

William Moldenhauer de Jesus

**USO DE REDES NEURAIAS ARTIFICIAIS
AUTORREGRESSIVAS PARA ESTIMAR A CAPACIDADE DE
REFRIGERAÇÃO DE COMPRESSORES ATRAVÉS DE DADOS
DE REGIME TRANSIENTE**

Trabalho de conclusão de curso
submetido ao Centro de Engenharias
da Mobilidade da Universidade
Federal de Santa Catarina para a
obtenção do Grau de Bacharel
Interdisciplinar em Mobilidade.

Orientador: Prof. Dr. Rodolfo César
Costa Flesch.

Joinville
2013

Jesus, William Moldenhauer de

Uso de redes neurais artificiais autorregressivas para estimar a capacidade de refrigeração de compressores através de dados de regime transiente / William Moldenhauer de Jesus; orientador, Rodolfo César Costa Flesch - Florianópolis, SC, 2013.
58 p.

Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Santa Catarina, Campus Joinville. Graduação em Engenharia da Mobilidade.

Inclui referências

1. Engenharia da Mobilidade. 2. Redes Neurais Artificiais Não Lineares Autorregressivas. 3. Estimção da Capacidade de refrigeração. I. Flesch, Rodolfo César Costa . II. Universidade Federal de Santa Catarina. Graduação em Engenharia da Mobilidade. III. Título.

William Moldenhauer de Jesus

**USO DE REDES NEURAIAS ARTIFICIAIS
AUTORREGRESSIVAS PARA ESTIMAR A CAPACIDADE DE
REFRIGERAÇÃO DE COMPRESSORES ATRAVÉS DE DADOS
DE REGIME TRANSIENTE**

Esta monografia foi julgada adequada para obtenção do Título de “Bacharel Interdisciplinar em Mobilidade”, e aprovada em sua forma final.

Joinville, 26 de agosto de 2013

Prof. Sílvia Lopes de Sena Taglialenha, Dra
Coordenadora do Curso

Banca Examinadora:

Prof. Rodolfo César Costa Flesch, Dr.
Orientador
Universidade Federal de Santa Catarina

Prof. Lucas Weihmann, Dr.
Universidade Federal de Santa Catarina

Prof. Rodrigo Castelan Carlson, Dr.
Universidade Federal de Santa Catarina

Aos meus pais que tanto se esforçaram para que eu aqui chegasse, aos meus sobrinhos, com amor dedico este trabalho.

AGRADECIMENTOS

Primeiramente agradeço aos meus pais, Cintia Rosana Moldenhauer e Valmir de Jesus Junior, por terem me dado à vida. Sem o amor que nutriram um dia não teria nascido o fruto que aqui está. Agradeço também o apoio e a amizade incondicional que os dois me proporcionaram nos momentos mais difíceis que passamos. Agradeço ao carinho e paciência que dispenderam comigo durante toda a vida, muitas vezes privando-se das suas próprias, para a tarefa da criação que foi realizada de forma linda, com tamanho afeto e carinho que apenas este parágrafo para lhes agradecer se mostra tão singela quanto um átomo no meio do universo.

Apesar de acreditar ser impossível agradecer a todos que contribuíram para que eu chegasse até aqui, sinto que não devo deixar de fazê-lo pelo medo de esquecer uns de vocês. Por isso de antemão agradeço todos os anônimos que nessa vida toparam comigo. A todos que de certa forma me trouxeram até aqui, me puxando ou empurrando, todos vocês foram imprescindíveis para que eu aqui chegasse.

No entanto fico muito feliz de lembrar e poder agradecer aos meus avôs, vó Daura, vó Neci, vô Valmir pelas inúmeras acolhidas em suas casas, pelas alegrias durante os cafés e pelas palavras de carinho, apoio e sabedoria que sem dúvida me trouxeram até aqui. Agradeço também aos meus irmãos Felipe, Pamela e Priscila, aos meus tios e primos pela amizade incondicional que nutrimos uns pelos outros.

Agradeço ao meu orientador, professor Rodolfo César Costa Flesch, pela amizade e apoio durante todo o tempo.

Agradeço a todos os meus professores, meus amigos e amigas, a todas pessoas que estão ou passaram pela minha vida. Sem o apoio onipresente de vocês em minha vida nada seria possível. Sem vocês os fardos seriam infinitamente mais pesados e as alegrias infinitamente mais tristes. Vocês não têm ideia do quanto foram presentes em toda a minha vida mesmo quando não nos comunicamos com a frequência que gostaríamos. Muito obrigado.

“Um homem precisa viajar. Por sua conta, não por meio de histórias, imagens, livros ou TV. Precisa viajar por si, com seus olhos e pés, para entender o que é seu. Para um dia plantar as suas próprias árvores e dar-lhes valor. Conhecer o frio para desfrutar o calor. E o oposto. Sentir a distância e o desabrigo para estar bem sob o próprio teto. Um homem precisa viajar para lugares que não conhece para quebrar essa arrogância que nos faz ver o mundo como o imaginamos, e não simplesmente como é ou pode ser. Que nos faz professores e doutores do que não vimos, quando deveríamos ser alunos, e simplesmente ir ver”.

(Amyr Klink, 1998)

RESUMO

Os processos industriais e a forma com que os produtos evoluem tornam necessário que novos métodos de avaliação de produção sejam aptos a identificar melhorias implementadas aos novos produtos. Um dos ensaios principais, dentre os de avaliação de produtos de refrigeração, é o ensaio de desempenho de compressores herméticos. Os dois principais fatores que limitam o número de ensaios de desempenho são os custos elevados das bancadas de teste e o tempo de duração dos ensaios. Este trabalho utiliza redes neurais artificiais não lineares autorregressivas para estimar a capacidade de refrigeração de compressores sem a necessidade de realização do ensaio completo, reduzindo, dessa forma, o tempo necessário para realização dos ensaios. Duas abordagens são propostas para o problema, uma com a rede operando em malha aberta e outra com a rede operando em malha fechada. As redes são treinadas com dados obtidos através de ensaio da capacidade de refrigeração através do método F – que mede diretamente a vazão de fluido refrigerante na fase líquida. A rede em malha fechada busca reproduzir o comportamento do compressor em ensaio, enquanto a rede em malha aberta simplesmente estima o valor do instante posterior através dos últimos cinco dados inseridos na rede. As duas abordagens se mostraram adequadas para modelar o ensaio e conseguem, apesar de certo nível de incerteza, estimar os valores de regime permanente através de dados de regime transiente. No entanto a abordagem em malha fechada é a que se mostra mais interessante do ponto de vista de economia de tempo de ensaio, pois estima a partir das primeiras cinco médias móveis todo o comportamento da rede. Enquanto a abordagem em malha aberta faz a estimativa sempre a partir das cinco médias móveis anteriores do ensaio.

Palavras-chave: Redes Neurais Artificiais. Compressores. Refrigeração. Capacidade de Refrigeração. Inferência.

LISTA DE FIGURAS

Figura 1: Neurônio biológico.	35
Figura 2: Modelo de neurônio não linear.....	36
Figura 3: Transformação afim produzida pela presença de um bias.	37
Figura 4: Gráfico da função heavyside.	38
Figura 5: Gráfico da função linear por partes.	39
Figura 6: Gráfico da função sigmoide para parâmetro de inclinação a.	39
Figura 7: Rede alimentada adiante. Destaque para a apresentação das camadas intermediária e de saída.	40
Figura 8a e 8b: Arquitetura MLP e BMLP , com duas camadas intermediárias.	41
Figura 9: Redes neurais recorrentes.....	42
Figura 10: Estrutura da rede de malha aberta.	46
Figura 11: Gráfico dos ensaios de capacidade de refrigeração em função do tempo.	47
Figura 12: Regressão linear mostrando a correlação dos dados de saída da rede os alvos em todas as fases de treinamento.	51
Figura 13: Correlação entre os dados de saída da rede e os alvos para o caso inédito apresentado.	52
Figura 14: Gráfico de comparação entre as saídas da rede e os alvos para malha aberta.	53
Figura 15: Correlação da saída da rede em malha fechada com os ensaios usados no treinamento.	54
Figura 16: Correlação da saída da rede em malha fechada e os alvos para o caso inédito apresentado.	55
Figura 17: Gráfico de comparação entre as saídas da rede e os alvos para rede em malha fechada.	56

