

## ANÁLISE DE ENSAIOS ULTRASSÔNICOS NO CONCRETO ATRAVÉS DE REDES NEURAIS ARTIFICIAIS

ALEXANDRE LORENZI, LUIZ CARLOS P. DA SILVA FILHO

*Laboratório de Ensaios e Modelos Estruturais, Programa de Pós-Graduação em Engenharia Civil,  
Universidade Federal do Rio Grande do Sul*

*Av. Osvaldo Aranha, 99 - Térreo, 90035-190 Porto Alegre, RS, BRASIL*

*E-mails: alexandre.lorenzi@ufrgs.br, lcarlos66@gmail.com*

**Abstract**— Concrete is the most used structural material in civil engineering. To ensure that concrete structures reach the desired design service life, it is necessary to monitor the evolution of material properties and the deterioration of state condition over time. One of the most effective ways to assessing finished structures is by using Nondestructive Test (NDT) Methods. One of NDT methods more suitable to evaluate concrete structures is the Ultrasonic Pulse Velocity (UPV). This method allows the assessment of concrete homogeneity and compacity. It is known that the presence of voids and defects are critical factors in the definition of concrete strength, therefore this data is naturally correlated with compressive strength, the key parameter used for concrete quality control. Given this fact, several attempts have been made to estimate concrete strength using UPV data, considering the concrete characteristics, such as age, water/cement ratio ( $w/c$ ), temperature, type of cement and method of curing. However, the relationship between these variables is affected by several factors, making the development of reliable models using traditional techniques a very complex task. This research investigates the feasibility of applying a novel modeling technique, based on the concept of Artificial Neural Networks - ANNs - to generate prediction models linking concrete characteristics, UPV measurements and compressive strength. The purpose is to determine a non-linear relationship between these parameters, obtaining useful to make compressive strength estimates and analyze structural condition. The ANN morphology used was based on the Multy-Layer Perceptron (MLP) concept, with four layers and up to 20 neurons per layer, resulting in a very flexible and adaptable tool for modeling nonlinear problems. Different configurations were tested to check performance. The models generated are very efficient, obtaining coefficients of determination ( $R^2$ ) greater than 95%, and performing much better than traditional multiple regression models, when exposed to a training database of 2200 results collected from different researches, spanning a great range of concrete types.

**Keywords** — Artificial Neural Networks, Nondestructive Testing, Ultrasonic Tests, Concrete, Strength Estimates

**Resumo** — O concreto tem um papel de destaque na indústria da construção civil, em decorrência de ser o material estrutural mais utilizado. Para garantir que as estruturas de concreto atinjam a vida útil de projeto desejada, é necessário acompanhar a evolução das propriedades do material e a eventual degradação de sua condição com o tempo. Uma das maneiras mais eficientes de avaliar estruturas acabadas consiste na utilização de ensaios não destrutivos, dentre os quais se destaca a técnica de medição da velocidade de propagação de pulsos ultrassônicos. Este método permite avaliar a homogeneidade e compacidade do material. Considerando que a presença de vazios, ou “defeitos” na microestrutura de um material, é um fator fundamental na definição da resistência à compressão, várias tentativas foram feitas de estimar a resistência à compressão do concreto, principal parâmetro de projeto, a partir de dados de ensaios ultrassônicos, considerando algumas das características básicas do concreto utilizado, tais como idade, relação água/cimento ( $a/c$ ), temperatura, tipo de cimento e modo de cura. No entanto, a relação existente entre a resistência do concreto e o ensaio ultrassônico é afetada por diversos fatores, o que torna a geração de modelos de correlação adequados e confiáveis uma tarefa bastante complexa. Esta pesquisa investiga a flexibilidade da aplicação de uma nova técnica de modelagem, com base no conceito de Redes Neurais Artificiais (RNAs) para gerar modelos de previsão conectando as características do concreto, os valores do ensaio ultrassônico e a resistência à compressão do concreto. A proposta é determinar uma relação não-linear entre estes parâmetros, obtidos para se proceder com estimativas da resistência à compressão e com a análise das condições estruturais. A morfologia utilizada tem por base o conceito de MLP, com quatro camadas e até 20 neurônios por camada, resultando numa ferramenta flexível e adaptável para a modelagem de problemas não-lineares. Foram testadas diferentes configurações de rede dos quais resultaram modelos de relacionamento muito eficientes, que apresentaram coeficientes de determinação superiores a 95% e apresentaram desempenho melhor que modelos estatísticos tradicionais de regressão múltipla, quando expostos a um banco de dados de 2200 resultados de diferentes pesquisadores, com concretos de características bastante diversas.

**Palavras-chave** — Redes Neurais Artificiais, Ensaios Não Destrutivos, Ensaio Ultrassônico, Concreto

### 1 Introdução

Existem diversas técnicas de modelagem de informações que possibilitam que seja simulada a inteligência humana, fator indispensável para a resolução de problemas de interpretação complexos, como no caso da análise de resultados de ensaios de velocidade de propagação de pulso ultrassônico, que demandam conhecimento especializado. Dada a escassez de especialistas, fica evidente a necessidade da utilização de ferramentas de Inteligência Artificial (IA) para desenvolver modelos capazes de auxiliar no diagnóstico e na tomada de decisão a partir dos resultados de ensaios deste tipo. Uma das técnicas de IA mais promissoras é a que emprega as Redes Neurais Artificiais (RNAs), pois a mesma se baseia numa simulação do funcionamento do cérebro humano.

As RNAs são uma nova estratégia de análise de dados, que tem sido empregada para modelar fenômenos complexos e não-lineares, sobre os quais ainda não se tem um conhecimento estruturado. A utilização delas permite que sejam emulados processos de aprendizado e de descoberta. A capacidade de aprendizado através da análise de exemplos e

generalização das relações aprendidas é um dos atrativos principais da solução de problemas por meio da utilização das RNAs.

Neste trabalho se estuda a viabilidade da aplicação destas ferramentas de modelagem para a geração de estimativas do valor da resistência à compressão, a partir de dados de resultados de ensaios de velocidade de pulso ultrassônico, considerando algumas das características básicas do concreto utilizado, tais como idade, relação água/cimento (*a/c*), temperatura, tipo de cimento e modo de cura.

Acredita-se que, através da utilização de uma rede com arquitetura de perceptron de múltiplas camadas (MPL – multilayer perceptron), é possível correlacionar, de forma não-linear, parâmetros de entrada conhecidos, como o tipo do cimento, o traço, a idade, a relação água/cimento, a temperatura de cura e a velocidade de propagação de pulso ultrassônico, com o principal parâmetro de controle desejado – a resistência à compressão do concreto. Para tanto se propõe treinar as redes com um algoritmo de retropropagação de erro (EBP – error back-propagation), expondo-as a uma série elevada de dados conhecidos, que lhes permitam estimar coeficientes de correlação para cada camada, gerando um modelo não-linear e altamente complexo que busca capturar, de forma não-estruturada, as várias inter-relações entre as variáveis de entrada.

No caso específico do concreto, as RNAs estão sendo utilizadas para desmistificar as propriedades de materiais cimentícios (El-Chabib e Nehdi, 2005), para a análise da durabilidade do concreto (Ukrainczyk e Ukrainczyk, 2008), para a modelagem de fissuras (Reda Taha et al., 2004), para prever a performance de diferentes traços de concreto compactado com rolo (Nehdi, El Chabib, El Naggar, 2002), para avaliar a resistência do concreto (Hola e Schabowicz, 2005), para estimar a produtividade das atividades de concretagem (Ezeldin e Sharara, 2006) e a resistência à compressão do concreto (Kim et al., 2004), para prever a tensão última de corte em concretos reforçados (Sanad e Saka, 2001), para auxiliar na análise estrutural (Rajasekaran, 2004), modelagem de tensão e deformação de pilares circulares em concreto (Oreta e Kawashima, 2003), diagnósticos de danos em estruturas (Tsai e Hsu, 2002) e para determinar o proporcionamento de misturas de concreto (Oh et al., 1999).

## 2 Fundamentos de Redes Neurais Artificiais

Em sua forma mais geral, uma RNA é uma estrutura computacional virtual projetada de forma a modelar a maneira como o cérebro realiza uma determinada tarefa de interesse. Objetivando atingir um bom desempenho, as RNAs empregam uma interligação maciça de células computacionais simples, denominadas neurônios ou unidades de processamento (Haykin, 2001).

As RNAs tentam simular a arquitetura e o modo de operar do cérebro humano e seu sistema nervoso, sendo constituídas normalmente de uma série de elementos de processamento interconectados entre si. Cada elemento processador pode ter muitas entradas, mas terá somente uma saída (Sanad & Saka, 2001). As formas como os estímulos de entrada se combinam para gerar o sinal de saída pode variar.

