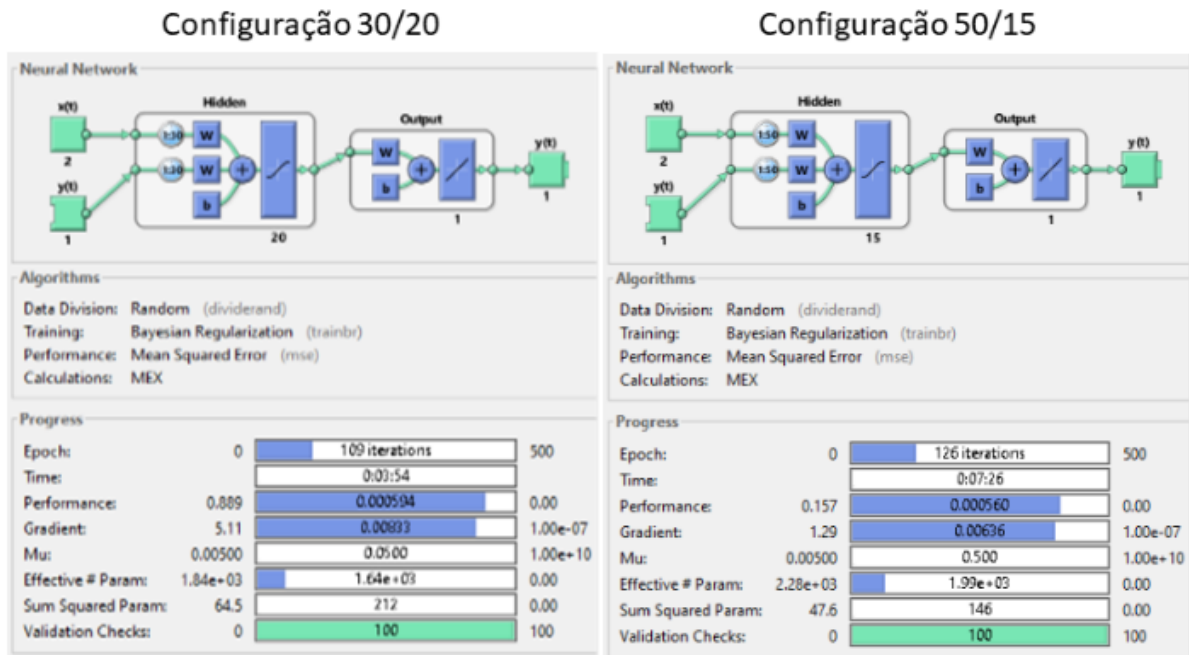
A evolução dos EMQs para as configurações 30/20 e 50/15 estão representadas na Figura 4.4, a generalização sobre os dados de validação, são mostrados nos pontos demarcados pelos círculos. Na configuração 30/20 o treinamento foi encerrado na época 109, atingindo o critério de parada e na configuração 50/15 o treinamento foi encerrado na época 126, atingindo o critério de parada, como apresentado na Figura 4.5.

Figura 4.4 – Evolução do EMQ sobre os dados de treinamento, teste e validação.



Fonte: Gerado no Matlab R2017a.

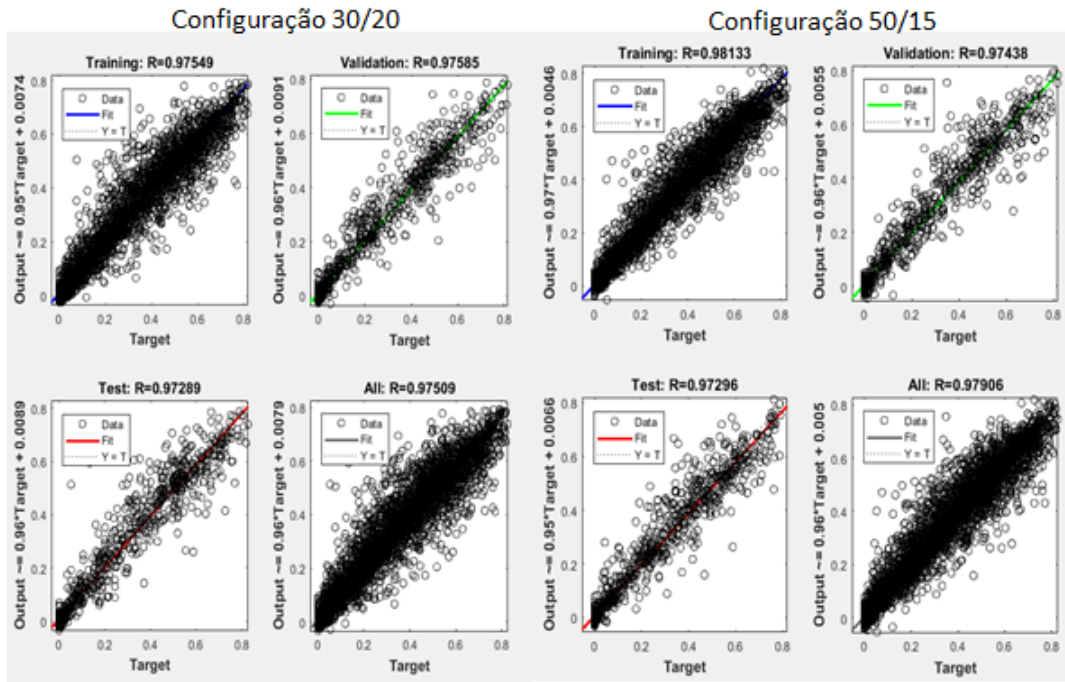
Figura 4.5 – Rede *RNA-NARX*.