LISTA DE ABREVIATURAS E SIGLAS

RNA	Rede Neural Artificial
RNN	Rede Neural Natural
IA	Inteligência Artificial
Adaline	<i>Adaptative Linear Element</i> (Elemento Linear Adaptativo)
Madaline	<i>Multiple Adaptative Linear Element</i> (Múltiplo Elemento Linear Adaptativo)
ART	<i>Adaptative Ressonance Theory</i> (Teoria de Ressonância Adaptativa)
MLP	<i>Multi Layer Perceptron</i> (<i>Perceptron</i> de multiplas camadas)
BMLP	<i>Bridged Multi Layer Perceptron</i> (<i>Perceptron</i> multiplas camadas com pontes)
COP	<i>Coefficient of Performance</i> (Coeficiente de desempenho)
W	watts
NARNET	<i>Nonlinear Autoregressive Network</i> (Rede Não-linear Autorregressiva)

Sumário

1 INTRODUÇÃO	27
1.1 CONTEXTUALIZAÇÃO	27
1.2 OBJETIVO GERAL	28
2 REVISÃO DA LITERATURA	30
2.1 O QUE É UMA RNA?	30
2.2 HISTÓRICO	31
2.3 MODELO DE NEURÔNIO	34
2.3.1 Funções de ativação	36
2.4 ARQUITETURAS DE REDE	38
2.5 PROCESSOS DE APRENDIZAGEM	41
2.6 TIPOS DE REDE E ALGORITMOS UTILIZADOS	42
3 PROCEDIMENTOS EXPERIMENTAIS	43
3.1 PROPOSTA, ESTRUTURA NEURAL E PROGRAMAÇÃO	43
3.1.1 Programação	45
3.1.2 Pré-tratamento de Dados	46
3.1.3 Criação da Rede e Definição de seus parâmetros de Treinamento	47
4 ANÁLISE DOS RESULTADOS	49
4.1 RESULTADOS DA REDE PROPOSTA	49
4.1.1 Resultados do treinamento	49
4.1.2 Resultados da rede de malha fechada	52
5 CONSIDERAÇÕES FINAIS	56
REFERÊNCIAS	58

1 INTRODUÇÃO

Os processos industriais e a forma com que os produtos evoluem tornam necessário que novos métodos de avaliação de produção sejam desenvolvidos para identificar melhorias implementadas aos novos produtos. Um dos ensaios principais, dentre os de avaliação de produto na indústria de sistemas de refrigeração, é o ensaio de desempenho de compressores herméticos. Os dois principais fatores que limitam o número de ensaios de desempenho são os custos elevados das bancadas de teste e o tempo de duração dos ensaios (HENKLEIN, 2006).

Este trabalho propõe uma forma de reduzir o tempo desse tipo de ensaio com base numa ferramenta de inteligência artificial, mais especificamente redes neurais artificiais (RNA), que faça a correlação dos dados de regime transiente com o valor de regime permanente. Com isso espera-se poder concluir o ensaio ainda na fase transitória, sem a necessidade de aguardar o assentamento de todas as variáveis envolvidas para que possam ser realizadas estimativas para os valores em regime permanente.

1.1 CONTEXTUALIZAÇÃO

Refrigeração é a arte de resfriar corpos sólidos ou fluidos para temperaturas abaixo das disponíveis no ambiente, em determinado tempo e local (GOSNEY, 1982). Para atender às diversas necessidades provenientes da evolução da sociedade e do estilo de vida adotado por ela, esta importante área da engenharia vem sendo aprimorada no decorrer dos últimos séculos. Atualmente, é impossível dissociar as atividades desenvolvidas pela sociedade das atividades desenvolvidas pelas tecnologias de refrigeração, seja no resfriamento e conservação de alimentos, na climatização de ambientes, na medicina, ou nas atividades industriais (WALTRICH, 2008).

Podem-se dividir as atividades de refrigeração em três aplicações: refrigeração industrial; condicionamento de ar; refrigeração doméstica. As três atividades apesar de apresentarem características semelhantes tanto no processo quanto nos componentes têm motivações diferentes para as suas aplicações. As atividades industriais se referem às temperaturas entre -70°C até 15°C , podendo chegar a temperaturas inferiores na indústria da criogenia (STOECKER; JABARDO, 2002).

Os processos que envolvem o condicionamento de ar são classificados com relação ao seu objetivo: conforto térmico ou

industrial. Enquanto o conforto térmico visa proporcionar às pessoas sensação térmica agradável, o industrial visa satisfazer condições de processos. As grandes diferenças entre as duas atividades são os níveis de temperatura, as exigências de controle da umidade e o elevado índice de filtragem e remoção de contaminantes nas atividades industriais (STOECKER; JABARDO, 2002).

A refrigeração doméstica, compreendida basicamente pelos refrigeradores e *freezers*, é a que apresenta maior importância econômica na refrigeração. Estima-se que haja em operação atualmente mais de um bilhão de refrigeradores domésticos no mundo (PROCEEDINGS OF THE 6TH INTERNATIONAL CONFERENCE ON COMPRESSORS AND COOLANTS, 2006). Estes mais de um bilhão de refrigeradores têm um impacto significativo no consumo energético mundial principalmente devido à sua baixa eficiência, cerca de 15% da eficiência de Carnot (WALTRICH, 2008). Logo, eventuais melhorias na eficiência dos componentes poderiam trazer inúmeros benefícios à matriz energética mundial e por consequência ao meio ambiente.

Como a maioria dos sistemas de refrigeração se baseia no princípio de compressão e expansão de fluido com mudança de fase, o compressor tem papel de suma importância no circuito de refrigeração.

O dispositivo responsável por realizar a circulação de fluido pela tubulação de um sistema através do aumento de pressão é o compressor. Inúmeros aspectos construtivos são possíveis. Os compressores alternativos utilizam de um dispositivo do tipo biela manivela acoplado ao pistão que aumenta a pressão conforme o volume da câmara é reduzido. Os compressores rotativos apresentam um rotor com palhetas móveis montados dentro da carcaça com um determinado deslocamento de excentricidade. Assim ao rotacionar, as palhetas diminuem o volume e comprimem o fluido. Para serem capazes de realizar trabalho os compressores devem conter uma fonte de energia mecânica para os elementos que forçam a circulação de fluido em seu interior. Tal trabalho pode ser disponibilizado por um motor elétrico que converte a energia elétrica em energia mecânica. Desta forma o fluido é capaz de vencer as perdas de carga e realizar as trocas de calor para que o circuito de refrigeração cumpra o seu papel (RODRIGUES, 1991; HENKLEIN, 2006).

Tal componente evoluiu junto aos aparelhos refrigeradores até os dias de hoje, forçando os fabricantes a executar melhorias construtivas de forma a atender a evolução das exigências do mercado. A identificação e quantificação das melhorias são feitas através da análise de uma série de parâmetros obtidos através de ensaios específicos. O

ensaio de desempenho busca determinar a capacidade de refrigeração, a potência elétrica ativa consumida, a eficiência isentrópica e o coeficiente de desempenho, com o compressor submetido a determinadas condições preestabelecidas por normas tais como: ISO 917, ASHRAE 23, NBR 15826, ARI 540 (HENKLEIN, 2006).

Os ensaios de desempenho são de extrema importância e são realizados com grande frequência dentro de uma indústria de compressores. Os investimentos em infraestrutura são muito altos, pois tais testes são realizados em bancadas específicas que chegam a custar centenas de milhares de dólares. Além disso, o tempo de testes prejudica o número de execuções possíveis, pois cada bancada é capaz de ensaiar apenas um compressor por vez e os tempos médios de ensaio beiram as cinco horas. Tais problemas diminuem a segurança estatística fornecida e também diminuem a agilidade nas avaliações de melhorias implementadas ao produto (HENKLEIN, 2006).

1.2 OBJETIVO GERAL

O objetivo desta monografia é usar uma ferramenta de inteligência artificial (IA), mais especificamente, redes neurais artificiais (RNA), para estimar a capacidade de refrigeração em regime permanente. A partir dos dados medidos durante o transitório. Como um trabalho inicial pretende-se avaliar o uso de redes neurais artificiais autorregressivas para tais estimativas.

1.3 JUSTIFICATIVA

Como descrito na seção **Erro! Fonte de referência não encontrada.**, os ensaios de desempenho de compressores são realizados em bancadas de custo elevado e consomem muito tempo. Os testes com RNAs devem ser capazes de reduzir o tempo de teste em compressores e seguir os dados experimentais, sem a necessidade de aguardar toda a realização do ensaio. Com a inferência dos valores finais do ensaio (em regime) a partir dos dados medidos nas fases iniciais do ensaio, será possível reduzir significativamente o tempo de ensaio para ensaios que não necessitam seguir normas internacionais, como é o caso dos ensaios internos para avaliação de melhoria de eficiência em protótipos.

