



## Previsão da Velocidade dos Ventos em Cidades do Nordeste do Brasil Utilizando o Paradigma de Ensembles

Carlos Roberto Junior<sup>1</sup>, Maxwell Queiroz Francisco<sup>2</sup>, Aida Araújo Ferreira<sup>3</sup>, Felype Nery de Oliveira Vasconcelos<sup>4</sup>

<sup>1</sup>Graduando em Análise e Desenvolvimento de Sistemas – IFPE. e-mail: carloscrj@recife.ifpe.edu.br

<sup>2</sup>Graduando em Análise e Desenvolvimento de Sistemas – IFPE. e-mail: mqf@a.recife.ifpe.edu.br

<sup>3</sup>Doutora em Ciência da Computação – UFPE e docente no curso Análise e Desenvolvimento de Sistemas – IFPE. e-mail: aidaaf@gmail.com

<sup>4</sup>Graduando em Análise e Desenvolvimento de Sistemas – IFPE. e-mail: felypenery@gmail.com

**Resumo:** Nos últimos anos a polêmica sobre a crise energética tomou certo vulto, incitando a geração e exploração de novas tecnologias que possam atenuar ou quem sabe sanar este problema, por meio de uma forma limpa e renovável, que é o caso da geração de energia por fontes eólicas. Como a geração eólica é uma das fontes renováveis de energia com o menor custo de produção, considerável quantidade de recursos disponíveis e como a velocidade dos ventos é a principal informação para previsão de geração de energia, foram desenvolvidos neste trabalho modelos de previsão de velocidade média dos ventos, para serem utilizados em conjunto com sistema de despacho de geração de energia. Foram utilizadas técnicas de inteligência artificial, técnicas estatísticas e também o paradigma de Ensembles, que apresentou melhores resultados quando comparados com as técnicas isoladas. O resultado deste trabalho deu origem a um software, capaz de carregar uma base de dados contendo informações relativas ao histórico das velocidades de uma região e determinar qual o melhor modelo para previsão da velocidade média horária dos ventos para cada base de dados.

**Palavras-chave:** Energia Eólica, *Ensembles*, Inteligência Artificial, Métodos Estatísticos

### 1. INTRODUÇÃO

Desde a origem da computação, uma das maiores ambições dos cientistas e envolvidos nessa área, é fazer com que a máquina um dia seja dotada de capacidade intelectual semelhante ao do ser humano. Ou seja, que os computadores sejam suficientemente capazes de perceber, entender e resolver um problema. Esta abordagem atualmente é intitulada como Inteligência Artificial (IA) e vem sendo estudada desde a metade do século passado, abrindo precedentes para ramificações importantíssimas como as Redes Neurais Artificiais (RNA's).

Atualmente muitas tarefas são desempenhadas por computadores munidos de IA, tais como aplicativos de segurança para sistemas informacionais, reconhecimento de face, reconhecimento de voz e escrita, bem como robôs que substituem a mão-de-obra humana em trabalhos de extrema insalubridade, como abertura e fechamento de válvula em usinas nucleares.

Nos últimos anos o uso de energias renováveis passou a ser bastante vislumbrado pela sociedade brasileira, principalmente pelo consumidor final, pois ficou marcado na história e ainda é lembrado por muitos a crise energética e os transtornos ocorridos no ano de 2001.

Pode-se dizer que o Brasil possui um grande potencial eólico devido a boa distribuição dos ventos e sua qualidade. Segundo a ANEEL, os últimos estudos apontam que o Brasil possui um potencial eólico na ordem de 60.000 MW.

A operação e integração das fontes de energia eólica com os sistemas de distribuição de energia são dificultosas. Isto acontece devido às características de intermitência e variabilidade dos ventos, dificultando assim o planejamento e estabilidade dos sistemas elétricos que são compostos por fontes diversificadas de energia (FERREIRA, 2011).

A velocidade do vento é a principal entrada para sistemas de previsão de energia eólica. Para que a fonte eólica possa ser inserida na matriz energética é necessária aplicação de métodos ou ferramentas capazes de realizar a previsão da velocidade dos ventos de forma que a sua obtenção seja suficientemente segura e não afete o planejamento da matriz energética.