Fonte: Gerado no Matlab R2017a.

Como pode ser observado na Figura 4.6, o (R^2) para todos os conjuntos, isto é, para a etapa de treinamento, teste e validação, as configurações, 30/20 variou entre 0,972 e 0,975 e a 50/15, variou entre 0,972 e 0,981. Tais valores indicam um bom ajuste entre os dados reais e os dados preditos, portanto, a rede *RNA-NARX* proposta foi capaz de prever a energia gerada pela usina fotovoltaica.


Figura 4.6 – Análise de regressão linear entre a potência medida e predita.



Fonte: Gerado no Matlab R2017a.

Além do consistente resultado obtido pelo (R^2), observa-se por meio da Figura 4.7, que o comportamento da rede na predição dos dados de geração de energia (banco 1) foi eficaz. Isto foi observado pelo comportamento semelhante dos valores de energia preditos (linha amarela) em relação aos valores de energia gerados pela microestação (linha azul). Foi observado na figura, que a resposta da rede atingiu o alvo com poucos erros próximos.

Figura 4.7 – Resposta da rede *RNA-NARX* aos dados de entrada.




Fonte: Gerado no Matlab R2017a.

Na Figura 4.8, é apresentado as correlações dos resíduos (erros) encontrados pela rede *RNA-NARX*. Observou-se que a correlação dos erros em relação ao atraso, a partir do início do

treinamento da rede foi praticamente nulo. Isso mostra que não há correlação significativa nos erros, isto é, estão dentro dos limites de confiança em torno de zero, indicando que este modelo é adequado para prever a geração de energia fotovoltaica.


Figura 4.8 – Autocorrelação dos resíduos (erros) encontrados para a rede *RNA-NARX*.



Fonte: Gerado no Matlab R2017a.

Visando certificar a eficiência do modelo *NARX*, foi realizada regressão polinomial dos dados (Figura 4.9). Os dados de energia do banco 1 foram utilizados como variável dependente (Y) e os dados de temperatura e radiação como variáveis independentes (X) do modelo.

Figura 4.9 – Diagrama de dispersão - Regressão polinomial.



A equação de predição de energia é apresentada na Equação 4.1, em que y refere-se a energia a ser gerada, o x_1 a radiação solar e o x_2 a temperatura. A regressão apresentou um bom coeficiente de determinação (0,9166), mostrando que o modelo foi bem ajustado (ATSALAKIS;

VALAVANIS, 2009). No entanto, mostrou um resultado menor em relação à rede *NARX*, ($R^2 = 0,97906$).

$$Y = 0,0669 + 2,3605x_1 - 1,5528x_1^2 - 129,6874x_2 + 46833,72x_2^2 \quad (4.1)$$

5 CONCLUSÃO

O objetivo geral do trabalho foi avaliar o uso da rede neural *NARX* como ferramenta de predição da geração de energia elétrica para uma hora à frente (curto prazo), para a microestação de energia fotovoltaica particular de Varginha-MG, aplicando diferentes bancos de dados de sistemas solares fotovoltaicos, para definir a melhor configuração da rede, ou seja, apresente o maior coeficiente de determinação (R^2) e o menor erro médio quadrático (EMQ) para cada combinação de variáveis de entrada .

Visando a predição da energia fotovoltaica, a rede *RNA-NARX* foi adotada devido aos relatos na literatura mostrarem a eficiência de tal modelo em prever energia gerada, por meio de dados de radiação (BOUSSAADA et al., 2018; LOUTFI; BERNATCHOU; TADILI, 2017). No entanto, o uso da *RNA-NARX* na predição de energia fotovoltaica por meio de dados de energia, temperatura e radiação, como empregados nesse trabalho, não foi encontrado na literatura.