Neste trabalho, os ensaios não serão acompanhados pela ferramenta neural em tempo real, mas espera-se que isso possa ser

possível durante a realização dos ensaios em campo. Para este trabalho, a incerteza trazida pela estimativa será avaliada como satisfatória ou não ao obterem-se os resultados e compará-los com os dados reais dos testes.

2 REVISÃO DA LITERATURA

2.1 O QUE É UMA RNA?

As redes neurais artificiais (RNAs) foram inspiradas desde o início na forma como o cérebro humano processa informações. A complexidade na sua forma de processamento, aliada à não linearidade e ao paralelismo inerentes à sua estrutura, permitem aos cérebros efetuar processos ainda não possíveis por computadores ou mesmo realizar uma determinada tarefa em tempos muito menores do que um computador convencional (HAYKIN, 2001).

Os processadores atuais realizam processamento de informação basicamente efetuando operações aritméticas simples, o que os confere características muito boas para processar contas para as quais foram programados, como: somas, multiplicações, divisões e subtrações (STALLINGS, 2010). No entanto uma RNA é uma técnica de IA que se caracteriza por usar a experiência adquirida pela rede num processo de aprendizagem como forma de tratar a informação. Isso lhe confere o poder de gerar dados de saída mesmo que a entrada não seja exatamente o que lhe foi mostrado no processo de aprendizagem. Logo uma RNA é capaz de generalizar e extrair relações em um conjunto de dados mesmo que aparentemente desconexos. Dessa forma, uma RNA modela uma determinada tarefa ou função de interesse, o que a possibilita resolver problemas complexos de grande escala que atualmente não são possíveis de serem tratados. As RNAs são simuladas através de componentes eletrônicos ou por programação em um computador digital (HAYKIN, 2001). Dessa forma,

Uma rede neural¹ é um processador maciçamente paralelo distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-la disponível para uso (HAYKIN, 2001, p. 28).

¹ Haykin (2001) usa o termo rede neural como sinônimo para rede neural artificial e o mesmo será realizado neste trabalho.

2.2 HISTÓRICO

O primeiro trabalho da era moderna das redes neurais começou com McCulloch e Pitts. McCulloch foi um psiquiatra e Pitts um prodígio matemático. Juntos descreveram um modelo matemático inicial que unificava os estudos de neurofisiologia e da lógica matemática. Ao assumir que seu modelo fosse do tipo “tudo ou nada”, com número suficiente de unidades e com conexões sinápticas ajustadas, operando de forma síncrona, mostraram que a rede realizaria a computação de qualquer função computável² (BARRETO, 1999). Em 1949 Hebb apresentou pela primeira vez uma formulação explícita de uma regra de aprendizagem fisiológica para a modificação de sinapses. Hebb em *The Organization of Behavior*, propôs que a conectividade do cérebro se modificava conforme um organismo ia aprendendo tarefas funcionais. Hebb também propôs que a eficiência de uma sinapse é dada conforme a utilização dos neurônios por aquela sinapse (HEBB, 1947 apud HAYKIN, 2001). Na década de 1950 Rochester, Holland, Haight e Duda pela primeira vez tentaram usar simulação computacional para testar uma teoria neural com base no postulado de aprendizagem de Hebb (ROCHESTER et al., 1956, apud HAYKIN, 2001). Uttley na mesma década mostrou que uma rede neural pode aprender a classificar um conjunto simples de padrões binários. Mais tarde, em 1979, Uttley formulou a hipótese de que a eficiência de uma sinapse variável do sistema nervoso depende da relação estatística entre os estados flutuantes em ambos os lados daquela sinapse (UTTLEY, 1966 apud HAYKIN, 2001).

Muito foi desenvolvido em mais artigos, teses e livros publicados nas décadas de 1950 e 1960 sobre o que tratamos hoje como redes neurais artificiais. Destacam-se os trabalhos de Gabor (1960 apud HAYKIN, 2001) que criou um filtro adaptativo não-linear capaz de aprender através da alimentação da máquina por amostras de um processo estocástico, juntamente com a função alvo que a máquina deveria produzir; Rosenblatt (1958 apud HAYKIN, 2001) em seu trabalho sobre o perceptron, que introduziu um método inovador de aprendizagem supervisionada, comprovada por ele mesmo posteriormente; Widrow e Hoff (1960 apud HAYKIN, 2001) com a ideia de algoritmo do mínimo quadrado médio e a formulação a partir

² Uma função é dita computável se um algoritmo é capaz de calcular o valor desta numericamente.

desse do Adaline (elemento linear adaptativo); Widrow (1962 apud HAYKIN, 2001) novamente com uma das primeiras RNAs em camadas treináveis com múltiplos elementos adaptativos, Madaline (multiplo-adaline); Por fim Minsky e Papert (1969 apud HAYKIN, 2001) provaram matematicamente que existiam limitações fundamentais nos cálculos que poderiam ser realizados por perceptrons de camada única e que tais limitações eram expansíveis à versão de múltiplas camadas.

Com os trabalhos de Minsky e Papert mostrando limitações básicas na área e devido à falta de recursos tecnológicos e financeiros as pesquisas sobre redes neurais foram descontinuadas nos anos 1970. Muitos dos pesquisadores abandonaram a área durante essa década e buscaram outros segmentos. No entanto em 1980 os trabalhos foram retomados com importantes contribuições. Grossberg (1980 apud HAYKIN, 2001), baseando-se no seu próprio trabalho anterior sobre aprendizagem competitiva (GROSSBERG, 1972; 1976 apud HAYKIN, 2001), estabeleceu a teoria da ressonância adaptativa (ART, Adaptive Resonance Theory). Hopfield, em 1982 criou um novo modo de entender a computação executada por redes recorrentes com conexões sinápticas simétricas e estabeleceu o isomorfismo entre uma rede recorrente assim definida e o modelo *Ising* utilizado na física estatística. Este modelo de rede atraiu muita atenção nos anos 1980 e ficou conhecida como rede de Hopfield, apesar de outros pesquisadores terem contribuído na origem deste modelo (HOPFIELD, 1982 apud HAYKIN, 2001).

Durante os anos 1980, o trabalho de Kirkpatrick, Gellat e Vecchi com um novo procedimento denominado recozimento simulado tornou possível aos pesquisadores Ackley, Hinton e Sejnowski (1985 apud HAYKIN, 2001) desenvolver a máquina de Boltzmann, que foi a primeira realização bem sucedida de uma rede neural de múltiplas camadas. Mesmo o processo de aprendizagem da máquina de Boltzmann sendo menos eficiente do que o algoritmo de retropropagação (*backpropagation*) ele mostrou que a especulação de Minsky e Papert (1969 apud HAYKIN, 2001), que praticamente extinguiu os trabalhos envolvendo RNA na década de 1970, não estava corretamente embasada. Além dessa importante conquista, a máquina de Boltzmann também embasou o desenvolvimento das redes de crença sigmoide de Neal (1992 apud HAYKIN, 2001). Esta por sua vez conseguiu melhorar significativamente a aprendizagem e ligou as redes neurais às redes de crença sigmoideal.

Barto, Sutton e Anderson publicaram um artigo em 1983 sobre a aprendizagem por reforço que gerou muito interesse no assunto, principalmente na sua aplicação em controle. Especificamente

mostraram que um sistema de aprendizagem por reforço poderia aprender a equilibrar um cabo de vassoura sem a presença de um professor auxiliar. O sistema precisaria apenas de um sinal de insucesso que mostrasse que ele caía quando o cabo ultrapassasse um certo ângulo crítico e que também indicasse com um sinal quando a base chegasse ao final da pista (BARTO; SUTTON; ANDERSON, 1983 apud HAYKIN, 2001). Em 1996, o livro *Neurodynamic Programming* de Bertsekas e Tsitsiklis colocou o aprendizado por reforço sobre uma base matemática apropriada, ligando-a à programação dinâmica de Bellman (BERTSEKAS; TSITSIKLIS, 1996 apud HAYKIN, 2001).