ISBN 978-85-62830-10-5

VII CONNEPI©2012



No Brasil, após o racionamento de energia ocorrido em 2001, o Governo Federal mostrou bastante interesse na geração de energia eólica e outras fontes renováveis. Em 26 de Abril de 2002, sob a lei nº 10.438 o Governo Federal criou o PROINFA (Programa de Incentivo às Fontes Alternativas de Energia Elétrica), que tem como objetivo fomentar empreendimentos que utilizem a fontes eólicas, biomassa e pequenas centrais hidrelétricas, visando promover uma maior segurança no abastecimento de energia elétrica.

O custo de geração de energia por meio de fontes eólicas é um dos mais baixos e sua disponibilidade é abundante. Entretanto, o caráter aleatório dos ventos torna essa obtenção incerta, dificultando o planejamento e a estabilidade do sistema elétrico, uma vez que os mesmos são na maioria das vezes compostos por fontes diversificadas.

Técnicas de previsão que utilizem métodos estatísticos e/ou RNA's podem auxiliar no processo de planejamento do despacho de geração de energia, tendo em vista que estas técnicas se mostraram bastante promissoras para a tarefa de previsão, que é o foco deste trabalho.

O objetivo deste projeto é desenvolver um sistema híbrido, dotado de inteligência, que possibilite fazer previsões da velocidade média dos ventos, e assim auxiliar o planejamento do despacho de geração de energia elétrica.

Esse sistema será tido como híbrido ou misto, pois combinará técnicas de IA e Técnicas Estatísticas. O ramo da Inteligência Artificial que trabalharemos é o das Redes Neurais Artificiais, mais precisamente sobre a arquitetura *Multilayer Perceptron* (MLP) e os *Ensembles*. Os métodos estatísticos utilizados são os métodos das médias móveis e o método do amortecimento exponencial.

Segundo Hansen e Salamon (1990, p.998) ensembles ou agrupamento de componentes, foi definido como uma forma de combinar soluções obtidas de múltiplos componentes. A vantagem de fazer este tipo de combinação vem do fato de que há uma tendência de se obter um resultado melhor do que aquele obtido individualmente pelo melhor dos previsores.

## **2. REFERENCIAL TEÓRICO**

### **2.1 Redes Neurais artificiais**

Para Valença (2009, p.17), uma Rede Neural Artificial (RNA) pode ser definida como um sistema constituído por elementos interconectados, denominados neurônios, que estão organizados em camadas, onde existe uma camada de entrada, uma ou mais camadas intermediárias e uma camada de saída, e estes são responsáveis pela não linearidade e pela memória da rede. Uma importante característica das RNA's é sua capacidade de aprendizagem por exemplos, associações e generalizações, ou seja, o aprendizado das RNA's é similar ao aprendizado do cérebro humano. Os principais paradigmas de aprendizagem são os supervisionados e não supervisionados. Onde, no primeiro destaca-se pelo conhecimento prévio do resultado que se espera numa fração de dados de entrada. No segundo, a rede aprende apenas com os dados de entrada, ou seja, o algoritmo não requer o conhecimento de nenhuma fração de dados de saída. Treinar uma rede neural é a tarefa de ajustar os pesos através de uma "regra" de aprendizagem até que a rede forneça um resultado desejado (VALENÇA, 2009).

### **2.2 Algoritmos Genéticos**

Segundo Ludemir (2007), algoritmos genéticos são algoritmos de otimização e busca baseados nos mecanismos de seleção natural e na genética que trabalham com um conjunto de possíveis soluções simultaneamente, enquanto que os métodos convencionais de otimização trabalham de forma sequencial, avaliando uma solução a cada instante. As técnicas usadas pelos AG's são as seguintes: um espaço de busca, onde estão todas as possíveis soluções para o problema e uma função de avaliação ou custo que avalia, geralmente através de uma *nota*, cada possível solução presente no espaço de busca.

### **2.3 Métodos Estatísticos**

O propósito dos métodos estatísticos é basicamente identificar um padrão entre os dados da série, por meio da análise de seu histórico e partir daí prever valores futuros (MORETTIN, P. A; TOLOI, C. M, 1981).

### 2.3.1 Média Móvel Simples

O termo média móvel é utilizado porque à medida que a próxima observação está disponível, a média das observações é recalculada, incluindo esta última observação e despreza a observação mais antiga, conforme podemos visualizar na Equação 1. (MORETTIN, P. A; TOLOI, C. M, 1981)

$$Z_{T+1} = \frac{Z_T + Z_{T-1} + Z_{T-2} + Z_{T-3} + \dots + Z_{T-(n-1)}}{n}$$

**Equação 1:** Método Média Móvel Simples

Onde  $n$  representa a janela de previsão a ser usada.