Nesse trabalho trinta configurações diferentes foram avaliadas. Aplicando análise estatística, foi possível observar que as configurações 30/20, 30/25, 50/15 e 50/25 (atraso/nº de neurônios), foram as que apresentaram os menores erros médios quadráticos (EMQ) para os três bancos de dados.

Com este resultado, foi realizado uma nova avaliação aplicando-se as configurações 30/20, 30/25, 50/15 e 50/25 (atraso/nº de neurônios) para o banco 1, visando selecionar a configuração com a melhor predição. Conforme resultados obtidos, conclui-se que as melhores configurações para a rede *RNA-NARX*, foram a configuração com 20 neurônios na camada oculta e 30 atrasos em sua entrada e a configuração 15 neurônios na camada oculta e 50 atrasos em sua entrada. Estas configurações resultaram em um erro médio quadrático de 0,0023 e 0,0027 e coeficiente de determinação 0,975 e 0,979.

Visando comparar a eficiência da rede *RNA-NARX* com outra metodologia, foi realizado a predição da energia fotovoltaica via modelo de regressão polinomial, onde apresentou coeficiente de determinação $R^2 = 0,9166$, mostrando que o modelo foi bem ajustado. No entanto, mostrou um resultado menor em relação à rede *NARX*.

A rede *RNA-NARX* mostrou-se promissora para previsão de geração de energia fotovoltaica (FV) com uma hora de antecipação, confirmando que as variáveis temperatura, irradiação e geração de energia tem grande influência na predição com resultados satisfatórios, e de fundamental importância para o controle e planejamento do sistema elétrico.

6 TRABALHOS FUTUROS

- Aplicação de outros modelos de rede neural artificial para previsão da geração de energia fotovoltaica e fazer comparativos entre os resultados.
- Utilizar um banco com mais dados (dois anos de observações), com dois períodos das quatro estações do ano (Outono, Inverno, Primavera e Verão), para predição da geração de energia fotovoltaica.
- Aplicar o modelo *RNA-NARX* para predição de energia eólica.

REFERÊNCIAS

- ABEDINIA, O.; AMJADY, N.; GHADIMI, N. Solar energy forecasting based on hybrid neural network and improved metaheuristic algorithm. **Computational Intelligence**, Wiley Online Library, v. 34, n. 1, p. 241–260, 2018.
- ABHISHEK, K. et al. Weather forecasting model using artificial neural network. **Procedia Technology**, Elsevier, v. 4, p. 311–318, 2012.
- AGOUA, X. G.; GIRARD, R.; KARINIOTAKIS, G. Short-term spatio-temporal forecasting of photovoltaic power production. **IEEE Transactions on Sustainable Energy**, IEEE, v. 9, n. 2, p. 538–546, 2017.
- AGUIRRE, L.; CORREA, M. V.; CASSINI, C. Nonlinearities in narx polynomial models: representation and estimation. **IEE Proceedings-Control Theory and Applications**, IET, v. 149, n. 4, p. 343–348, 2002.
- AGUIRRE, L. L. Introdução à identificação de sistemas: técnicas lineares e não lineares aplicadas a sistemas reais. **Editora UFMG. Belo Horizonte**, 2007.
- ATSALAKIS, G. S.; VALAVANIS, K. P. Surveying stock market forecasting techniques—part ii: Soft computing methods. **Expert Systems with applications**, Elsevier, v. 36, n. 3, p. 5932–5941, 2009.
- BALFOUR, J.; SHAW, M.; NASH, N. Introdução ao projeto de sistemas fotovoltaicos. **São Paulo: LTD**, 2016.
- BECQUEREL, A.-E. Recherches sur les effets de la radiation chimique de la lumiere solaire au moyen des courants electriques. **CR Acad. Sci**, v. 9, p. 145–149, 1839.
- BILGILI, M.; SAHIN, B.; YASAR, A. Application of artificial neural networks for the wind speed prediction of target station using reference stations data. **Renewable Energy**, Elsevier, v. 32, n. 14, p. 2350–2360, 2007.
- BOUSSAADA, Z. et al. A nonlinear autoregressive exogenous (narx) neural network model for the prediction of the daily direct solar radiation. **Energies**, Multidisciplinary Digital Publishing Institute, v. 11, n. 3, p. 620, 2018.
- BOX, G. E.; COX, D. R. An analysis of transformations. **Journal of the Royal Statistical Society: Series B (Methodological)**, Wiley Online Library, v. 26, n. 2, p. 211–243, 1964.
- BOYLE, G. Renewable energy. **Renewable Energy**, by Edited by Godfrey Boyle, pp. 456. **Oxford University Press, May 2004. ISBN-10: 0199261784. ISBN-13: 9780199261789**, p. 456, 2004.
- BUITENHUIS, A.; PEARCE, J. M. Open-source development of solar photovoltaic technology. **Energy for Sustainable Development**, Elsevier, v. 16, n. 3, p. 379–388, 2012.
- CANADIANSOLAR. Canadian Solar Datasheet MaxPower CS6X-P, 2017. Disponível em: <https://siccossolar.com.br/PDF/CanadianSolar/1ModulosFotovoltaicos/3.1.Modulo72cells/3.1.1StandardPoly-SiCS6X/canadian_solar-datasheet-maxpower-CS6X-P-v5.pdf>.
- CARDADOR, M. A. Seguidor de potência máxima para sistema fotovoltaico com conversor matricial. **Instituto Superior Técnico, Universidade Técnica de Lisboa**, 2011.