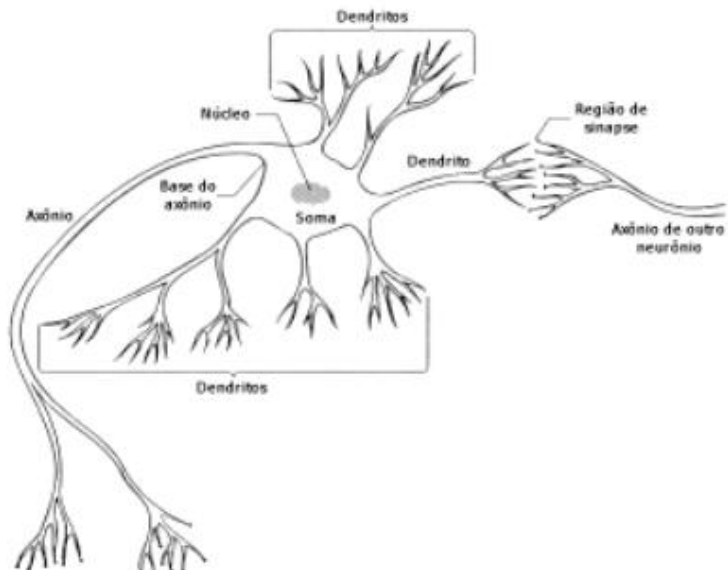
Em 1986, Rumelhart, Hilton e Williams (1986 apud HAYKIN, 2001) desenvolveram o algoritmo de retropropagação (*backpropagation*). O livro editado por Rumelhart e McClelland, *Parallel Distributed Processing: Explorations in the Microstructures of Cognition*, contribuiu para a popularização do algoritmo de retropropagação no treinamento de perceptrons de múltiplas camadas. Linsker (1988 apud HAYKIN, 2001) descreve um novo princípio para a auto-organização em uma rede perceptiva, o que preserva o máximo de informação sobre os padrões de atividade das entradas sujeito às limitações de conexões sinápticas e o intervalo dinâmico das sinapses. Também em 1988, Broomhead e Lowe descrevem um procedimento para o projeto de redes alimentadas adiante (*feedforward*), que servem como alternativa aos perceptrons de múltiplas camadas (BROOMHEAD; LOWE, 1988 apud HAYKIN, 2001). Vapnik e coautores inventaram, no início dos anos 1990, uma classe de redes de aprendizagem supervisionada poderosa do ponto de vista computacional, chamada de máquinas de vetor de suporte, também utilizada para reconhecimentos de padrões (VAPNIK et al., 1988 apud HAYKIN, 2001).

As redes neurais certamente trilham um longo caminho desde os dias iniciais de McCulloch e Pitts. De fato, elas se estabeleceram como um tema interdisciplinar com raízes profundas em neurociências, psicologia, matemática, ciências físicas e engenharia. É desnecessário dizer que elas estão aqui para ficar e que continuarão a crescer em teoria projetos e aplicações. (HAYKIN, 2001, p.69)

2.3 MODELO DE NEURÔNIO

Um neurônio, basicamente, é uma unidade de soma que recebe e combina sinais de outros neurônios através de entradas sinápticas chamadas dendritos. Caso a combinação de sinais vindas dos dendritos seja forte suficiente o neurônio é ativado, produzindo um sinal de saída enviado ao axônio. O axônio se divide e se conecta a milhares de dendritos, que se ligam à outros neurônios. A força entre as ligações sinápticas é que determina a magnitude do sinal que será transmitida. Assim é a força, ou condutância³, da junção sináptica que ao se modificar pode proporcionar maior ou menor facilidade para a condução das sinapses. Essa seria a responsável pelo aprendizado do cérebro (IEEE IECON INTERNATIONAL CONFERENCE, 1995). A estrutura básica de um neurônio biológico é mostrada na Figura 1.

Figura 1: Neurônio biológico.




Fonte: Souza (2004).

³ Inverso de resistência.

A simulação computacional do modelo cerebral recai geralmente sob a forma de uma RNA que consiste efetivamente de elementos básicos de processamento de dados, ou seja, neurônios artificiais, ligados entre si. Os neurônios artificiais são análogos aos neurônios biológicos. São formados de três elementos básicos (Figura 2): as sinapses, o somador e uma função de ativação. As sinapses assim como no modelo neural natural são responsáveis pelas entradas dos sinais do somador. As forças entre as ligações sinápticas são representadas através de pesos sinápticos que multiplicam os sinais de entrada. O somador soma os sinais devidamente ponderados pelos pesos sinápticos o que constitui um combinador linear. A função de ativação tem o papel de restringir a amplitude do sinal de saída. O modelo neural ainda pode incluir um bias aplicado externamente – esse tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação (HAYKIN, 2001).

Figura 2: Modelo de neurônio artificial não linear.



Fonte: Haykin (2001).

Matematicamente descreve-se um neurônio k através das equações (1) e (2):

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

e

$$y_k = \varphi(u_k + b_k) \quad (2)$$

Onde x_1, x_2, \dots, x_m são os sinais de entrada; $w_{k1}, w_{k2}, \dots, w_{km}$ são os pesos sinápticos do neurônio k ; u_k é a saída do combinador linear devido aos sinais de entrada; b_k é o bias; φ é a função de ativação do neurônio; y_k é a saída do neurônio. Adicionalmente com a soma do bias à combinação linear define-se o campo local induzido, v_k , que modifica o sinal de saída do somador conforme a equação:

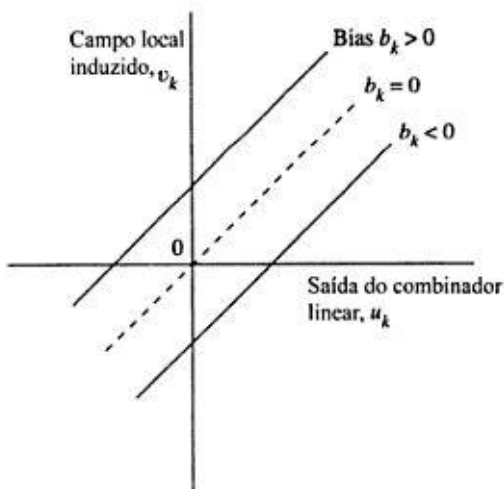
$$v_k = u_k + b_k. \quad (3)$$

Desta forma,

$$y_k = \varphi(v_k). \quad (4)$$

A figura 3 mostra o comportamento do sinal de saída do combinador linear de acordo com a natureza do campo local induzido (HAYKIN, 2001).

Figura 3: Transformação afim produzida pela presença de um bias.



Fonte: Haykin (2001).

2.3.1 Funções de ativação


A função de ativação é responsável por normalizar as saídas da combinação linear para uma saída do neurônio, geralmente dentro do intervalo de $[-1, +1]$ ou $[0, 1]$. Sendo assim o sinal fornecido pela função de ativação é uma forma a mais de processamento da rede neural. De

forma análoga ao que ocorre no neurônio biológico a função de ativação informa ao próximo neurônio da camada o quão sensibilizado foi pelo sinal de entrada (HAYKIN, 2001). Haykin (2001) descreve três tipos básicos de função de ativação.

a) Função limiar, que é uma função *heaviside*⁴. Onde:

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

Figura 4: Gráfico da função heaviside.



Fonte: Haykin (2001).


O modelo que adota esta função de ativação é conhecido como modelo de McCulloch-Pitts. A saída de um neurônio para tal modelo assume o valor 1, se o campo local induzido (v_k), for não-negativo e 0 caso contrário. A figura 4 ilustra graficamente esta condição.

b) Função linear por partes. As funções lineares por partes, representadas graficamente na figura 5 com fator de ampliação unitário é basicamente uma aproximação de um amplificador não-linear. Nesta, temos que:

$$y_k = \begin{cases} 1, & v \geq 1/2 \\ v, & 1/2 > v > -1/2 \\ 0, & v \leq -1/2 \end{cases}$$

⁴ A função *heaviside* também é conhecida por função degrau.

Figura 5: Gráfico da função linear por partes.




Fonte: Haykin (2001).

- c) Função sigmoide. Esta função de ativação é a forma mais comum utilizada na construção de redes neurais artificiais segundo Haykin (2001). É uma função estritamente crescente que apresenta tanto comportamento linear como não linear (figura 6). Um exemplo de função sigmoide é a função logística, definida por:

$$\varphi(v) = \frac{1}{1+e^{(-av)}} \quad (5)$$

onde a é o parâmetro de inclinação da função sigmoide.

Figura 6: Gráfico da função sigmoide para parâmetro de inclinação a .



Fonte: Haykin (2001).


O sucesso e poder de uma abordagem está ligado, primeiro, à sua habilidade de capturar e representar, através de um modelo formal ou de uma representação abstrata, as características do sistema sob estudo.

Segundo, sobre a capacidade do modelo formal de permitir a obtenção de novos teoremas, conjecturas, análises do sistema e projeto (AZEVEDO; BRASIL; OLIVEIRA, 2000).