### 2.3.2 Amortecimento Exponencial

Este método é muito parecido com o da média móvel, porém cada observação terá um peso. Esse peso vai diminuindo para os valores mais antigos, ou seja, os valores recentes são mais influentes no resultado da previsão (Barros, 2007). Podemos representar esse modelo matematicamente pela Equação 2.


$$Z_{T+1} = \alpha Z_T + \alpha(1 - \alpha)Z_{T-1} + \alpha(1 - \alpha)^2 Z_{T-2} + \dots + \alpha(1 - \alpha)^{T-1} Z_{T-(n-1)}$$

**Equação 2:** Método Amortecimento Exponencial

Onde  $Z_{T+1}$  representa o valor previsto um instante à frente,  $Z_T$  é a observação anterior,  $\alpha$  é o coeficiente de amortização e  $n$  representa os  $n$  termos da série temporal.

## 2.4 Ensembles

*Ensemble* é um paradigma de aprendizado em que propostas alternativas de solução para um problema, denominadas componentes, têm suas saídas individuais combinadas à obtenção de uma solução final (HANSEN e SALAMON, 1990). *Ensembles* são comprovadamente capazes de aumentar a capacidade de generalização e, conseqüentemente, o desempenho geral do sistema (LEONE et al., 2006). A Figura 1 apresenta a estrutura genérica de um *Ensemble*.



**Figura 1:** Estrutura geral de um ensemble

## 3. RESULTADOS E DISCUSSÃO

### 3.1 Metodologia

Nosso estudo tem como universo três bases de dados, contendo as velocidades dos ventos das cidades de Belo Jardim (BJD), São João do Cariri (SCR) e Triunfo (TRI). Todas as bases contêm as



colunas: data (aaaammdd), hora (de 0 a 23), direção, temperatura (graus Celsius) e velocidade média horária (m/s). A amostra é constituída apenas da terceira coluna, que contém as velocidades horárias dos ventos. Segue abaixo na Tabela 1 informações detalhada sobre cada cidade.

**Tabela 1: Descrição da base dados das cidades analisadas**

Nome da base	Latitude	Longitude	Altitude da Estação SONDA	Período
<b>Belo Jardim</b>	08°20'08" Sul	36°25'27" Oeste	718 metros	01/07/2004 a 31/12/2005
<b>São João do Cariri</b>	07°23'27" Sul	36°31'58" Oeste	718 metros	01/01/2006 a 31/12/2007
<b>Triunfo</b>	07°50'17" Sul	38°06'06" Oeste	1123 metros	01/07/2004 a 31/12/2006

As bases foram normalizadas para o intervalo [0,1], pois é muito importante para adequação ao padrão estabelecido pelas RNA's. Esta normalização consiste em realizar um processamento na coluna da velocidade média horária dos ventos. Segue na Equação 3.

$$V_{norm} = \frac{V_{original} - V_{min}}{V_{max} - V_{min}}$$

**Equação 3:** Normalização de dados

Onde,  $V_{original}$  é o valor a ser normalizado,  $V_{min}$  e  $V_{max}$  são respectivamente os valores mínimo e máximo das velocidades horárias e  $V_{norm}$  é o valor normalizado.

Na segunda etapa foi realizada a procura dos parâmetros para as RNA's (Quantidade de neurônios, Função de Ativação e Algoritmo de Treinamento) de cada cidade, por meio da técnica de Algoritmos Genéticos. A solução do AG era codificada da seguinte maneira: A primeira posição se refere à quantidade de neurônios (1 a 200), a segunda posição referente à função de ativação (1 para sigmoide logística ou 2 para tangente hiperbólica), e por fim a terceira, referente ao algoritmos de treinamento (1 para Levenberg–Marquardt (LM) ou 2 para Rprop). Com o intuito de efetuarmos uma melhor avaliação e obtermos resultados mais refinados, esta técnica foi repetida cinco vezes para cada base, sendo necessárias em média 7 horas de processamento para cada experimento, através do hardware descrito na Tabela 2.