As unidades simples são chamadas de neurônios e guardam apenas uma variável de estado, que se modifica dependendo dos estímulos recebidos de todos os neurônios antecedentes ao qual aquela unidade está conectada. As ligações entre os neurônios são denominadas conexões e se caracterizam por terem intensidades diferentes. Estas intensidades são representadas pelos pesos sinápticos, que são coeficientes de correlação existentes entre os neurônios. A rede funciona, portanto, através da disseminação de estímulos por meio de suas camadas, sendo que a matriz de pesos sinápticos vai modificando estes estímulos, gerando respostas diferentes para estímulos diferentes.

Dada sua natureza, as RNAs têm uma propensão natural para armazenar conhecimento experimental, não-estruturado. A definição dos pesos considera as relações ocultas entre os dados e organiza o conhecimento de uma forma que permite seu uso para interpretação de novas situações, de uma maneira similar ao que acontece no cérebro humano. O emprego de um número maciço de células computacionais simples faz com que a RNA tenha uma “capacidade de raciocínio” não-linear e de grande potencial.

Uma RNA típica é constituída por uma camada de entrada, composta de tantos neurônios quanto seja necessário para codificar as informações conhecidas, de uma ou mais camadas intermediárias, que permitem a transformação da informação de acordo com uma estrutura de pesos que foi estabelecida quando a rede foi treinada, e uma camada de saída, que contém o resultado do processamento realizado pela RNA. Para que uma rede se configure é necessário

treiná-la, utilizando, para esta finalidade, a exposição a casos onde os estímulos de entrada e o sinal de saída são conhecidos.

Uma das técnicas de aprendizagem mais utilizadas é a da retropropagação de erro, que consiste em um procedimento em duas etapas alternadas, que são repetidas até que se obtenha a melhor estimativa possível, representada por um coeficiente de correlação mais alto. Na primeira etapa de aprendizagem, denominada propagação, um padrão da atividade é aplicado aos nós sensoriais da rede e seu efeito é propagado através da rede, produzindo um conjunto de sinais de saídas. Durante a segunda etapa, retropropagação, os pesos sinápticos são ajustados de acordo com uma regra de correção de erro. Esse ajuste faz com que a resposta obtida através da simulação da rede se mova para mais perto da resposta desejada, em um sentido estatístico (Haykin, 2001).

Braga et al (2000) destacam que a solução de problemas utilizando as RNAs é bastante atrativa, pois, sua estrutura facilita a armazenagem de conhecimento não-estruturado e o paralelismo inerente à mesma permite criar modelos flexíveis e não-lineares, que têm uma grande possibilidade de apresentar desempenho superior aos modelos convencionais na resolução de problemas complexos.

### 3 Ensaios Não Destrutivos

O simples fato de o concreto ser o material mais utilizado na construção civil já justifica a realização de estudos sobre os fatores que podem afetar suas propriedades e sobre as formas de medir as mesmas. Tradicionalmente, a resistência à compressão é a propriedade de controle mais empregada para analisar a qualidade deste material, vislumbrando que esta seja a propriedade utilizada por construtores para assegurar a perfeita execução das estruturas de concreto.

De acordo com Mordfin (1966) apud Bray e Stanley (1997), três axiomas descrevem a relação da avaliação por meio de Ensaios Não Destrutivos (NDT) com o serviço satisfatório para componentes e sistemas:

- Todos os materiais contêm falhas;
- As falhas em um material não o tornam necessariamente impróprio para serviço;
- A percepção de uma falha, geralmente, aumenta com o tamanho da mesma.

Cabe salientar que os NDT não são métodos adequados para medir a resistência à compressão de uma estrutura, mas, para analisar suas propriedades e determinar sua homogeneidade. É possível, entretanto, estimar a resistência a partir de alguns dos resultados obtidos, pois, quanto menos heterogêneo for o concreto e quanto menor for a relação água/cimento do mesmo, mais resistente o mesmo será. Pode-se, desta forma, estabelecer uma correlação dos resultados dos NDT com a resistência da estrutura. Todavia, estas correlações são particulares para um certo tipo de concreto e devem ser utilizadas com cautela.

A principal vantagem da aplicação de métodos não intrusivos é que eles não acarretarão dano à estrutura de concreto analisada ao se proceder com a avaliação. A utilização deste tipo de ensaios conduz a uma maior segurança e permite uma melhor programação da construção. Uma característica importante é a de permitir a execução de ensaios no mesmo local, de modo a permitir acompanhar variações com o tempo.

Dentre os métodos disponíveis, o Ensaio Ultrassônico (UPV) pode ser considerado como um dos mais promissores para a avaliação de estruturas de concreto, pois possibilita realizar um exame da homogeneidade do material. Por meio de sua utilização consegue-se realizar um controle total da estrutura, podendo-se levar em conta, inclusive, as variações das propriedades com o tempo. Pode-se, por exemplo, utilizar a análise das variações na velocidade de propagação de uma onda ultrassônica, para verificar-se a compacidade de uma estrutura ou detectar regiões heterogêneas no interior da mesma. Neville (1997) lembra que existe relação entre a velocidade das ondas ultrassônicas e a densidade do concreto e essa relação oferece justificativa para o uso da velocidade de ondas ultrassônicas para a avaliação do concreto, embora esteja sujeita a certas limitações.

O controle de estruturas de concreto através da utilização deste tipo de ensaio é uma ferramenta bastante útil, pois permite efetuar um mapeamento das características do material e um acompanhamento das mesmas ao longo de sua vida útil. Procedendo-se com a análise dos dados obtidos têm-se parâmetros para checar a uniformidade do concreto, controlar a sua qualidade, acompanhar sua deterioração e, através de comparação com corpos de prova de referência, até mesmo estimar a resistência do mesmo.

### 3.1 Ensaios Ultrassônicos

Dentre os métodos de NDT, o UPV tem sido muito utilizado na área de vistoria e monitoramento de estruturas de concreto. Isto decorre do fato de que o mesmo permite que se meçam e controlem uma série de parâmetros fundamentais para determinar a qualidade do concreto. Sua utilização permite caracterizar o material e estabelecer importantes parâmetros para a verificação de sua condição.

O método de UPV está baseado na propagação de ondas sonoras de alta frequência pelo material analisado. Estas ondas variam de velocidade em função da quantidade de poros e vazios, o que possibilita a detecção de discontinuidades. A idéia é projetar a onda sonora para dentro do material, medindo o tempo, até que a mesma se propague até um outro ponto qualquer. Sabendo a distância entre os pontos, é possível então determinar a velocidade média no trecho de propagação, que irá depender de diversos fatores, tais como a natureza do material, a porosidade do mesmo e a presença ou não de água nos poros, entre outros. Em função da sua sensibilidade a estes fatores, os ensaios ultrassônicos servem para caracterizar um determinado material, sua integridade e outras propriedades físicas, tornando-se uma técnica bastante usada para o controle de qualidade, detecção de defeitos, medição de espessuras ou caracterização dos materiais constituintes do concreto, segundo explica a norma americana E 114-95 (ASTM, 1995).

A metodologia de aplicação do ensaio tipo UPV está baseada no fato de que o monitoramento do tempo de propagação de pulsos por uma seção transversal de concreto permite estimar a sua compacidade e que esta, de forma indireta, se correlaciona com as propriedades mecânicas do material. Geralmente se utilizam transdutores de superfície de baixa frequência (25-60 kHz) para aplicação em concreto.

O ensaio se inicia quando um pulso de frequência ultrassônica é gerado e transmitido para um transdutor eletroacústico, colocado em contato com a superfície do concreto a ser testado. Após passar pelo concreto, as vibrações são recebidas e convertidas pelo segundo transdutor eletroacústico. O tempo decorrido entre a emissão da onda e sua recepção é medido com precisão de pelo menos  $0,1\mu\text{s}$  (Neville e Brooks, 1997).

Os resultados do ensaio de UPV irão depender da densidade e propriedades elásticas do material em estudo. Como a qualidade de muitos materiais de construção é relacionada com sua rigidez, a medida da UPV pode ser usada tanto para medir a qualidade das estruturas de concreto, como para estimar suas propriedades mecânicas, como a resistência à compressão e o módulo de elasticidade (Meneguetti *et al.*, 1999).

Com sua utilização consegue-se realizar um controle total da estrutura, podendo-se levar em conta, inclusive, as variações das propriedades com o tempo. Por exemplo, através da análise das variações na velocidade de propagação do pulso ultrassônico, é possível verifica a compacidade de uma estrutura ou detectar regiões heterogêneas no interior da mesma.

### 3.2 Aplicação no Concreto

No caso particular do concreto, a relação entre velocidade de propagação de onda ultrassônica e resistência à compressão é afetada por um número grande de variáveis, incluindo, por exemplo, a relação água/cimento, o tamanho e o tipo do agregado, o procedimento de moldagem, o tamanho da amostra e o tipo de cimento. Apesar disto, o ensaio ultrassônico é um indicativo útil e pode ser aplicado com segurança para avaliar a uniformidade do concreto em uma estrutura, como afirmam LANDIS *et al* (2002). A Figura 1 ilustra a execução do ensaio de UPV, com um equipamento portátil, em corpos-de-prova cilíndricos de concreto.