- CARNEIRO, J. Electromagnetismo b módulos fotovoltaicos características e associações. **Universidade do Minho Escola de Ciências Departamento de Física Campus de Azurém, Guimarães**, 2010.
- CASTANER, L.; SILVESTRE, S. **Modelling photovoltaic systems using PSpice**. [S.l.]: John Wiley and Sons, 2002.
- CILIMKOVIC, M. Neural networks and back propagation algorithm. **Institute of Technology Blanchardstown, Blanchardstown Road North Dublin**, v. 15, 2015.
- DAS, U. K. et al. Svr-based model to forecast pv power generation under different weather conditions. **Energies**, Multidisciplinary Digital Publishing Institute, v. 10, n. 7, p. 876, 2017.
- DAS, U. K. et al. Forecasting of photovoltaic power generation and model optimization: A review. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 81, p. 912–928, 2018.
- DROSSU, R.; OBRADOVIC, Z. Rapid design of neural networks for time series prediction. **IEEE Computational Science and Engineering**, IEEE, v. 3, n. 2, p. 78–89, 1996.
- FAHRENBRUCH, A.; BUBE, R. **Fundamentals of solar cells: photovoltaic solar energy conversion**. [S.l.]: Elsevier, 2012.
- GAROUDJA, E. et al. Statistical fault detection in photovoltaic systems. **Solar Energy**, Elsevier, v. 150, p. 485–499, 2017.
- GREEN, M. A. et al. Solar cell efficiency tables (version 50). **Progress in Photovoltaics: Research and Applications**, Wiley Online Library, v. 25, n. 7, p. 668–676, 2017.
- GREENPRO, A. P. C. Energia fotovoltaica-manual sobre tecnologias, projecto e instalação. **Europa: Comissão Europeia**, p. 43, 2004.
- GUARNIERI, R. A. Emprego de redes neurais artificiais e regressão linear múltipla no refinamento das previsões de radiação solar do modelo eta. **Unpublished master's thesis, Instituto Nacional de Pesquisas Espaciais**, 2006.
- GUARNIERI, R. A. Emprego de redes neurais artificiais e regressão linear múltipla no refinamento das previsões de radiação solar do modelo eta. **Unpublished master's thesis, Instituto Nacional de Pesquisas Espaciais**, 2006.
- HAYKIN, S. Redes neurais: princípios e prática, 2ª edição, tradução: Paulo martins engel. **Editora: Bookman, Porto Alegre, Cap**, v. 1, n. 2, p. 3, 2001.
- HAYKIN, S. **Redes Neurais: Princípios e Pratica**. [S.l.]: Artmed, 2007. ISBN 9788577800865.
- HEINEN, E. D.; FERNANDES, R. A. Redes neurais recorrentes aplicadas à previsão de radiação solar no horizonte de curto prazo. **Anais do Computer on the Beach**, p. 841–849, 2018.
- JAMAL, T. et al. Technical challenges of pv deployment into remote australian electricity networks: A review. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 77, p. 1309–1325, 2017.

JELIHOVSCHI, E. G.; FARIA, J. C.; ALLAMAN, I. B. Scottknott: a package for performing the scott-knott clustering algorithm in r. **TEMA (São Carlos)**, SciELO Brasil, v. 15, n. 1, p. 3–17, 2014.

KALOGIROU, S. A. Artificial neural networks in renewable energy systems applications: a review. **Renewable and sustainable energy reviews**, Elsevier, v. 5, n. 4, p. 373–401, 2001.