**Tabela 2:** Especificação do Hardware

	Marca	Modelo	Frequência	Capacidade
<b>Computador</b>	LG	E500-L	-	-
<b>Processador</b>	Intel	Pentium T2390 (Dual-Core)	1,86Ghz	-
<b>Memória-RAM</b>	A-Data Technology	DDR2	667Mhz	3 Gigabytes

Em seguida foi iniciada a terceira etapa, onde foram analisados os resultados dos testes utilizando métodos estatísticos, de forma que fossem estabelecidas faixas de valores ideais para os parâmetros de cada método, como coeficiente de amortecimento e janela de observação, para os métodos de Média Móvel e Amortecimento Exponencial respectivamente.

E por último, o módulo foi marcado pela implementação da técnica de Ensembles, onde este é responsável pela combinação das previsões dos Métodos Estatísticos e de Redes Neurais Artificiais. As regras de combinação adotadas foram Média Aritmética e Média Ponderada.



No combinador por Média Ponderada foi definido que cada componente receberia um peso diferenciado, baseado em seu resultado de MSE total. A métrica de distribuição dos pesos varia de acordo com a quantidade de previsores selecionados, onde:

- Para dois participantes, o que obtiver o menor MSE receberá um peso 60 e o outro receberá 40;
- Para três participantes, o que obtiver o menor MSE receberá um peso 50, o segundo menor receberá 30 e o último 20;

O resultado desta combinação seja por média ponderada ou média aritmética é comparada com o resultado desejado e então calculado um MSE para o conjunto selecionado.

### 3.2 Resultados Obtidos

Os experimentos em busca de melhores parâmetros foram iniciados pela análise da base de dados da cidade de São João do Cariri, onde se esperava encontrar uma de uma janela de observação ideal, conforme descrito na seção 3.1.

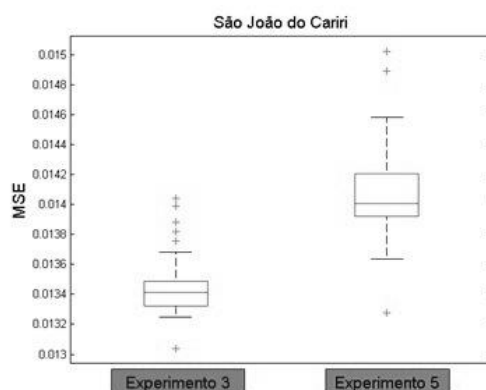
Seguem na tabela e gráfico abaixo os resultados dos indivíduos obtidos para a cidade de São João do Cariri e a evolução dos mesmos ao longo do experimento. A Tabela 3 relaciona os melhores indivíduos de cada experimento realizado, tendo como o melhor de todos o que está marcado em negrito.

**Tabela 3:** Indivíduos do AG São João do Cariri

Base de Dados	Experimento	MSE	Número de Neurônios	Função de Ativação	Algoritmo de Treinamento
São João do Cariri	1	0,0135	104	Tangente Hiperbólica	LM
	2	0,0135	10	Sigmoide Logística	RP
	<b>3</b>	<b>0,0130</b>	<b>10</b>	<b>Sigmoide Logística</b>	<b>LM</b>
	4	0,0134	15	Tangente Hiperbólica	RP
	5	0,0133	10	Tangente Hiperbólica	LM

É importante frisar, que o indivíduo que apresentar menor MSE ao término de cada experimento é escolhido como parâmetro da Rede em questão, e não o melhor indivíduo das iterações intermediárias. O melhor encontrado foi no experimento 3, portanto, a configuração para esta rede ficou sendo 10 neurônios nas camadas ocultas, Função de ativação Sigmoide Logística e Algoritmo de Treinamento LM.

Para afirmar se as diferenças entre os métodos são estatisticamente significativas, foram considerados os MSEs de todos os cinquenta indivíduos da última iteração de cada experimento e realizado um teste de hipóteses (t de Student pareado) com significância de 0,01 entre o melhor experimento e os demais. O resultado do teste rejeitou a hipótese nula (médias iguais) com 99% de confiança em todos os quatro casos (experimento 3 vs. experimento [1,2,4,5]).