Considerando que a resistência está fortemente correlacionada com a densidade do material, pode-se utilizar o ensaio de UPV para estimar a mesma de uma forma indireta, sem que seja necessário retirar amostras do material. Esta possibilidade é muito atraente, pois evita que a investigação da resistência provoque danos no material, ou resultem na necessidade de um reparo, cuja interface com o material original vai se constituir numa zona mais vulnerável à deterioração. Danos mal corrigidos podem, inclusive, resultar numa vida de serviço encurtada ou, em casos extremos, provocar falhas locais ou globais, colocando em risco os usuários das edificações ou estruturas sob análise.



Figura 1. Ensaio de UPV em um corpo-de-prova de concreto.

Um grande número de variáveis, potencialmente, afeta a correlação de resultados de compacidade, obtidos via pulso ultrassônico, e de resistência à compressão do concreto. A relação água/cimento (a/c), o tamanho do agregado, o teor de umidade, a técnica de moldagem, o tamanho das amostras e o tipo de cimento, por exemplo, afetam diretamente a resistência à compressão. A eficiência da técnica, portanto, é limitada, sendo mais útil para estudos comparativos da resistência ao longo do tempo ou de mapeamento de variações de resistência numa estrutura.

Para melhorar sua eficiência é necessário desenvolver modelos mais sofisticados, tema que é objeto de interesse da pesquisa em andamento. Dada a sinergia de efeitos e falta de conhecimento sobre cada um deles, pode-se dizer que este é um problema que exige uma modelagem não-linear de um conhecimento pouco estruturado, o que justifica o emprego da técnica de modelagem via RNAs.

#### 4 Formatação do Modelo

O objetivo deste trabalho foi formular uma RNA apropriada para interpretação de dados de ensaios de UPV com vistas a obter uma estimativa confiável da resistência à compressão do material ensaiado sem a extração de testemunhos. Para alcançar este objetivo o programa de pesquisa estabelecido compreendeu a geração e teste de várias configurações de RNAs, compostas por diferentes quantidades de neurônios em cada camada.

Fixou-se o número de camadas em 5, pois análises anteriores haviam indicando que esta morfologia básica permitia obter um número de correlações que dava boa flexibilidade e capacidade de interpretação à rede, sem acarretar esforços de processamento computacional muito elevados.

Definiu-se que as redes teriam configurações com maior número de neurônios nas camadas intermediárias. Nas primeiras camadas a função de transferência utilizada foi a tangente sigmóide hiperbólica, enquanto na camada de saída adotou-se a função linear. Todas as redes foram treinadas por meio do algoritmo EBP (Error Back-propagation), descrito na seção 2 e referido na literatura como o mais empregado.

A Figura 2 mostra um modelo esquemático de rede, com as variáveis investigadas neste trabalho. A estrutura efetiva das RNAs estudadas variaram a partir de uma configuração inicial composta por um MLP com cinco camadas, sendo a camada de entrada composta por dados referentes a seis parâmetros controlados (Tabela 1). De forma a possibilitar trabalhar com parâmetros de naturezas diferentes, os mesmos foram codificados em valores numéricos. Todas as RNAs utilizadas foram treinadas utilizando todas as variáveis estudadas.

As redes foram treinadas com um banco de dados com mais de 2000 registros de ensaios de pulso ultrassônico e de resistência à compressão realizados na mesma amostra de concreto. Os dados compreendiam resultados de UPV de 1.600 a 5.000 m/s, e de resistência à compressão de 10 a 100 MPa.

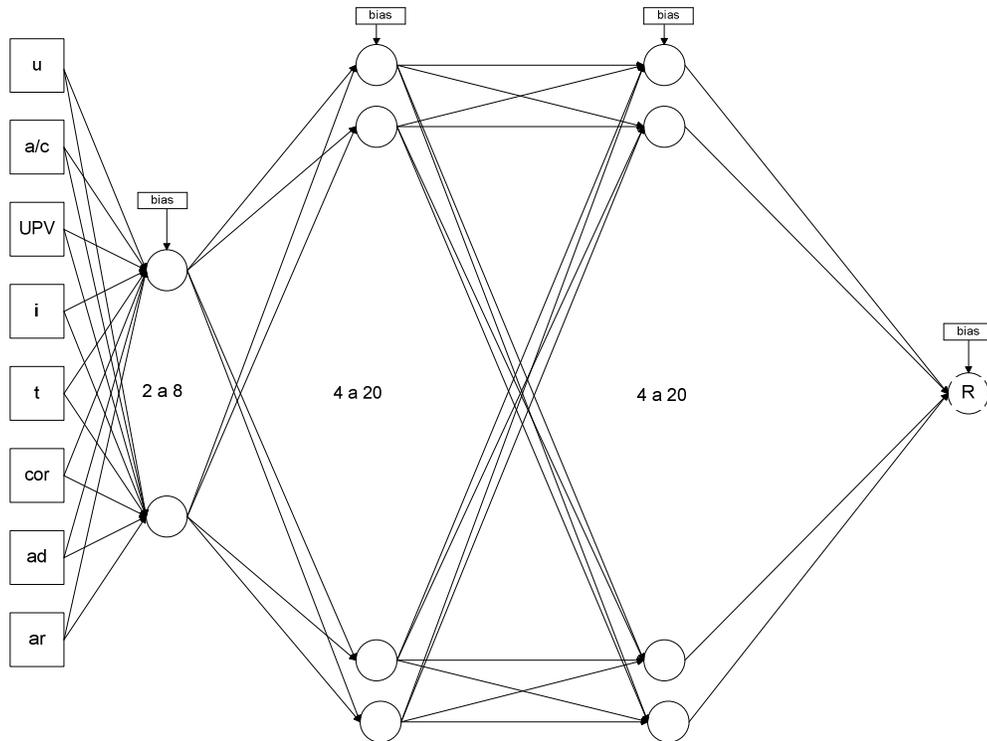


Figura 2 – Representação do MLP utilizado.

Tabela 1 – Parâmetros Controlados.

	Parâmetro	0	+1
	Tipo de Cimento	Reatividade (ar)	CP II, CP IV
Cor (c)		CP II, CP IV, CP V	CP B
Adições (ad)		CP B, CP V	CP II, CP IV
	Modo de Cura (u)	Ambiente	Saturada
	Relação a/c (a/c)	0,35	0,65
	Temperatura (t)	23	800
	Idade (i)	0,5	360
	UPV	1600	5000

Para realização do estudo, os dados disponíveis foram reunidos em dois subconjuntos, sendo utilizados 90% deles utilizados para treinamento e 10% para teste e validação dos modelos. Os modelos neurais foram gerados a partir de várias configurações de uma RNA, treinada com um algoritmo de retropropagação de erro, sendo controlados o erro da estimativa e o número de épocas de treinamento (etapas de iteração), necessário para convergência do modelo, sendo registrado o tempo computacional gasto para o treinamento. Adotou-se um erro máximo aceitável de 5 MPa.

Para a execução dos experimentos determinou-se, inicialmente, quais os parâmetros que seriam relevantes informar para que a RNA obtivesse uma boa resposta, bem como qual seria a forma de apresentação dos dados que seriam

classificados. No presente caso, os parâmetros foram: resistência do concreto (parâmetro de saída), UPV, relação  $a/c$ , temperatura de cura, idade e parâmetros relacionados com o tipo de cimento (cor, adições e reatividade).

## 5 Análise de Resultados

As Figuras 3 a 9 mostram os resultados dos dados de treinamento da simulação da RNA contendo  $8 \times 8 \times 20 \times 20 \times 1$  neurônios (valores para cada uma das camadas). Os losangos em vermelho indicam os dados originais, enquanto os círculos (verdes) são os valores estimados pela rede. Para que se possa ter uma idéia da dificuldade desta tarefa, foram incluídos, na figura, os resultados de uma modelagem realizada utilizando um software estatístico tradicional, representado pelas cruzes (em azul). O modelo de regressão foi gerado com auxílio da ferramenta *Advanced Linear/Nonlinear Models* do *Software Estatística 8.0*. Foram utilizados na modelagem todos os dados coletados e usados no treinamento da rede.

Pode-se observar, na Figura 3, que existe uma boa aderência entre os valores estimados e os reais, evidenciando que a rede é capaz de capturar e reproduzir o comportamento não-linear desta relação. Como é possível notar, o melhor modelo tradicional obtido não conseguiu representar adequadamente o fenômeno, resultando numa simulação bastante rudimentar do comportamento da relação. A rede neural foi muito mais eficiente, mostrando alta flexibilidade e adaptabilidade.

As Figuras 4 e 5 apresentam os resultados das simulações, destacando a influência do fator idade de realização do ensaio, sendo que a Figura 5 ilustra a simulação realizada para idades iniciais do concreto (abaixo de 10 dias). Observa-se claramente a importância deste parâmetro para a evolução da resistência do concreto. Nota-se que, a partir da análise somente dos resultados de UPV, é possível encontrar valores muito dispersos para a resistência do concreto, visto que, para ambos os casos, são encontrados resultados semelhantes em todas as idades de ensaio. Este fato vem ilustrar a dificuldade de se proceder a uma análise do concreto somente com base nos resultados dos ensaios de UPV, ao mesmo tempo em que demonstra a importância de se utilizar técnicas mais robustas para análise do significado dos dados obtidos a partir de ensaios de UPV.