KUBAT, M. Neural networks: a comprehensive foundation by simon haykin, macmillan, 1994, isbn 0-02-352781-7. **The Knowledge Engineering Review**, Cambridge University Press, v. 13, n. 4, p. 409–412, 1999.

LAOUAFI, A.; MORDJAOUI, M.; DIB, D. One-hour ahead electric load and wind-solar power generation forecasting using artificial neural network. In: IEEE. **IREC2015 The Sixth International Renewable Energy Congress**. [S.l.], 2015. p. 1–6.

LEVENBERG, K. A method for the solution of certain non-linear problems in least squares. **Quarterly of applied mathematics**, v. 2, n. 2, p. 164–168, 1944.

LIMA, K. C.; FERNANDEZ, J. P. R. A influência das anomalias de temperatura da superfície do mar e da topografia em dois eventos de precipitação intensa ocorridos no sudeste do brasil. **Engenharia Ambiental: Pesquisa e Tecnologia**, v. 8, n. 1, 2011.

LOPES, J. H. O. et al. Previsão de produção fotovoltaica a muito curto prazo usando análise e modelação de dinâmica de sombras. 2010.

LOSCHI, H. J. et al. Proposta de um método complementar de predição da irradiância solar global para curtos intervalos de tempo, baseado em processos de markov= proposal of a global solar irradiance prediction complementary method for short-term, based on markov processes. [sn], 2017.

LOUTFI, H.; BERNATCHOU, A.; TADILI, R. Generation of horizontal hourly global solar radiation from exogenous variables using an artificial neural network in fes (morocco). **International Journal of Renewable Energy Research (IJRER)**, v. 7, n. 3, p. 1097–1107, 2017.

MORENO-MUNOZ, A. et al. Very short term forecasting of solar radiation. In: IEEE. **2008 33rd IEEE Photovoltaic Specialists Conference**. [S.l.], 2008. p. 1–5.

MOSAVI, A. et al. State of the art of machine learning models in energy systems, a systematic review. **Energies**, Multidisciplinary Digital Publishing Institute, v. 12, n. 7, p. 1301, 2019.

OECD, I. et al. Energy and air pollution: World energy outlook special report 2016. International Energy Agency, Paris, France, 2016.

OLATOMIWA, L. et al. Adaptive neuro-fuzzy approach for solar radiation prediction in nigeria. **Renewable and Sustainable Energy Reviews**, Elsevier, v. 51, p. 1784–1791, 2015.

PIAZZA, A. D.; PIAZZA, M. C. D.; VITALE, G. Solar and wind forecasting by narx neural networks. **Renewable Energy and Environmental Sustainability**, EDP Sciences, v. 1, p. 39, 2016.

PIRES, C. L. et al. Metodologia para previsão de carga e geração no horizonte de curtíssimo prazo. Universidade Federal de Santa Maria, 2016.

R Core Team. **R: A Language and Environment for Statistical Computing**. Vienna, Austria, 2020. Disponível em: <<https://www.R-project.org/>>.

RODRIGUES, L. M. R. et al. Previsão do comportamento de um sistema elétrico com penetração fotovoltaica utilizando inteligência artificial. 2016.

SAWIN, J. L. et al. Renewables 2018-global status report. a comprehensive annual overview of the state of renewable energy. advancing the global renewable energy transition-highlights of the ren21 renewables 2018 global status report in perspective. 2018.

SCOTT, A. J.; KNOTT, M. A cluster analysis method for grouping means in the analysis of variance. **Biometrics**, JSTOR, p. 507–512, 1974.

SILVA, R. A. e; BRITO, M. Impact of network layout and time resolution on spatio-temporal solar forecasting. **Solar Energy**, Elsevier, v. 163, p. 329–337, 2018.

SURI, M. et al. Cloud cover impact on photovoltaic power production in south africa. **Proceedings of SASEC**, 2014.

TEIXEIRA, T. B. Influência da temperatura em aglomerados auto-reconfiguráveis de células solares fotovoltaicas. **MSc em Universidade Federal de Minas Gerais-Instituto de Ciências Exatas**, 2008.

TZANAKOU, E. M. Supervised and unsupervised pattern recognition: feature extraction and computational intelligence. CRC press, 2017.

VILLALVA, M. G. **Energia Solar Fotovoltaica**. [S.l.]: Saraiva Educação SA, 1983.

VILLALVA, M. G.; GAZOLI, J. R. Energia solar fotovoltaica: conceitos e aplicações. **São Paulo: Érica**, v. 2, 2012.