2.4 ARQUITETURAS DE REDE

A forma com que se estabelecem as ligações entre os neurônios de uma RNA está intimamente ligada ao algoritmo de aprendizado usado para treinar a rede. Frequentemente as RNAs são representadas em estruturas de camadas (figura 7) que se dividem em: camada de entrada, que tem a função apenas de fornecer os dados de entrada da rede para a próxima camada em que se liga, sem fornecer qualquer processamento à RNA; camada intermediária ou oculta, que intervém entre a camada de entrada e a camada de saída, processando efetivamente a maior parte do sinal; camada de saída, que além de ter o papel de processamento menor que a camada intermediária, também deve ser capaz na sua saída de apresentar os resultados (AZEVEDO; BRASIL; OLIVEIRA, 2000).

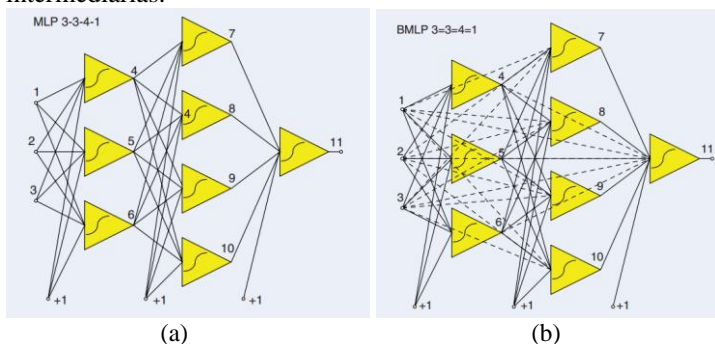
Figura 7: Rede alimentada adiante. Destaque para a apresentação das camadas intermediária e de saída.



Fonte: Haykin (2001).

Existem basicamente duas topologias de RNA, redes alimentadas adiante, e redes recorrentes (HAYKIN, 2001). As redes alimentadas adiante, também conhecidas como diretas podem ser redes de perceptron de múltiplas camadas (MLP)⁵ (figura 8a) ou redes de perceptron de múltiplas camadas em ponte (BMLP)⁶ (figura 8b). As redes de BMLP são mais poderosas que as redes MLP, pois elas permitem as ligações cruzadas entre neurônios de camadas distintas, apesar de as redes de MLP serem mais populares entre os pesquisadores. Dentro dessas duas variedades de redes alimentadas adiante existe uma grande variedade de arquiteturas que podem ser montadas (WILAMOWSKI, 2009).

Figura 8a e 8b: Arquitetura MLP e BMLP , com duas camadas intermediárias.




Fonte: Wilamowski (2009).

As redes recorrentes (figura 9) se diferenciam das redes alimentadas adiante simplesmente por terem pelo menos um laço de realimentação. Duas redes recorrentes têm particular importância para o estudo de RNAs: as redes de Hopfield e as redes bidirecionais de Kosko. A presença de laços de realimentação nas redes recorrentes tem um impacto profundo na capacidade de aprendizagem e no desempenho da rede. Os laços de realimentação ainda apresentam ramos particulares compostos de elementos de atraso unitário, o que resulta num comportamento dinâmico não linear (HAYKIN, 2001; AZEVEDO; BRASIL; OLIVEIRA, 2000).

⁵ Do inglês *multilayer perceptron* (MLP).

⁶ Do inglês *bridged multilayer perceptron* (BMLP).

Figura 9: Redes neurais recorrentes.



Fonte: Haykin (2001).

2.5 PROCESSOS DE APRENDIZAGEM

Aprendizagem é um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre (HAYKIN, 2001, p. 75)

A característica fundamental para uma RNA é a habilidade de aprender a partir do ambiente em que está inserida e de melhorar o seu desempenho através da aprendizagem. O aprendizado incorpora a rede, a capacidade de generalização e de aquisição de conhecimento, tornando disponível aplicá-los futuramente. Os processos de aprendizagem pelos quais a RNA passa para incorporar tais propriedades são formas de ajustes de pesos sinápticos denominados de treinamento.

Existem inúmeras alternativas para treinar as RNAs. Entre elas se destacam as técnicas de aprendizado por reforço, que consistem em reforçar os bons resultados gerados pela rede e penalizar os maus resultados. Logo, quando o resultado da rede é um resultado indesejável a rede altera os pesos sinápticos a fim de corrigir o mau funcionamento. Quando o resultado é desejável, nenhuma atitude é tomada. Os algoritmos de treinamento são responsáveis por ajustar os pesos sinápticos durante o treinamento (LIMA, 2005).

O processo de aprendizagem é obtido através de regras de aprendizagem que implicam numa determinada sequência de eventos. A

RNA, é primeiro, estimulada por um ambiente. Depois, sofre modificações nos seus pesos sinápticos como forma de resultado da sua estimulação. Por fim, responde de uma nova maneira ao ambiente, graças às modificações efetuadas.

Os paradigmas de aprendizagem comumente adotados são da forma: supervisionada e não supervisionada. No caso supervisionado, a rede é treinada com o auxílio de um supervisor que conhece o ambiente e apresenta um conjunto de dados de entrada e as respectivas saídas. Após o treinamento é desejado que o conhecimento do supervisor seja transmitido à rede. Dessa forma, o supervisor é removido e a rede deve ser capaz de lidar com as novas situações sozinha (LIMA, 2005).

No caso não supervisionado, não existe a presença de um supervisor durante o treinamento. Para treinar a rede, então, a rede se baseia em seus próprios critérios estatísticos, envolvendo processos de competição e colaboração entre os neurônios da rede.

2.6 TIPO DE REDE E ALGORITMO UTILIZADO

As redes neurais dinâmicas, que incluem linhas de atraso são usadas para filtragem não-linear e previsão. Há muitas aplicações para a previsão. Por exemplo, um analista financeiro pode querer prever o valor futuro de uma ação, obrigação ou outro instrumento financeiro. Um engenheiro pode querer prever o fracasso iminente de um motor a jato. Os modelos preditivos são também utilizados para a identificação do sistema (ou modelagem dinâmica), atividade que permite a construção de modelos dinâmicos para sistemas físicos. Esses modelos são importantes para a análise, simulação, monitoramento e controle de uma variedade de sistemas (BEALE; HAGAN; DEMUTH, 2013).

Foi utilizado neste trabalho um modelo de previsão de série de tempo não linear com uma rede neural dinâmica conhecida por NARNET (*Nonlinear Autoregressive Network* – Rede Autorregressiva Não Linear). A rede proposta é utilizada para realizar uma espécie de filtragem dinâmica, em que os valores passados de uma ou mais séries de tempo são usados para prever valores futuros de forma recorrente.

O algoritmo de treinamento utilizado foi o algoritmo de retropropagação do erro baseado na função de atualização de pesos e estado de bias de acordo com a otimização de Levenberg-Marquardt.

3 PROCEDIMENTOS EXPERIMENTAIS

Um compressor de refrigeração pode ser analisado de várias formas e cada uma conta com peculiaridades e procedimentos: capacidade frigorífica, consumo e coeficiente de desempenho (COP).

A capacidade frigorífica de um compressor para refrigeração segundo a norma ABNT NBR 15826 (2010, p. 1) é “o produto da vazão de massa do refrigerante deslocado pelo compressor, obtido no ensaio, com a diferença de entalpia específica do refrigerador no ponto de medição na sucção do compressor e a entalpia específica do líquido saturado à temperatura que corresponde à pressão de descarga de ensaio no ponto de medição na saída do compressor”. Tal norma define os pontos de medição de entalpia com o objetivo de evitar que não idealidades do sistema de medição influenciem no resultado do ensaio que caracteriza o compressor.

O consumo é definido por Poletto (2006, p. 28) como: “a medida da potência absorvida pelo compressor dada uma condição de operação” e o coeficiente de desempenho como a razão entre a capacidade e o consumo.

Segundo a norma ISO 917 - que normatiza os ensaios de compressores a fim de determinar a capacidade de refrigeração, o consumo, a eficiência isentrópica e o coeficiente de desempenho do compressor - os resultados dos ensaios que realmente têm valor para determinar esses parâmetros de desempenho dos compressores são os dados de regime permanente. No entanto os dados de regime transitório não são totalmente desprezíveis. Esses dados dizem muito sobre o processo apesar de não serem levados em consideração pela norma ISO 917. Neste trabalho serão usados os dados de regime transitório para obter informações a respeito do regime permanente através de um processo de inferência empregando RNA.