**Gráfico 1:** Teste de hipótese SCR

A comparação do desempenho pode ser realizada de forma visual por meio do gráfico do tipo BoxPlot, conforme pode ser visto no gráfico 1. O referido apresenta a comparação entre o experimentos 3 e 5 para a cidade de São João do Cariri, onde o resultado de cada experimento é representado pela caixa, a marca central dentro desta caixa significa a mediana e os símbolos de “mais” fora das caixas representam os valores atípicos, também chamado de *outliers*.

A Tabela 4 mostra os resultados dos erros em 5 experimentos realizados na de São João do Cariri com o método de Redes Neurais.

**Tabela 4:** Média dos Resultados MLP São João do Cariri

Base de Dados	Resultado N°	MSE	Desvio Padrão - MSE	MAE	Desvio Padrão - MAE
São João do Cariri	1	0,0134	0,0194	1,1162	0,8558
	2	0,0134	0,0193	1,1121	0,8557
	3	0,0134	0,0195	1,1139	0,8573
	4	0,0133	0,0193	1,1101	0,8530
	5	0,0134	0,0195	1,1188	0,8585
	<b>Média</b>	<b>0,0134</b>	<b>0,0194</b>	<b>1,1142</b>	<b>0,8561</b>

Depois que foram efetuados os experimentos em todos os métodos isoladamente, relacionado as características das bases de dados e levantado os parâmetros que apresentaram os melhores resultados, deu-se início aos experimentos utilizando o paradigma de *Ensembles*.

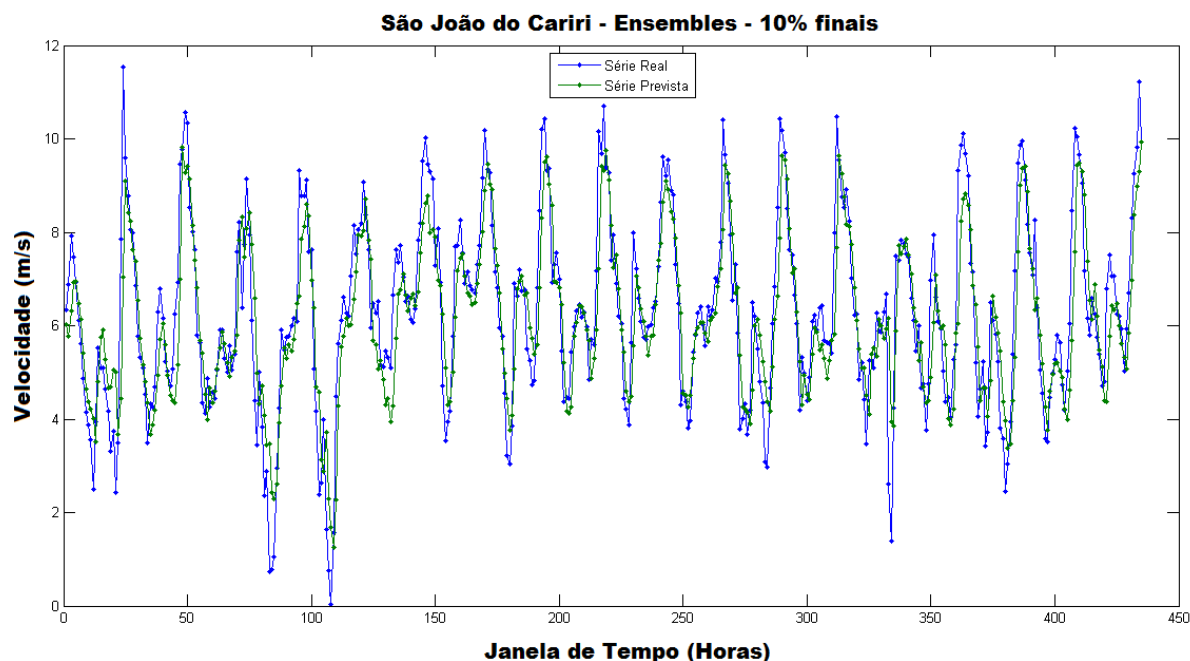
Os resultados obtidos para a base de São João do Cariri, mostrados na Tabela 5, teve um resultado melhor ao ser aplicado a técnica de *Ensembles* por Média Ponderada utilizando MLP e AES. Contudo, o coeficiente de amortecimento utilizado para esta base foi de 0.9.