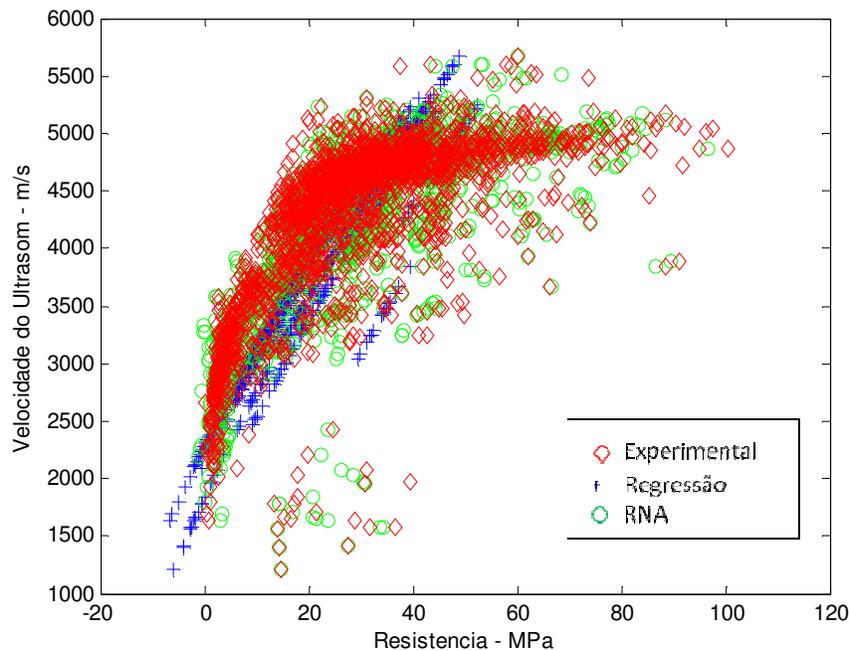


Figura 3. Modelagem da Rede Neural Artificial – RNA  $8 \times 8 \times 20 \times 20 \times 1$  – Dados de Treinamento.

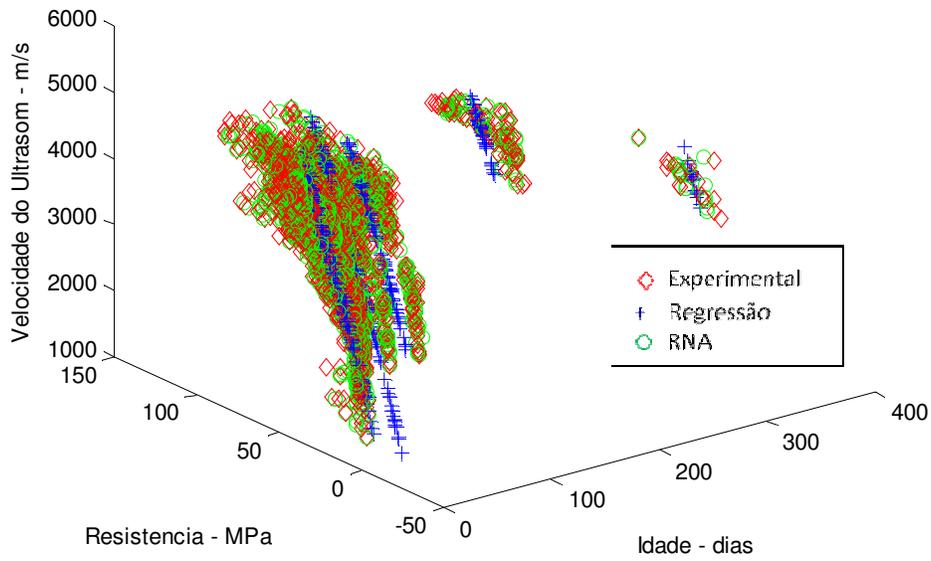


Figura 4 – Modelagem da Rede Neural Artificial para os parâmetros Resistência e UPV em função da Idade – Rede 8x8x20x20x1 – Dados de Treinamento.

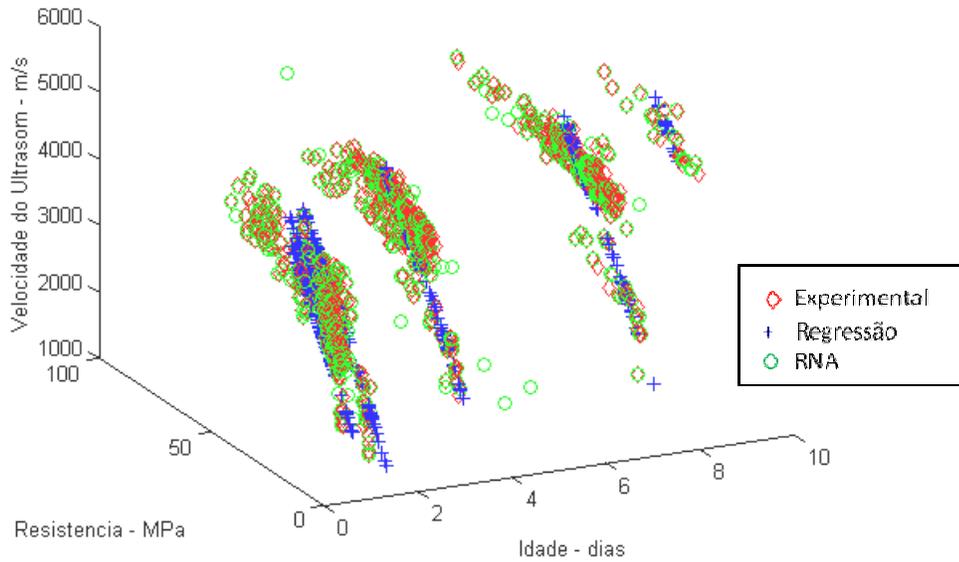


Figura 5 – Modelagem da Rede Neural Artificial em função para os parâmetros Resistência e UPV para as Idades Iniciais – Rede 8x8x20x20x1 – Dados de Treinamento.

De forma geral, os dados indicam que a utilização das RNAs permite a geração de modelos capazes de reproduzir o comportamento não-linear da relação UPV x  $F_c$ , o que é evidenciado pelo fato das simulações apresentarem coeficientes de correlação elevados. Este fato evidencia a potencialidade de aplicação destas ferramentas para a análise de dados que, em princípio, teriam uma correlação estatística muito pequena. Visualmente, pode-se perceber uma aderência muito boa entre os resultados obtidos através das RNAs e os resultados reais, apesar de existirem alguns pontos em que as RNAs ainda apresentam problemas de estimação, normalmente quando as resistências são muito baixas. Na Figura 6 observa-se a grande influência e importância da relação  $a/c$  para os concretos. Vislumbra-se, na figura, a evolução da resistência para os concretos analisados e pode-se notar claramente a contribuição da diminuição da redução da relação  $a/c$  para o aumento da resistência do concreto. Os resultados obtidos indicam que o aumento do número de neurônios nas camadas intermediárias colabora para melhorar as estimativas da rede.

As Figuras 7, 8 e 9 demonstram as simulações levando-se em consideração os parâmetros característicos de cada tipo de cimento empregado nesta base de dados. Os diferentes tipos de cimento empregados para esta simulação foram classificados, conforme as suas características (reatividade, adições e cor), em valores binários para cada um dos tipos de cimento. Pode-se observar que existe uma boa aderência entre os valores estimados pela RNA e pelos valores reais, evidenciando a grande capacidade da mesma de capturar, tratar os dados e reproduzir o comportamento não-linear da relação.

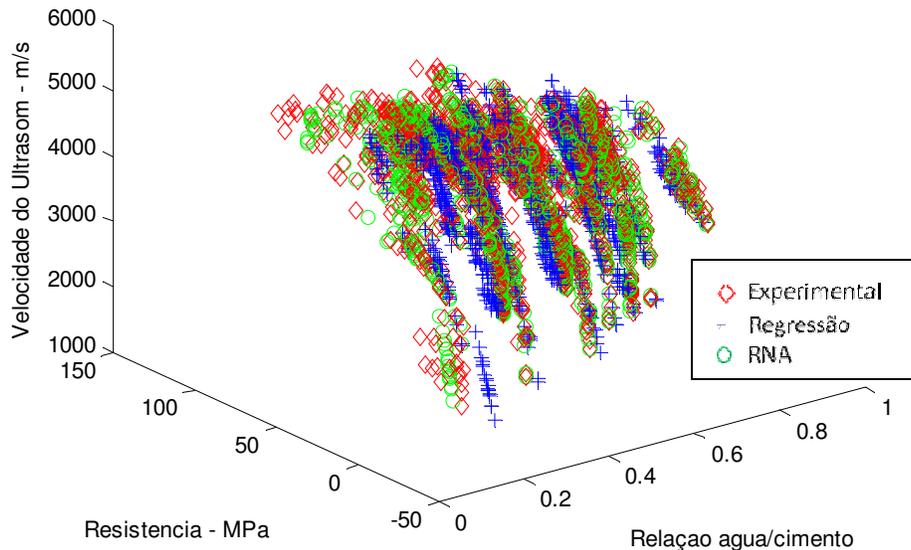


Figura 6 – Modelagem da Rede Neural Artificial em função da relação  $a/c$  – Rede 8x8x20x20x1 – Dados de Treinamento.