3.1 PROPOSTA, ESTRUTURA NEURAL E PROGRAMAÇÃO

A partir de uma base de dados de ensaios realizados conforme a norma ISO 917, foram obtidos uma série de dados para se avaliar os compressores. Entre os parâmetros avaliados a capacidade de refrigeração será o parâmetro de interesse, para a avaliação realizada neste trabalho. A escolha dessa variável se deveu principalmente a dois motivos: (a) a grandeza é fundamental para realização da avaliação do desempenho energético de um compressor e (b) a medição da grandeza

é realizada de forma indireta e o período de transitório associado à dinâmica da grandeza é o maior entre as variáveis tidas como resultado do ensaio de desempenho.


Existem nove formas de medir a capacidade de refrigeração de um compressor (HENKLEIN, 2006). A norma ISO 917 estipula que sejam usados no mínimo dois métodos. Dessa forma o método A – calorímetro de fluido secundário e F – medidor de fluxo de massa na fase líquida foram usados nos testes.

A proposta da rede neural é inferir sobre os valores de regime permanente da capacidade de refrigeração medida com o método F – medidor de fluxo de massa na fase líquida através dos dados de regime transiente. O sistema modelado apresenta características tipicamente dinâmicas, ou seja, a saída é função dos dados instantâneos e da sequência histórica de dados. Dessa forma a estrutura proposta para a rede neural será de uma rede dinâmica não linear alimentada adiante para a primeira abordagem e recorrente num segundo momento.

A arquitetura da rede segue de acordo com a proposta estabelecida, usando apenas um neurônio na camada de entrada, representando a capacidade de refrigeração (figura 10). O número de neurônios na camada intermediária será a menor possível, de modo a minimizar os recursos computacionais para treinamento e será definida com base nos resultados experimentais obtidos. Na camada de saída haverá também apenas um neurônio que representará o valor do próximo dado da série (figura 10).

Duas redes serão propostas neste trabalho. A primeira será uma rede dinâmica não linear em malha aberta que realizará a função de estimar o próximo dados conhecidos até certo instante. A segunda rede oferece um desafio maior, pois a partir dos dados de entrada ela deve ser capaz de estimar o valor de regime permanente, reproduzindo passo a passo o comportamento da rede treinada em malha aberta. Essa forma de rede é apresentada na revisão da literatura como redes neurais recorrentes.

Figura 10: Estrutura da rede de malha aberta.



3.1.1 Programação

Neste trabalho, assim como em outros da mesma linha (STEINBACH 2008; LIMA, 2010; HENKLEIN, 2006) usou-se do potencial do programa Matlab para processar e armazenar as informações de entrada da rede e da ferramenta de redes neurais do próprio programa para as etapas de criação da rede, treinamento, validação e teste.


O programa escrito seguiu as quatro etapas sugeridas por Steinbach (2008), que sugere que o programa contenha: importação dos dados dos ensaios para o Matlab; manipulação dos dados para formação dos conjuntos de treinamento; definição das características da RNA; gráficos para avaliação da rede treinada.

Sendo assim a primeira parte do programa importa os dados diretamente dos arquivos de texto que contém os dados de capacidade de refrigeração medidas a partir do método F realizados em compressores de refrigeração. Com os dados dos ensaios armazenados é definido o grupo de dados para treinamento da rede, validação e teste. Esses dados são pré-processados, conforme discutido na próxima seção. Na sequência a rede é criada definindo-se os parâmetros de treinamento discutidos posteriormente na seção 3.1.3. Por fim apresenta-se os resultados da rede no capítulo 4.

3.1.2 Pré-tratamento de dados

Como o ensaio de capacidade de refrigeração realizado através do método F – medidor de fluxo de massa na fase líquida – está sujeito a dados que podem apresentar ruídos que levem ao mau treinamento da rede neural, foi necessário utilizar um pré-tratamento dos dados. Dessa forma para se captar a essência do comportamento da rede, minimizando o efeito do ruído, optou-se por pegar uma média móvel de cinco dados como sendo a entrada de um instante. Adicionalmente, os dados foram reamostrados, de modo a aumentar o tempo entre duas amostras consecutivas. A reamostragem foi realizada com um período de amostragem vinte vezes maior que o período original. Os dados obtidos a partir do método F foram tomados a cada 10 segundos, logo o dado de entrada da rede representa a média da capacidade de refrigeração de 50 segundos de ensaio. Na sequência após 200 s capta-se novamente a média do instante 200 s ao 250 s e assim por diante até o teste chegar a 5000 segundos (83,3 minutos). Após os 5000 s considerou-se que os testes chegaram ao regime permanente, devido à pequena variação dos valores se comparados aos valores de regime transiente. Essa não é a definição formal de regime permanente adotada pelas normas, mas para este primeiro estudo essa suposição simplificou bastante a tarefa de tratamento dos dados. Os primeiros 2100 segundos (35 minutos) também foram negligenciados para permitir que a rede não reproduzisse a informação anterior a esse tempo (figura 11).

Figura 11: Gráfico dos ensaios de capacidade de refrigeração em função do tempo.



Após importação, agrupamento e tratamento dos dados de entrada usou-se da função *preparats* do Matlab para preparar as séries de dados de entrada e alvos para a simulação e o treinamento da rede. A função desloca automaticamente as entradas e alvos das séries temporais de acordo com o que se necessite para preencher a camada inicial de estados com as informações atual e atrasadas dos dados de entrada.

3.1.3 Criação da rede e definição de seus parâmetros de treinamento

A partir da arquitetura definida criou-se uma RNA dinâmica não linear de malha aberta que infere somente o próximo valor de capacidade de refrigeração, levando em consideração a evolução da grandeza até o instante atual. Os únicos parâmetros que foram alterados para tentar obter um melhor comportamento foram os números de neurônios da camada intermediária e o número de operadores de atraso. Os outros parâmetros da rede como: algoritmo de treinamento, número máximo de épocas de treinamento, máximo de falhas de validação e erro médio quadrático, foram mantidos constantes.

O algoritmo de treinamento utilizado foi do tipo retropropagação. Mais especificamente foi o utilizado o algoritmo Levenberg-Marquardt, que segundo Ranganathan (2004) é o algoritmo de otimização mais amplamente utilizado e o método mais rápido para treinamento de redes neurais diretas de tamanho moderado, ou seja, redes da ordem de centenas de pesos segundo Lima (2005).

Os demais parâmetros apresentados, ou seja, aqueles cujos valores não foram alterados, são essencialmente voltados a definir condições de parada para o algoritmo de treinamento. O número máximo de épocas de treinamento estabelece a quantidade de vezes que o algoritmo de treinamento irá expor o conjunto de dados para a rede neural definir os pesos sinápticos. O erro médio quadrático é o erro máximo aceitável calculado pelo algoritmo de treinamento para um dado conjunto de treinamento. Os dois parâmetros segundo Steinbach (2008) são subjetivos, uma vez que não se sabe anteriormente o número de iterações que a rede deverá fazer para convergir ao menor erro, tão pouco se sabe qual o erro mínimo que será encontrado. A validação, no entanto, é o parâmetro que garante que a rede não está perdendo a capacidade de generalização ao decorar os dados de treinamento.

Sendo assim, utilizou-se o número de épocas de treinamento como 1000; o erro médio quadrático como sendo zero; e o número máximo de falhas de validação como 50. A escolha desses dados foi

embasada no trabalho de Lima (2010), que faz a escolha com dados muito próximos para uma série de testes.

O número de ensaios que foram tratados e apresentados para a rede foi 100. Desses dados, 70% foram usados para treinamento, 15% para validação e 15% para teste. O número de iterações que a rede usou até que atingisse número máximo de falhas de validação foi 119.

4 ANÁLISE DOS RESULTADOS

Conforme anunciado na seção 3.1.3 uma série de testes foram realizados para identificar qual seria o número de neurônios da camada intermediária e o número de operadores de atraso utilizados na rede. Sendo assim foram testadas redes de 3 a 20 neurônios na camada intermediária, para operadores de atraso de 2 a 5. Para cada teste variou-se primeiramente o número de neurônios da camada intermediária, mantendo fixo o número de operadores de atraso. Após realizar os ensaios de 3 a 20 neurônios na camada intermediária mudou-se o número de operadores de atraso e repetiu-se o experimento.

Os testes mostraram que a rede que apresentou menor erro quadrático médio e melhor correlação de dados foi com 3 neurônios na camada intermediária. Outras redes apresentaram desempenho próximo, no entanto optou-se pela rede com menor número de neurônios na camada intermediária. O número de operadores de atraso foi crucial para a rede reduzir o erro e melhorar a correlação de dados de entradas e saídas, tanto em malha aberta quanto em malha fechada. A rede que apresentou melhor desempenho foi com cinco operadores de atraso, ou seja, inferiu-se o dado do próximo ponto a partir dos últimos 5 dados de capacidade de refrigeração.