ZILLES, R. et al. **Sistemas fotovoltaicos conectados à rede elétrica**. [S.l.]: Oficina de Textos, 2016.

APÊNDICE A

Script aplicado:

```

%Limpa tela
clear all
close all
clc

%Entra dados

Energia = csvread('energiaV0.csv');
Radiaetemp = csvread('radiaetempV0.csv');%
X = tonndata(Radiaetemp,false,false); %entrada com atrasos
T = tonndata(Energia,false,false);%saída com atrasos

% Tipo de treino

trainFcn = 'trainbr'; % Bayesian Regularization backpropagation
%Atrasos na saída e na entrada
inputDelays = 1:50; %número atrasos na entrada X, melhora mto o
desempenho
feedbackDelays = 1:50; %número de atrasos na saída T, mas atrasos tbm
deixam lento
hiddenLayerSize = 1:15 ; % número de neurônios melhora o processamento
mas nem mto
net=narxnet(inputDelays,feedbackDelays,hiddenLayerSize,'open',trainFcn);%
insere os atrasos na rede
net.inputs{1}.processFcns = {'removeconstantrows','mapminmax'}; %calibra
as entradas
net.inputs{2}.processFcns = {'removeconstantrows','mapminmax'}; %calibra
as entradas

%-----
% TREINO
%-----

%preparando a rede

[x,xi,ai,t] = preparets(net,X,{},T);
net.divideFcn = 'dividerand'; % Esse comando divide os dados
aleatoriamente pra melhorar o treino

net.divideMode = 'time'; % Comando para todo o conjunto de dados
net.trainParam.epochs=1000; % Número de épocas.
net.trainParam.goal = 1e-10; % Erro.
net.trainParam.max_fail = 100; % Validação.
net.divideParam.trainRatio = 70/100; % porcentagem de treino
net.divideParam.testRatio = 15/100; % porcentagem de teste
net.divideParam.valRatio = 15/100; % porcentagem de validação
net.performFcn = 'mse'; % Critério de avaliação da rede (Mean Squared
Error) ou rmse etc...
net.plotFcns = {'plotperform','plottrainstate', 'ploterrhist', ...
'plotregression', 'plotresponse', 'ploterrcorr', 'plotinerrcorr'};

% iniciar treino
[net,tr] = train(net,x,t,xi,ai);

```

```

%-----
% TESTE
%-----

y = net(x,xi,ai);
e = gsubtract(t,y);
trainTargets = gmultiply(t,tr.trainMask);%cria o teste
valTargets = gmultiply(t,tr.valMask); %cria a validação
testTargets = gmultiply(t,tr.testMask); %cria o teste
EMQ_TREINAMENTO_CONJ = perform(net,trainTargets,y) %Erro Treino
EMQ_TESTE_DADOS_MESMO_CONJ = perform(net,testTargets,y) %Erro Teste
EMQ_VAL_DEMAIS_DADOS_MESMO_CONJ=perform(net,valTargets,y)%ErroValidação

%% VALIDAÇÃO 1º CONJUNTO EXTERNO DE DADOS

Energia_conj1 = csvread('energiaALDV0.csv');
Radiaetemp_conj1 = csvread('radiaetempALDV0.csv');
Input2 = tonndata(Radiaetemp_conj1,false,false); %entrada com atrasos
Output2 = tonndata(Energia_conj1,false,false);%saída com atrasos
[Xs2, Xi2, Ai2, Ts2] = preparets(net, Input2, {}, Output2);
[Y,Xf,Af] = net(Xs2, Xi2, Ai2);
MSE_CONJ_EXT_1 = perform(net, Ts2, Y);
disp('EMQ de Validação CONJ EXTERNO 1:')
disp(MSE_CONJ_EXT_1)

%% VALIDAÇÃO 2º CONJUNTO EXTERNO DE DADOS

Energia_conj2 = csvread('energiaKISV0.csv');
Radiaetemp_conj2 = csvread('radiaetempKISV0.csv');
Input3 = tonndata(Radiaetemp_conj2,false,false); %entrada com atrasos
Output3 = tonndata(Energia_conj2,false,false);%saída com atrasos
[Xs4, Xi4, Ai4, Ts4] = preparets(net, Input3, {}, Output3);
[Y2,Xf2,Af2] = net(Xs4, Xi4, Ai4);
MSE_CONJ_EXT_2 = perform(net, Ts4, Y2);
disp('EMQ de Validação CONJ EXTERNO 2:')
disp(MSE_CONJ_EXT_2)
save redetreinada.mat

```

APÊNDICE B

Dados dos Erros Médios Quadrados (EMQ).