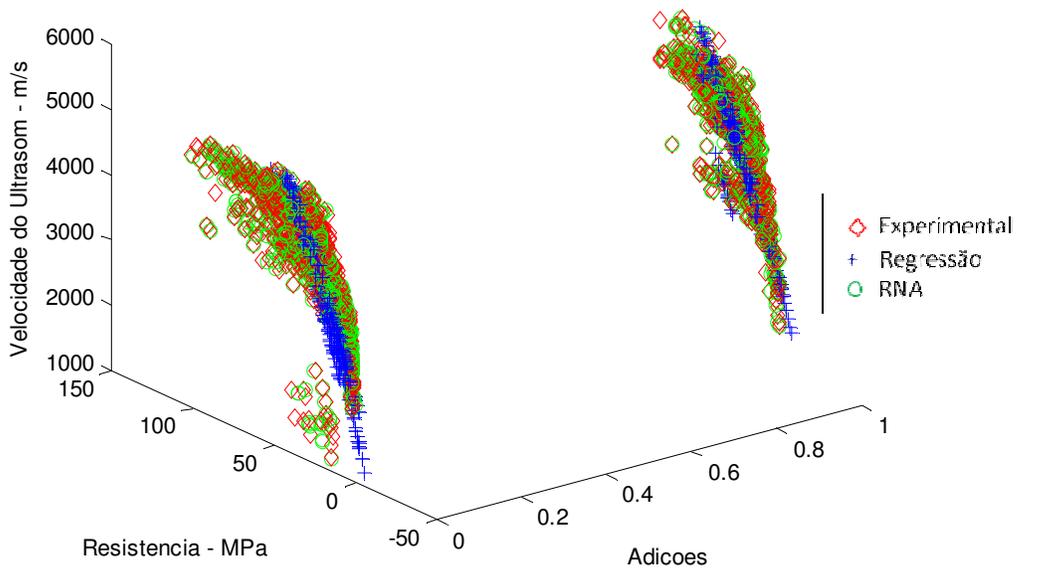


Figura 7 – Modelagem da Rede Neural Artificial em função das adições do cimento – Rede 8x8x20x20x1 – Dados de Treinamento.

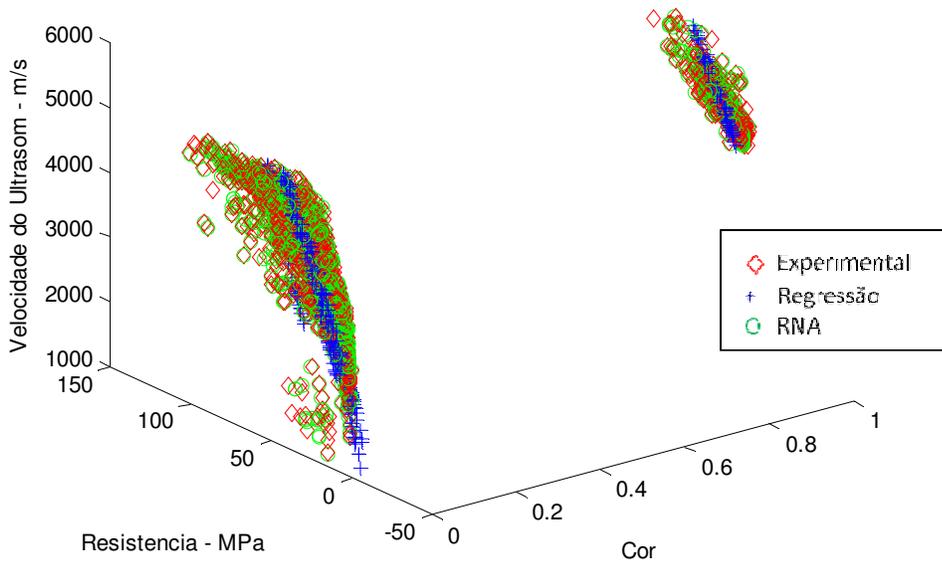


Figura 8 – Modelagem da Rede Neural Artificial em função das cores do cimento – Rede 8x8x20x20x1 – Dados de Treinamento.

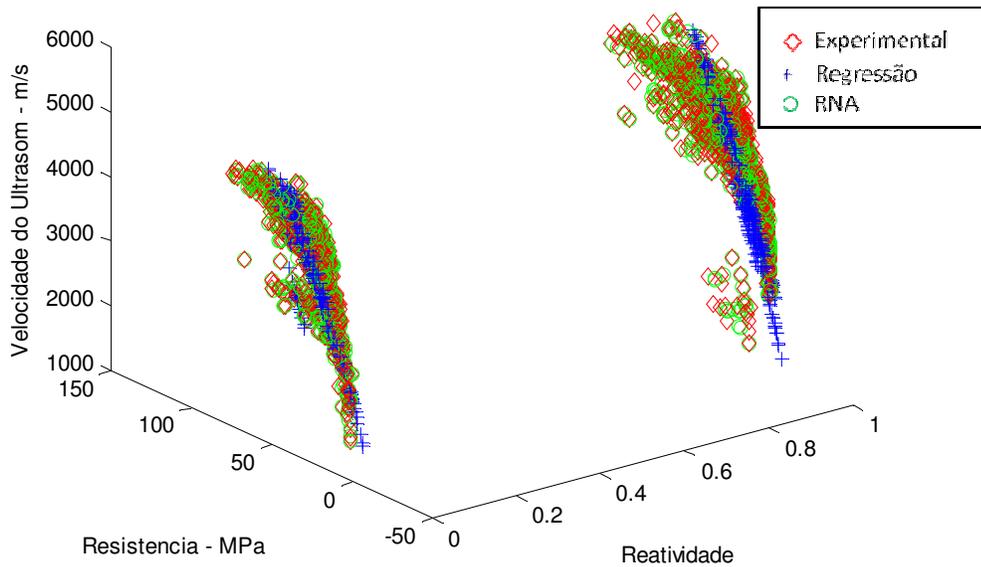


Figura 9 – Modelagem da Rede Neural Artificial em função da reatividade do cimento – Rede 8x8x20x20x1 – Dados de Treinamento.

As Figuras 10 a 16 mostram os resultados da simulação utilizando o banco de dados de teste. Consegue-se visualizar adequadamente o comportamento do concreto frente às variáveis utilizadas para análise. A utilização das RNAs comprova que é possível estimar o valor da resistência à compressão do concreto, a partir de resultados de ensaios de UPV e de parâmetros característicos do concreto. Esta simulação conseguiu extrapolar de maneira adequada os valores da etapa de treinamento para a etapa de teste. Desta forma, evidencia-se o grande poder de adaptabilidade das RNAs frente às incertezas dos processos.

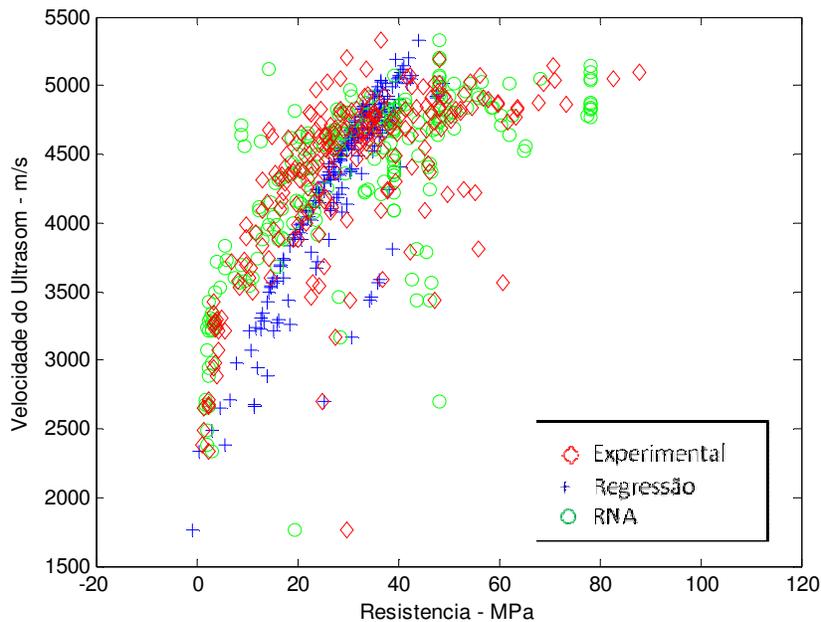


Figura 10 – Modelagem da relação VPU x Resistência à Compressão – RNA 8x20x20x1 – Dados de Teste.