4.1 RESULTADOS DA REDE PROPOSTA

4.1.1 Resultados do treinamento

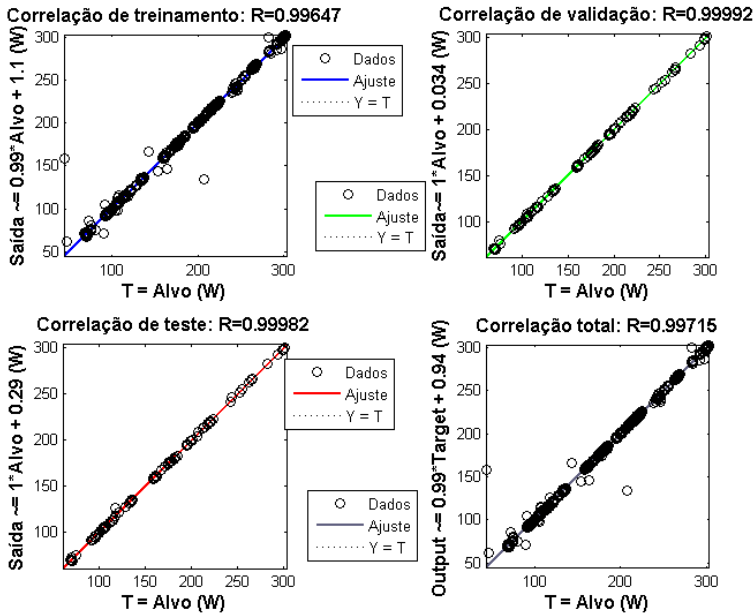
Foram propostas duas abordagens de rede para estimar a capacidade de refrigeração. A primeira rede opera em malha aberta e foi a rede inicial treinada. Essa rede fez a inferência do próximo valor da capacidade de refrigeração com base nos cinco dados anteriores⁷. A rede apresentou uma ótima correlação de dados entre a entrada e a saída como é possível ver na regressão linear feita automaticamente pelo Matlab para o treinamento na figura 12. Nota-se que em todas as etapas do treinamento que consiste em treinamento propriamente dito, validação e teste, a correlação⁸, R , entre os dados de treinamento da rede

⁷ Lembrando que cada dado representa a média de cinco medições do ensaio e que o próximo dado é tomado após ignorarem-se as próximas 15 medições.

⁸ É uma medida de interdependência entre os dados. Expressa a relação entre as variáveis, nesse caso o quanto os dados de saída da rede se

e os alvos⁹ foi próximo a 1, o que mostra uma elevada correlação entre os dados da saída da rede e os alvos.

Figura 12: Regressão linear mostrando a correlação dos dados de saída da rede os alvos em todas as fases de treinamento.



Um teste com uma amostra não apresentada para a rede foi feito a fim de verificar o comportamento para um caso inédito. A resposta da rede para o caso aleatório apresentado é mostrado nas figuras 13 e 14. É apresentada primeiramente a correlação dos dados de saída da rede frente ao valor alvo (figura 13). Através da linearização nota-se que o valor da melhor reta que descreve o comportamento da rede se mostrou próxima do valor da melhor reta dos dados de entrada. Mesmo havendo uma correlação um pouco inferior à obtida para inúmeros casos apresentados no treinamento, os erros apresentados na figura 14 mostram uma boa capacidade da rede em prever o valor da capacidade nas condições impostas. Como é possível ver, o erro não ultrapassa 0,5

relacionam com os dados reais do ensaio. Para um maior aprofundamento no tema ler Montgomery; Runger (2009).

⁹ Os alvos são os valores reais das saídas apresentadas à rede.

W (watts), o que demonstra que a rede em malha aberta conseguiu extrair a essência do comportamento do ensaio.

A ordem de dados da série não representa uma grandeza física como a saída da rede, pois não faz sentido associar a média de 5 valores em instantes de tempo diferentes a um valor de tempo. Tão pouco o software necessita dessa informação para processar os dados. Dessa forma o significado da ordem de dados da série é unicamente a ordem com que os dados da série foram tomados.

Figura 13: Correlação entre os dados de saída da rede e os alvos para o caso inédito apresentado.

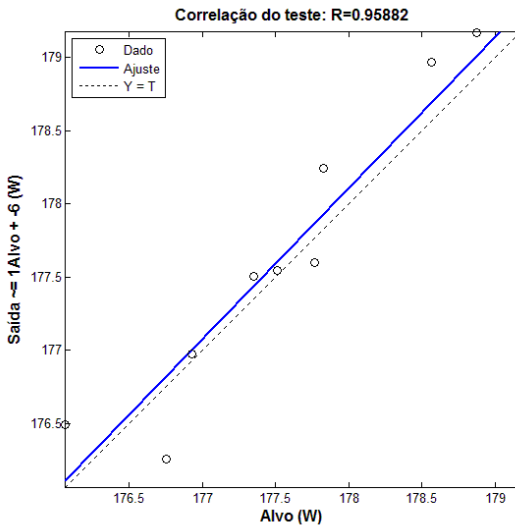



Figura 14: Gráfico de comparação entre as saídas da rede e os alvos para malha aberta.




4.1.2 Resultados da rede de malha fechada

Apesar de resultados de malha aberta mostrarem uma correlação significativa entre os dados de saída e os alvos, eles ainda não são capazes de estimar o valor de regime permanente a partir somente dos dados iniciais fornecidos em forma de atraso. Simplesmente a rede em malha aberta infere a partir dos cinco últimos dados fornecidos pelo tratamento de dados, qual será o próximo ponto.

Para inferir sobre os dados de regime permanente foi proposta uma rede em malha fechada, a qual, a partir dos 5 primeiros dados, fornece saídas que auto alimentam a rede e que têm como pretensão reproduzir o comportamento do ensaio. A rede não foi treinada novamente e a única diferença consiste na utilização das amostras geradas como estimativas pela rede para realizar a estimação dos valores da grandeza até que ela atinja o regime permanente.

Para essa rede, todos os dados usados para treinamento, validação e teste são apresentados como casos inéditos de teste e a correlação de dados entre as saídas da rede e os dados é mostrada na figura 15.


Figura 15: Correlação da saída da rede em malha fechada com os ensaios usados no treinamento.



É possível notar que o valor da correlação foi menor e que houve algumas saídas que se distanciaram bastante dos seus alvos. No entanto, a rede conseguiu generalizar o resultado e estimar para a maioria dos casos apresentados o valor de regime permanente. A conclusão é embasada na correlação entre as duas retas obtidas através da linearização. Esse foi o primeiro parâmetro para determinar se a RNA foi capaz de generalizar.


Para testar a rede em malha fechada e comparar com a malha aberta, o mesmo caso apresentado no caso de operação em malha aberta foi apresentado para rede em malha fechada. Os resultados são mostrados abaixo, nas figuras 16 e 17. A correlação para este caso inédito em malha fechada foi maior que a alcançada com o caso em malha aberta, o que demonstra um resultado inicial bastante animador para estimar os dados de regime permanente. A rede conseguiu se correlacionar melhor em malha fechada para este teste, mostrando grande aptidão para reproduzir os ensaios. No entanto o erro apresentado foi maior devido a um deslocamento da resposta, mas de certa maneira esse comportamento é aceitável pelo fato da rede ser autorregressiva e de levar em consideração apenas os primeiros dados medidos na fase inicial do ensaio. Também é possível notar que a rede reproduziu as tendências do ensaio apesar de propagar o erro enquanto o valor real do ensaio decresce quase que linearmente (do dado 2 até o dado 5 da série).

Figura 16: Correlação da saída da rede em malha fechada e os alvos para o caso inédito apresentado.



Na sequência (dado 6 da série) a rede estima o valor com base nos últimos 5 dados estimados por ela mesma através dos cinco primeiros operadores de atraso e faz isso de forma a reduzir o erro e não obedecendo a tendência decrescente acentuada da mesma forma que os últimos três pontos anteriores. Contudo, os valores continuam a reduzir e novamente a rede propaga o erro anterior até a rede estimar o valor final (dado 10 da série). É visível que a rede dispõe de um comportamento semelhante ao anterior (dado 5 da série) e que responde à redução do valor.

Figura 17: Gráfico de comparação entre as saídas da rede e os alvos para rede em malha fechada.