Banco de Dados	Atraso	Neurônio	Repetições dos testes	EMQ	Banco de Dados	Atraso	Neurônio	Repetições dos testes	EMQ	Banco de Dados	Atraso	Neurônio	Repetições dos testes	EMQ
1	5	5	1	0,003355	2	5	5	1	0,022965	3	5	5	1	0,015103
1	10	5	1	0,002521	2	10	5	1	0,025511	3	10	5	1	0,020296
1	20	5	1	0,002787	2	20	5	1	0,025588	3	20	5	1	0,014111
1	30	5	1	0,002879	2	30	5	1	0,009553	3	30	5	1	0,008491
1	40	5	1	0,003008	2	40	5	1	0,013124	3	40	5	1	0,006305
1	50	5	1	0,002599	2	50	5	1	0,010729	3	50	5	1	0,004943
1	5	10	1	0,003284	2	5	10	1	0,023361	3	5	10	1	0,016082
1	10	10	1	0,003046	2	10	10	1	0,037545	3	10	10	1	0,023564
1	20	10	1	0,002796	2	20	10	1	0,029579	3	20	10	1	0,015612
1	30	10	1	0,002455	2	30	10	1	0,009514	3	30	10	1	0,006441
1	40	10	1	0,002791	2	40	10	1	0,015531	3	40	10	1	0,008862
1	50	10	1	0,002696	2	50	10	1	0,008935	3	50	10	1	0,004901
1	5	15	1	0,003195	2	5	15	1	0,021597	3	5	15	1	0,016276
1	10	15	1	0,002745	2	10	15	1	0,030282	3	10	15	1	0,016709
1	20	15	1	0,002562	2	20	15	1	0,040187	3	20	15	1	0,024049
1	30	15	1	0,0028	2	30	15	1	0,012162	3	30	15	1	0,008255
1	40	15	1	0,00234	2	40	15	1	0,012608	3	40	15	1	0,008381
1	50	15	1	0,002811	2	50	15	1	0,006322	3	50	15	1	0,004445
1	5	20	1	0,003067	2	5	20	1	0,022226	3	5	20	1	0,014562
1	10	20	1	0,002618	2	10	20	1	0,037056	3	10	20	1	0,01922
1	20	20	1	0,002624	2	20	20	1	0,044207	3	20	20	1	0,016633
1	30	20	1	0,00293	2	30	20	1	0,008093	3	30	20	1	0,005938

1	40	20	1	0,00245	2	40	20	1	0,015116	3	40	20	1	0,008381
1	50	20	1	0,002823	2	50	20	1	0,009558	3	50	20	1	0,005182
1	5	25	1	0,003073	2	5	25	1	0,020453	3	5	25	1	0,014059
1	10	25	1	0,002542	2	10	25	1	0,034516	3	10	25	1	0,016153
1	20	25	1	0,002562	2	20	25	1	0,044329	3	20	25	1	0,015533
1	30	25	1	0,002905	2	30	25	1	0,008248	3	30	25	1	0,00604
1	40	25	1	0,002791	2	40	25	1	0,012356	3	40	25	1	0,007172
1	50	25	1	0,002632	2	50	25	1	0,008884	3	50	25	1	0,005358
1	5	5	2	0,003511	2	5	5	2	0,01389	3	5	5	2	0,011403
1	10	5	2	0,003213	2	10	5	2	0,031288	3	10	5	2	0,018736
1	20	5	2	0,003411	2	20	5	2	0,03925	3	20	5	2	0,019668
1	30	5	2	0,002844	2	30	5	2	0,008854	3	30	5	2	0,006334
1	40	5	2	0,002512	2	40	5	2	0,011996	3	40	5	2	0,00697
1	50	5	2	0,002631	2	50	5	2	0,012432	3	50	5	2	0,00568
1	5	10	2	0,003016	2	5	10	2	0,019446	3	5	10	2	0,012798
1	10	10	2	0,003011	2	10	10	2	0,03636	3	10	10	2	0,018607
1	20	10	2	0,002789	2	20	10	2	0,03193	3	20	10	2	0,014613
1	30	10	2	0,00259	2	30	10	2	0,008706	3	30	10	2	0,006174
1	40	10	2	0,002513	2	40	10	2	0,01205	3	40	10	2	0,006913
1	50	10	2	0,002588	2	50	10	2	0,011315	3	50	10	2	0,006279
1	5	15	2	0,003194	2	5	15	2	0,015045	3	5	15	2	0,011441
1	10	15	2	0,002852	2	10	15	2	0,034004	3	10	15	2	0,018986
1	20	15	2	0,002845	2	20	15	2	0,045942	3	20	15	2	0,021449