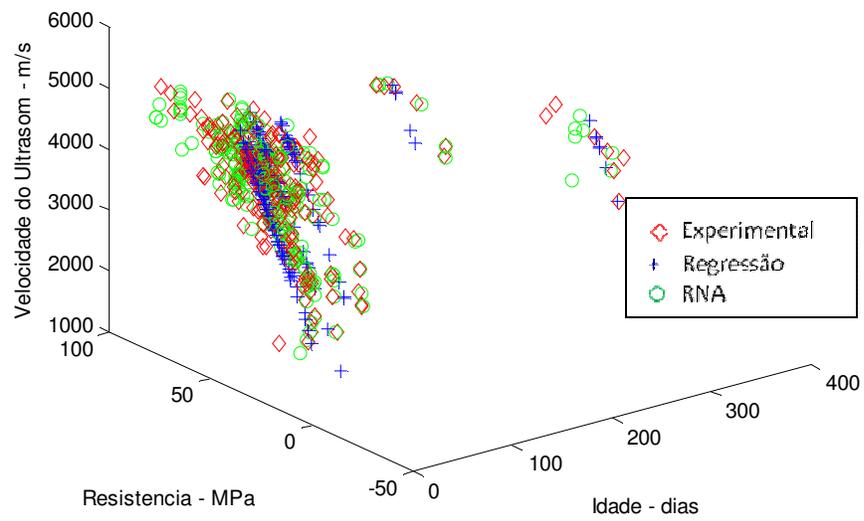


Figura 11 – Modelagem da relação VPU x Resistência à Compressão x Idade – RNA 8x20x20x1 – Dados de Teste.

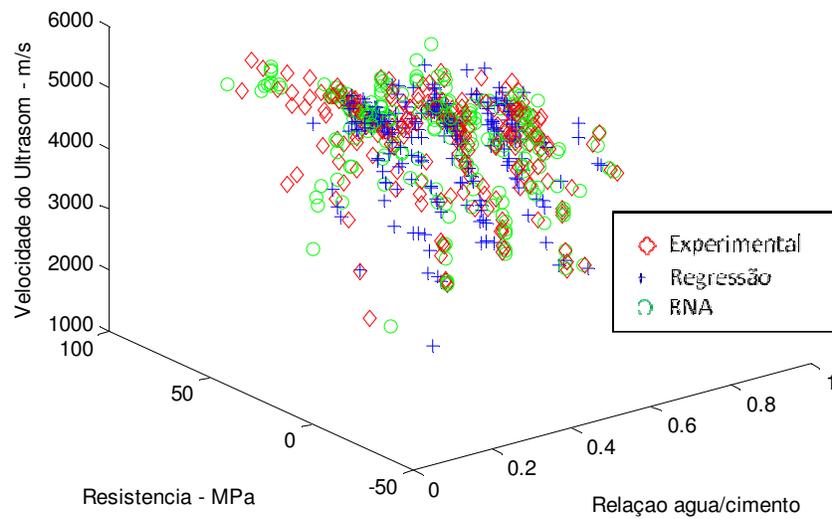


Figura 12 – Modelagem da relação VPU x Resistência à Compressão x Relação a/c – RNA 8x20x20x1 – Dados de Teste.

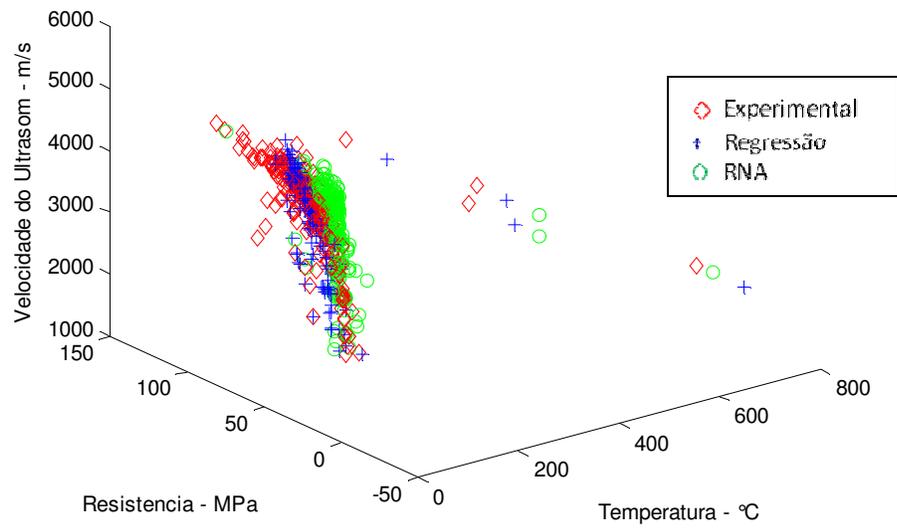


Figura 13 – Modelagem da relação VPU x Resistência à Compressão x Temperatura – RNA 8x20x20x1 – Dados de Teste.

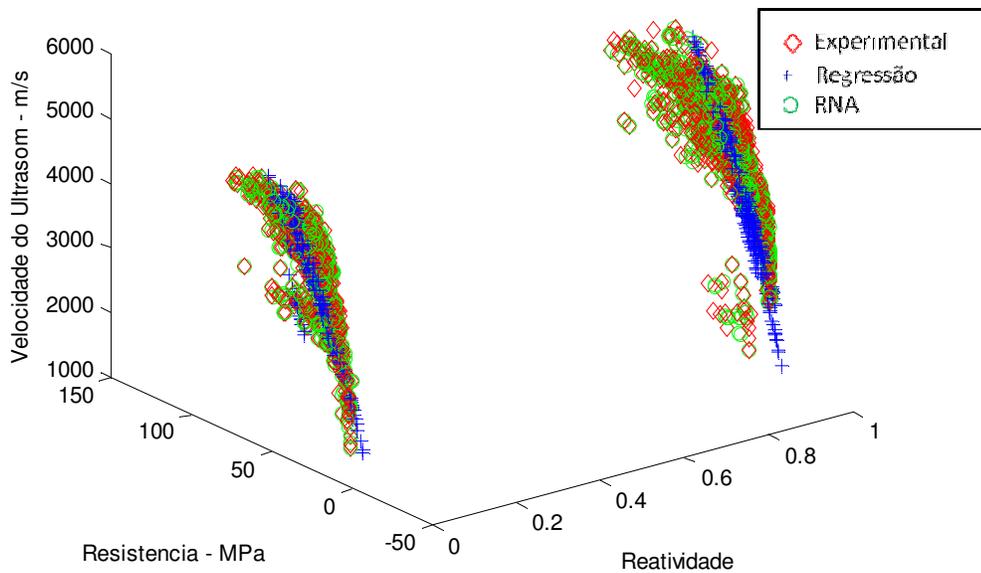


Figura 14 – Modelagem da relação VPU x Resistência à Compressão x Reatividade do Cimento – RNA 8x20x20x1 – Dados de Teste.

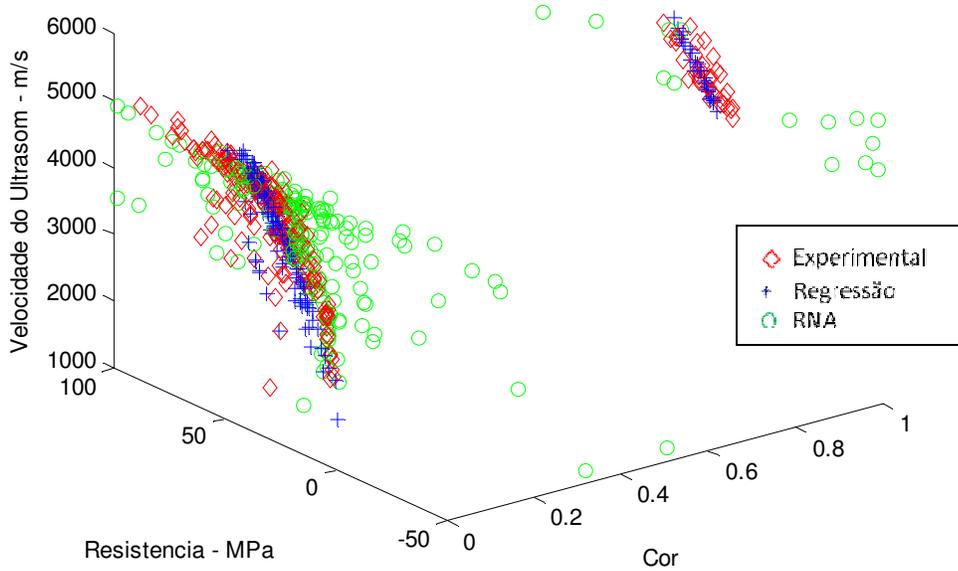


Figura 15 – Modelagem da relação VPU x Resistência à Compressão x Cor do Cimento – RNA 8x20x20x1 – Dados de Teste.