5 CONSIDERAÇÕES FINAIS

Os resultados obtidos neste trabalho mostram a forma promissora com que as redes neurais artificiais retroalimentadas e autorregressivas são capazes de reproduzir os ensaios e estimar os valores de regime permanente através dos dados tomados entre 2100 s e 3100 s de ensaio (35 min e 52 min respectivamente).

Apesar de a precisão do valor de regime para o teste apresentado não ser das melhores frente ao valor dos dados iniciais, também não foi esse objetivo pretendido neste trabalho. Ensaios que necessitem de uma margem de tolerância bastante estreita devem ser realizados pelos métodos convencionais de ensaio, porém a ferramenta neural desenvolvida apresenta indícios de que é possível, dentro de uma margem de incerteza, realizar predições do valor de regime permanente do ensaio a partir de dados medidos durante o transitório. Tal habilidade pode ser empregada para encerrar antecipadamente ensaios que não apresentariam bons resultados caso fossem levados até o fim ou então para obter-se uma boa estimativa do valor que seria alcançado em regime permanente em um ensaio válido caso ele fosse concluído. Nos dois casos, tem-se uma taxa reduzida de ocupação dos painéis de ensaio, o que se reflete diretamente em mais produtos ensaiados por unidade de tempo.

Os resultados obtidos na abordagem em malha aberta mostram erros menores dos que os obtidos na abordagem em malha fechada. No entanto as redes em malha aberta inferem com base apenas nas informações do ensaio. As redes em malha fechada fazem uma inferência inicial com base nas primeiras informações do ensaio e na sequência usam o próprio valor da saída da rede para inferir o próximo dado.

A correlação entre as regressões não é a melhor forma de se avaliar o comportamento das redes, porém neste trabalho foi o principal parâmetro analisado, uma vez que o software Matlab fornece tal valor de pronto. No entanto, avaliar o comportamento da rede caso a caso e ver como ela é capaz de inferir sobre o valor de regime é uma forma um pouco mais confiável, pois ao analisar o comportamento da rede frente aos dados de ensaio é exposto quão parecido ao ensaio é o comportamento da rede.

Durante a realização do trabalho foram tomados alguns cuidados para evitar que a rede entendesse um comportamento aleatório nos sinais utilizados para treinamento. O primeiro passo foi descartar os dados do intervalo inicial, no qual o comportamento efetivamente é

bastante aleatório devido a borbulhamentos. Além disso, foram realizadas médias móveis para atenuar ruídos de medição e foram descartados alguns pontos intermediários do sinal para tentar ensinar para a rede a tendência de comportamento dinâmico ao invés das oscilações de alta frequência. Todos esses cuidados levaram ao bom resultado encontrado, porém deve-se evidenciar que esse tipo de tratamento também pode estar escondendo alguma informação relevante para a rede. Dessa forma, sugere-se que trabalhos futuros explorem formas alternativas de atingir os mesmos objetivos alcançados neste trabalho sem a necessidade de um pré-processamento tão grande dos dados originais.

As perspectivas posteriores para este trabalho apontam duas vertentes para se buscar melhores resultados. A primeira trabalha com a possibilidade de utilizar outros dados dinâmicos além da capacidade de refrigeração encontrada a partir do método F para encontrar o valor da capacidade final. Dados como: pressões de descarga e sucção do compressor, potência elétrica ativa consumida pelo compressor, corrente elétrica que circula no compressor, potência elétrica que é dissipada nos resistores da unidade evaporadora, temperatura de carcaça do compressor são levadas em consideração no trabalho de Steinbach (2008) e poderiam ser usados para melhorar as estimativas da rede.

A segunda vertente busca verificar a rede deste trabalho para outros ensaios, comparando os dados das saídas com mais casos inéditos e analisando se a rede é capaz de inferir sobre outros ensaios da mesma forma que inferiu sobre o caso testado. Assim, a rede neural seria válida como forma de modelagem do ensaio. Para isso, serão necessários mais ensaios em laboratório, o que não pôde ser realizado durante a execução deste trabalho.

REFERÊNCIAS

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 15826**: Compressores de Refrigeração- Método de ensaio. Rio de Janeiro, 2010. 39 p.

AZEVEDO, F. M.; BRASIL, L. M.; OLIVEIRA, R. C. L. **Redes neurais com aplicações em controle e em sistemas especialistas**. Florianópolis, SC: Visual Books, 2000.

BARRETO, J. M. **Inteligência artificial no limiar do século XXI**. 2ed. Florianópolis: Duplic, 1999. 296p.

BEALE, Mark Hudson; HAGAN, Martin T.; DEMUTH, Howard B. **Neural Network Toolbox: User's Guide**. 2013. Disponível em: <http://www.mathworks.com/help/pdf_doc/nnet/nnet Ug.pdf>. Acesso em: 15 jan. 2014.

GOSNEY, W. B. **Principles of refrigeration**. Cambridge, UK: Cambridge University Press, 1982.

HAYKIN, Simon. **Redes neurais: Princípios e Prática**. 2 ed. Porto Alegre (RS): Bookman, 2001.

HENKLEIN, P. **Análise de ensaios de desempenho de compressores herméticos durante o transitório**. 2006. 136 f. Dissertação (Mestrado) – Universidade Federal de Santa Catarina, Florianópolis, 2006.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. **ISO 917: Testing of refrigerant compressors**. 2. ed. Switzerland, 1989.

IEEE IECON INTERNATIONAL CONFERENCE., 21., 1995, Orlando. **Introduction to artificial neural networks. In: Proceedings of the Industrial Electronics, Control, and Instrumentation**. Orlando, FL, Eua: Ieee, 1995.

IEEE SYSTEMS READINESS TECHNOLOGY CONFERENCE, 1992, Dayton, OH, Usa. **Correlation of transient and steady-state compressor performance using neural Networks**. Dayton, OH, Usa: IEEE, 1992.

INTERNATIONAL JOINT CONFERENCE, 1992, Baltimore, Md. **Modeling the neurodynamics of a biological neuron using a feedforward artificial neural network.** Baltimore, Md: IEEE, 1992.

LIMA, I. V. M. **Uma abordagem simplificada de detecção de intrusão baseada em redes neurais artificiais.** 94 f. Dissertação (Mestrado) - Curso de Ciência da Computação, Universidade Federal de Santa Catarina, Florianópolis, 2005.

MEHROTRA, K.; MOHAN, C.K.; RANKA, S. **Elements of artificial neural networks.** 1 ed. Cambridge (MA): MIT Press, 1996.

MONTGOMERY, Douglas C.; RUNGER, George C. **Estatística aplicada e probabilidade para engenheiros.** 2 ed. Rio de Janeiro: LTC, 2003. 465 p.

RODRIGUES, Paulo Sérgio B. **Compressores industriais.** Rio de Janeiro: Editora Didática e Científica (EDC), 1991.

POLETO, Eduardo Leseire. **Aprimoramento de uma bancada de ensaios de desempenho de compressores herméticos visando reduzir incertezas de medição.** 2006. 107 f. Dissertação (Mestrado) - Curso de Metrologia Científica e Industria, Departamento de Centro Tecnológico, Universidade Federal de Santa Catarina, Florianópolis, 2006.

PROCEEDINGS OF THE 6TH INTERNATIONAL CONFERENCE ON COMPRESSORS AND COOLANTS, 2006, Casta Papiernicka. **Refrigeration: The challenges associated with sustainable development.** Casta Papiernicka: International Institute Of Refrigeration, 2006.

RANGANATHAN, Ananth. **The Levenberg-Marquardt Algorithm.** 2004. Disponível em: <<http://users-phys.au.dk/jensjh/numeric/project/10.1.1.135.865.pdf>>. Acesso em: 15 jan. 2014.

SOUZA, André João De. **Aplicação de Multisensores no Prognóstico da Vida da Ferramenta de Corte em Torneamento.** 2004. 211 f. Tese (Doutorado) – Universidade Federal de Santa Catarina, Florianópolis, 2004.

STALLINGS, William. **Arquitetura e organização de computadores**. 8. ed. São Paulo (SP): Pearson, 2010.

STOECKER, W. F.; JABARDO, J. M. S. **Refrigeração industrial**. 2. ed. São Paulo (SP): Edgard Blucher, 2002.

WALTRICH, P. J. **Análise e otimização de evaporadores de fluxo acelerado aplicados a refrigeração doméstica**. 203 f. Tese (Doutorado) – Universidade Federal de Santa Catarina, Florianópolis, 2008.

WILAMOWSKI, B. M. Neural network architectures and learning algorithms. **Industrial Electronics Magazine**, Auburn, Alabama, EUA, v. 3, n. 4, p.56-63, 11 dez 2009.