**Tabela 5:** Resultado Ensemble São João do Cariri

Base de São João do Cariri					
Rótulo	Método	MSE	Desvio Padrão - MSE	MAE	Desvio Padrão - MAE
<b>A</b>	MLP	0,0133	0,0193	1,1086	0,8534
<b>B</b>	MMS (Janela 2)	0,0211	0,0335	1,3809	1,0974
<b>C</b>	AES (Coef. 0.9)	0,0078	0,0156	0,8032	0,7114
<b>Ensembles - Média Aritmética</b>	A + B	0,0138	0,0210	1,1232	0,8824
	A + C	0,0065	0,0104	0,7653	0,6129

	A + B + C	0,0090	0,0142	0,9012	0,7202
<b>Ensembles - Média Ponderada</b>	A + B	0,0133	0,0201	1,1041	0,8654
	A + C	<b>0,0061</b>	<b>0,0101</b>	<b>0,7331</b>	<b>0,5995</b>
	A + B + C	0,0073	0,0120	0,8059	0,6543

O gráfico 2 apresentado abaixo corresponde a previsão dos 10% finais da base de dados da cidade de São João do Cariri, utilizando a técnica de *ensembles* entre os componentes de Redes Neurais Artificiais – MLP com Amortecimento Exponencial Simples, como exposto na Tabela 5. Para este experimento foi realizado um teste de hipótese com significância de 0,01 entre as duas melhores combinações dos Ensembles da base de São João do Cariri (MLP+AES por Média Ponderada e Média Aritmética), utilizando o erro absoluto das velocidades. O resultado do teste de hipótese rejeitou a hipótese nula (médias iguais) com 95% de confiança.



**Gráfico 2:** Resultado previsão *Ensembles* SCR

#### 4. CONCLUSÕES

O modelo desenvolvido para previsão da velocidade média horária dos ventos utilizando ensembles apresentou resultados satisfatórios para a base estudada, quando comparado às técnicas isoladas utilizadas em (JUNIOR, 2011). Isto foi possível devido à realização dos passos iniciais, onde foram identificados os principais parâmetros e características de cada base de dados.

Por meio do processo sistemático que foi elaborado neste trabalho, podemos afirmar que a pesquisa foi concluída com sucesso, pois além dos resultados obtidos foi possível definir uma lista de procedimentos norteadores para a realização de novos modelos e trabalhos a cerca do tema.

O uso do método de Ensembles, combinando as técnicas de Redes MLP e AES obtiveram os melhores resultados. O processo de descoberta dos melhores parâmetros para as redes neurais artificiais de cada base de dados foi realizado por meio da técnica de Algoritmos Genéticos, contudo acreditamos que o método utilizado pode ser melhorado com o aumento do número de parâmetros dos indivíduos utilizados pelo AG e com a realização de mais inicializações.



## REFERÊNCIAS

FERREIRA, A. A. **Um Método para Design e Treinamento de Reservoir Computing Aplicado à Previsão de Séries Temporais**. Tese (Doutorado) – Programa de Pós-Graduação em Ciência da Computação, Universidade Federal de Pernambuco, Recife, 2011.

BARROS, M. **Processos Estocásticos**. Publit, 2007.

HANSEN, L. K.; SALAMON, P. **Neural network ensembles**, em IEEE Trans. Pattern Analysis and Machine Intelligence 12, no 10, 1990, p. 993-1001.

LEONE Filho, M. A., OHISHI, T. e BALLINI, R. - **Ensembles of Selected and Evolved Predictors using Genetic Algorithms for Time Series Prediction**, in: IEEE World Congress on Computational Intelligence, Vancouver , 2006.

LUDERMIR, A. de Pádua Braga; André Ponce de Leon F. de C. T. B. **Redes Neurais Artificiais - Teoria e Aplicações**. 2. ed. [S.l.: s.n.], 2007.

MORETTIN, Pedro A. e TOLOI, Clélia M. - **Modelos para Previsão de Séries Temporais**, Edgard Blucher, 1981.

VALENÇA, Mêuser. **Fundamentos das Redes Neurais**. 2ª ed. - Olinda, PE: Livro Rápido, 2009.

JUNIOR, C. R. S.; FERREIRA, A. A. – **Desenvolvimento de Sistema para Previsão de Séries Temporais Utilizando Redes Neurais Artificiais - VI Congresso de Pesquisa e Inovação da Rede Norte e Nordeste de Educação Tecnológica**. Natal, Rio Grande do Norte, 2011.