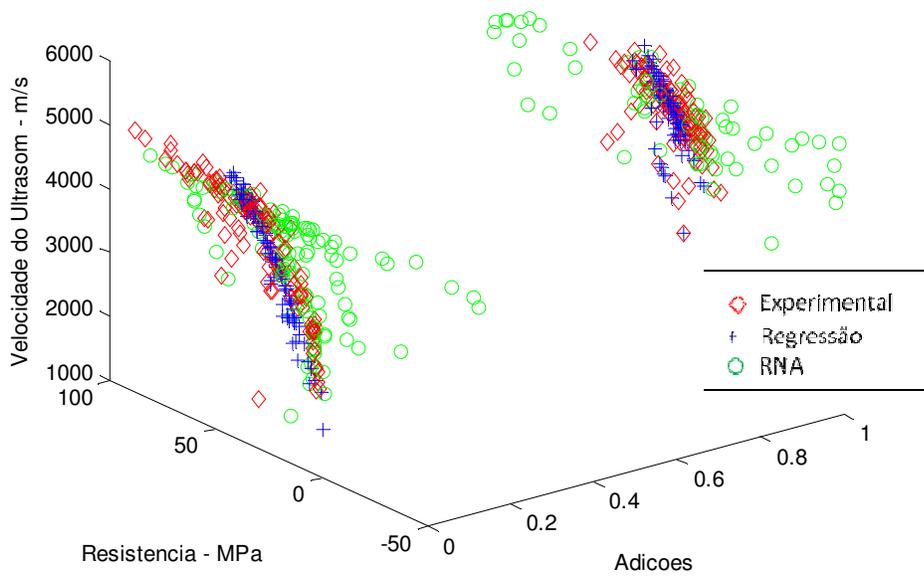


Figura 16 – Modelagem da relação VPU x Resistência à Compressão x Adições do Cimento – RNA 8x20x20x1 – Dados de Teste.

Com vistas a verificar qual o custo computacional derivado deste aumento de neurônios, a Tabela 2 ilustra alguns tempos registrados para fazer a simulação de diferentes redes. Podemos observar claramente, analisando a mesma, que o aumento no número de neurônios, em qualquer uma das camadas, corresponde a um acréscimo considerável do custo computacional despendido para realizar as simulações.

Tabela 2 – Tempo gasto no treinamento da rede.

Rede	Tempo (h)
8x2x4x4x1	00:15
8x2x20x20x1	01:32
8x4x20x20x1	03:00
8x6x20x20x1	04:50
8x8x20x20x1	07:17

As Figuras 17, 18, 19 e 20 mostram o erro médio obtido na etapa de treinamento pelas várias redes testadas. Pode-se observar claramente que o aumento do número de neurônios, tanto na camada de entrada quanto nas camadas ocultas, contribui significativamente para uma diminuição do erro médio da estimativa. Nas respectivas figuras, podemos observar que várias configurações de RNA obtiveram erros baixos (abaixo de 5 MPa), representados pela linha vermelha.

Em algumas redes simuladas, os erros médios das estimativas da resistência do concreto chegaram a valores absolutos de 2 MPa (RNA 6x20x20x1 e RNA 8x20x20x1). Este valor de erro é muito baixo para estruturas de concreto, principalmente quando se leva em consideração que a NBR 6118 – Projeto de Estrutura de Concreto (ABNT, 2007) preconiza que os valores mínimos da resistência à compressão do concreto é 20 MPa. Além disto, deve-se levar em conta que a amostra utilizada para proceder à simulação continha concretos com resistências elevadas (100 MPa). Isto evidencia o grande potencial de utilização desta técnica de simulação, tornando-se uma ferramenta poderosa para auxiliar na estimativa da resistência à compressão do concreto. Contudo, em alguns casos (RNA 8x4x16x1 e RNA 8x4x20x1), o resultado da simulação não foi adequado. Observa-se que a RNA com somente dois neurônios na primeira camada precisou de um número grande de neurônios nas camadas seguintes para atingir um resultado adequado. Nas demais simulações, o valor do erro médio foi inferior a 5MPa.

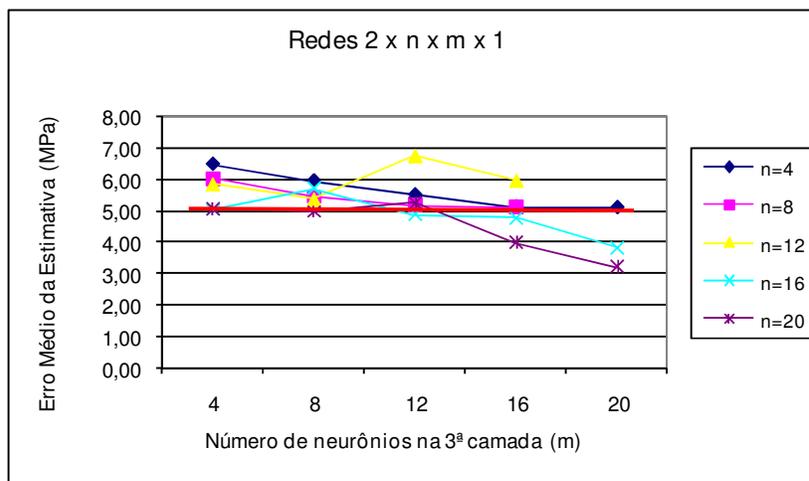


Figura 17 – Erro Médio (MPa) – Redes com 2 neurônios na 1ª camada oculta.

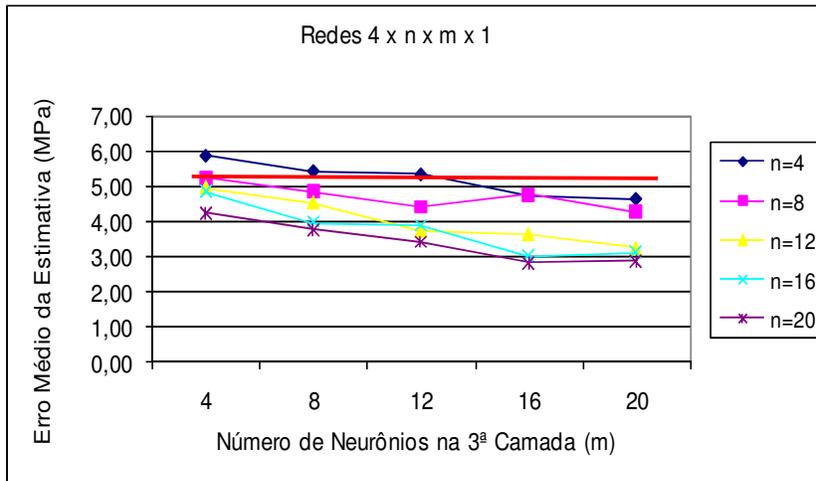


Figura 18 – Erro Médio (MPa) – Redes com 4 neurônios na 1ª camada oculta.

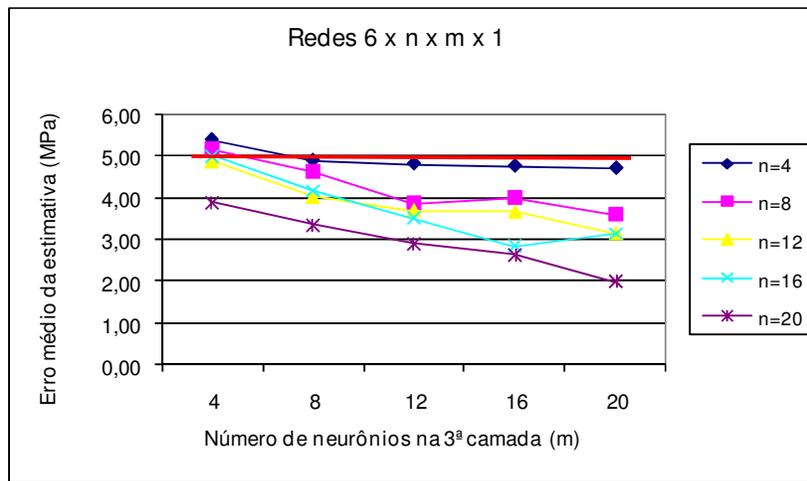


Figura 19 – Erro Médio (MPa) – Redes com 6 neurônios na 1ª camada oculta.

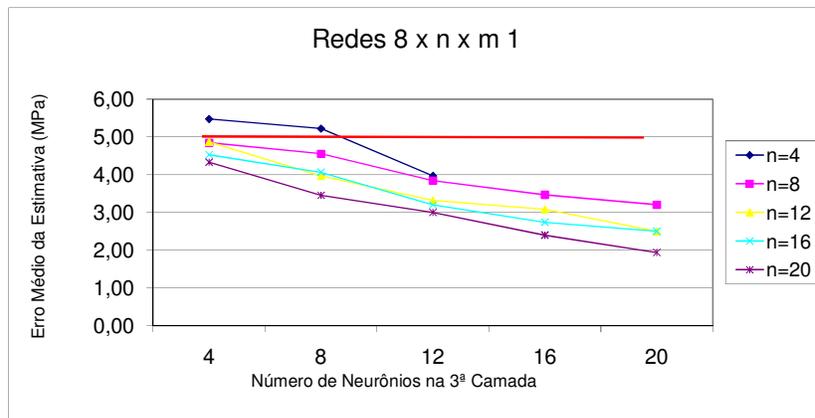


Figura 20 – Erro Médio (MPa) – Redes com 8 neurônios na 1ª camada oculta.