1	30	15	2	0,002724	2	30	15	2	0,015432	3	30	15	2	0,008077
1	40	15	2	0,00281	2	40	15	2	0,010197	3	40	15	2	0,007309
1	50	15	2	0,002965	2	50	15	2	0,00954	3	50	15	2	0,005722
1	5	20	2	0,002664	2	5	20	2	0,020963	3	5	20	2	0,013632
1	10	20	2	0,002922	2	10	20	2	0,034021	3	10	20	2	0,017573
1	20	20	2	0,002893	2	20	20	2	0,026499	3	20	20	2	0,013147
1	30	20	2	0,002592	2	30	20	2	0,00632	3	30	20	2	0,005236
1	40	20	2	0,0031	2	40	20	2	0,011151	3	40	20	2	0,006507
1	50	20	2	0,002351	2	50	20	2	0,010855	3	50	20	2	0,006155
1	5	25	2	0,003443	2	5	25	2	0,02267	3	5	25	2	0,014836
1	10	25	2	0,002656	2	10	25	2	0,027088	3	10	25	2	0,016617
1	20	25	2	0,002814	2	20	25	2	0,031486	3	20	25	2	0,016162
1	30	25	2	0,002484	2	30	25	2	0,00587	3	30	25	2	0,005524
1	40	25	2	0,002507	2	40	25	2	0,012441	3	40	25	2	0,008162
1	50	25	2	0,002421	2	50	25	2	0,00826	3	50	25	2	0,005537
1	5	5	3	0,003172	2	5	5	3	0,018527	3	5	5	3	0,010324
1	10	5	3	0,003144	2	10	5	3	0,029114	3	10	5	3	0,014461
1	20	5	3	0,002673	2	20	5	3	0,034651	3	20	5	3	0,015018
1	30	5	3	0,002831	2	30	5	3	0,011521	3	30	5	3	0,007554
1	40	5	3	0,00285	2	40	5	3	0,012288	3	40	5	3	0,008153
1	50	5	3	0,002553	2	50	5	3	0,008802	3	50	5	3	0,004499
1	5	10	3	0,003166	2	5	10	3	0,019256	3	5	10	3	0,013126
1	10	10	3	0,002413	2	10	10	3	0,029675	3	10	10	3	0,017694

1	20	10	3	0,002771	2	20	10	3	0,034716	3	20	10	3	0,016755
1	30	10	3	0,002738	2	30	10	3	0,011987	3	30	10	3	0,007276
1	40	10	3	0,002653	2	40	10	3	0,012708	3	40	10	3	0,008241
1	50	10	3	0,002923	2	50	10	3	0,012943	3	50	10	3	0,006117
1	5	15	3	0,003052	2	5	15	3	0,018463	3	5	15	3	0,011343
1	10	15	3	0,002944	2	10	15	3	0,026334	3	10	15	3	0,018504
1	20	15	3	0,002661	2	20	15	3	0,034432	3	20	15	3	0,016434
1	30	15	3	0,003092	2	30	15	3	0,008969	3	30	15	3	0,006028
1	40	15	3	0,002698	2	40	15	3	0,012088	3	40	15	3	0,008046
1	50	15	3	0,002564	2	50	15	3	0,007384	3	50	15	3	0,004943
1	5	20	3	0,003151	2	5	20	3	0,020924	3	5	20	3	0,014143
1	10	20	3	0,002704	2	10	20	3	0,026547	3	10	20	3	0,014702
1	20	20	3	0,002576	2	20	20	3	0,043684	3	20	20	3	0,019725
1	30	20	3	0,002553	2	30	20	3	0,01345	3	30	20	3	0,007748
1	40	20	3	0,002594	2	40	20	3	0,015099	3	40	20	3	0,008246
1	50	20	3	0,002711	2	50	20	3	0,014135	3	50	20	3	0,006633
1	5	25	3	0,002907	2	5	25	3	0,015803	3	5	25	3	0,011681
1	10	25	3	0,002821	2	10	25	3	0,026619	3	10	25	3	0,013839
1	20	25	3	0,002786	2	20	25	3	0,040981	3	20	25	3	0,017675
1	30	25	3	0,002678	2	30	25	3	0,011645	3	30	25	3	0,006925
1	40	25	3	0,002839	2	40	25	3	0,011569	3	40	25	3	0,007154
1	50	25	3	0,002482	2	50	25	3	0,011144	3	50	25	3	0,005879