A Tabela 3 apresenta os erros da fase de treinamento e de teste para alguns dos modelos neurais gerados e compara os referidos erros encontrados com o melhor modelo estatístico gerado através do software *Statistica 8.0*, levando-se em consideração a mesma base de dados utilizada para treinamento da RNA. Pode-se observar que, mesmo as RNAs com menor número de neurônios em suas camadas ocultas, obtiveram valores de simulação bem melhores do que o modelo estatístico. Este resultado já era esperado, em virtude dos dados analisados serem de grande complexidade, corroborando com a necessidade de se utilizarem ferramentas de IA para análise de problemas complexos e de difícil interpretação na Engenharia Civil.

Tabela 3 – Erros (%)

RNAs	Treinamento	Teste	Modelo Estatístico
2x4x4x1	6,50	6,39	56,0
2x20x20x1	3,25	3,67	
4x20x20x1	2,99	3,24	
6x20x20x1	2,05	2,76	
8x20x20x1	1,99	2,43	
10x20x20x1	1,98	2,40	

Os modelos gerados pelas das RNAs mostraram-se bastante eficientes, pois obtiveram coeficientes de determinação ( $R^2$ ) acima de 95%, fato este que demonstra a grande utilidade destes modelos na análise de problemas complexos. Num universo de 100 (cem) RNAs treinadas e testadas, somente em quatro casos, obtiveram-se valores de  $R^2$  abaixo de 95%. Isto vem comprovar a grande utilidade e importância para a análise de dados de problemas complexos e de difícil interpretação.

A utilização das RNAs se mostra bastante capaz de reproduzir o comportamento não-linear desta relação, o que é evidenciado pelo fato de as simulações apresentarem coeficientes de correlação com graus de precisão muito elevados. Este fato demonstra a potencialidade de sua aplicação para a análise de dados que, em princípio, teriam uma correlação estatística muito pequena.

Visualmente, pode-se perceber uma aderência muito boa entre os resultados obtidos por meio da utilização das RNAs e os resultados reais, apesar de existirem alguns pontos em que a RNA ainda apresenta problemas de estimação. Os ensaios mostram que o aumento do número de neurônios nas camadas intermediárias colabora para a melhoria das estimativas da rede.

## 6 Conclusão

Os resultados obtidos no presente trabalho demonstram que a utilização das RNAs permite que seja realizado um mapeamento não-linear da relação resistência do concreto x velocidade de pulso ultrassônico, sendo que a precisão e flexibilidade dos modelos neurais aumentam quando se incluem, entre os parâmetros de entrada, dados normalmente conhecidos sobre o concreto, tais como o tipo de cimento, a temperatura de cura, a relação a/c e a idade.

Dentre os parâmetros utilizados neste estudo, constata-se que a idade e a relação a/c são os que influenciaram de maneira mais significativa os resultados do UPV e, conseqüentemente, a variável de resposta da simulação (resistência à compressão do concreto), embora estudos comprovem que a utilização somente destes dois parâmetros resultem numa simulação com erros médios de 4 %, o que é aceitável quando se tratar da análise de concretos com diferentes características.

Comprova-se, pela análise dos modelos obtidos, que o uso de um maior número de neurônios aumenta consideravelmente o poder explicativo das redes, porém, acarreta custos computacionais cada vez maiores. Com utilização de uma RNA 2x8x48x1, foi possível produzir estimativas com erros médios muito baixos e maior eficiência do que obtido com métodos tradicionais.

Isto evidencia que as RNAs se constituem em um meio rápido e preciso de interpretação dos resultados de fenômenos complexos, dada a sua capacidade de aprendizagem e de generalização do conhecimento adquirido. Porém, para que se possa obter bons resultados, é necessário que se utilize uma base de dados que contenha uma quantidade significativa de dados confiáveis sobre o fenômeno, com uma boa variação dos parâmetros considerados importantes.

Constatou-se que, dada sua capacidade de aprendizagem e de generalização do conhecimento adquirido, uma RNA pode se constituir em um meio rápido e preciso de interpretação dos resultados de fenômenos complexos. Todavia, é preciso utilizar uma base de dados que contenha uma quantidade significativa de resultados prévios (recomenda-se algo em torno de 2.000-3.000 dados), com uma boa variação dos parâmetros considerados importantes para a avaliação do comportamento da estrutura.

A partir dos resultados obtidos nesta pesquisa foi obtido, junto ao INPI – Instituto Nacional de Propriedade Intelectual, uma patente de Privilégio de Inovação: “Método de Determinação de Propriedades de Concreto Através do uso de Sistemas Complexos Não-Lineares de Tratamento de Dados e Dispositivo Compreendendo tal Método – PI 0702238-7”.

### Referências Bibliográficas

- ASTM E 114-95, 1995. *Annual Book of ASTM Standards Vol. 03.03 - Nondestructive Testing*, Standard Practice for Ultrasonic Pulse-Echo Straight-Beam Examination by the Contact Method. ASTM.
- ABNT-NBR 6118, 2007. Projeto de Estruturas de Concreto – Procedimento. ABNT.
- Braga, A. P., Ludermir, T. B., Carvalho, A. C. P., 2000. *Redes Neurais Artificiais – Teoria e aplicações*, LTC – Livros Técnicos e Científicos Editora S.A.
- Bray, D., Stanley, R. K., 1997. *Nondestructive Testing – A Tool in Design, Manufacturing, and Service*, CRC Press, Boca Raton, 586 p.
- El-Chabib, H., Nehdi, M., 2005. Neural network modeling of properties of cement-based materials demystified. *Advances in Cement Research*, vol 17, n.3, pp.91-102.
- Ezeldin, A. S., Sharara, L. M., 2006. Neural Networks for Estimating the Productivity of Concreting Activities. *Journal of Construction Engineering and Management*. vol 132, n. 6, pp. 650-656.
- Haykin, S., 2001. *Redes Neurais: Princípios e prática*. Bookman, Porto Alegre, 900 p.
- Hola, J., Schabowicz, K., 2005. Methodology of Neural Identification of Strength of Concrete. *ACI Materials Journal*. vol 102, n. 6, pp. 459-464.
- Kim, J., Kim, D. K., Feng, M. Q., Yazdani, F., 2004. Application of Neural Networks for Estimation of Concrete Strength. *Journal of Materials in Civil Engineering*. vol 16, n. 3, pp. 257-264.
- Meneghetti, L. C., Padaratz, I. J., Steil, R. O., 1999. Use of Ultrasound to Evaluate Concrete Strength in the Early Ages. In: Nesvijski, E. G. & Choutova, T. Eds, *International Symposium on Nondestructive Testing Contribution to the Infrastructure Safety Systems in the 21<sup>st</sup> Century (NDTISS 99)*, pp. 42-47.
- Nehdi, M., El Chabib, H., El Nagggar, M. H., 2001. Prediction Performance of Self-Compacting Concrete Mixtures using Artificial Neural Network. *ACI Materials Journal*. vol 98, n. 5, pp. 394-401.
- Neville, A. M., 1997. *Propriedades do Concreto*. Pini.
- Neville, A. M., Brooks, J. J., 1997. *Concrete Technology*. Longman Singapor Publishers Pte.
- Rajasekaran, S., 2004. Functional Networks in Structural Engineering. *Journal of Computing in Civil Engineering*. vol 18, n. 2, pp. 172-181.
- Oreta, A. W. C., Kawashima, K., 2003. Neural Network Modeling of Compressive Strength and Strain of Circular Concrete Columns. *Journal of Structural Engineering*. vol 129, n. 4, pp. 554-561.
- Oh, J.-W., Lee, I.-W., Kim, J.-T., Lee, G.-W., 1999. Application of Neural Networks for Proportioning of Concrete Mixes. *ACI Materials Journal*. vol 96, n. 1, pp. 61-68.
- Sanad, A., Saka, M. P., 2001. Prediction of ultimate Shear Strength of Reinforced-Concrete deep beams using Neural Networks. *Journal of Structural Engineering*, vol 127, n.7, pp.818-828.
- Taha, M. M. R., Nourelin, A., El-Sheimy, N., Shrive, N. G., 2003. Neural Network modelling of creep in masonry. *Structures & Buildings*, vol. SB4, n. 157, pp. 279-292.
- Tsai, C.-D., Wu, T.-T., Liu, Y.-H., 2001. Application of Neural Networks to Laser Ultrasonic NDE of Bonded Structures. *NDT&E International*. vol 34, n. 8, pp. 537-546.
- Ukrainczyk, N., Ukrainczyk, V., 2008. A Neural Network method for analyzing concrete durability. *Magazine of Concrete Research*, vol 60, n.7, pp.475-486.