

Validação dos parâmetros reológicos de argamassa autoadensável com cinza do bagaço de cana-de-açúcar: uma abordagem baseada em redes neurais *multilayer perceptron*

Rafael Germano Dal Molin Filho (UEM) rafagermano@gmail.com

Rodrigo Clemente Thom de Souza (UFPR) thom@ufpr.br

Romel Dias Vanderlei (UEM) rdvanderlei@uem.br

Paulo Roberto Paraíso (UEM) prparaíso@uem.br

Luiz Mário de Matos Jorge (UEM) lmjorge@uem.br

Resumo:

No desenvolvimento de argamassas autoadensáveis realizam-se ensaios reológicos que determinam a dosagem ótima dos componentes, relevando, entre outros parâmetros, os controles da viscosidade e da coesão. Dentre os ensaios destacam-se o teste do Tronco de Cone de Mesa de Consistência e o teste do Mini-Slump. Assumindo uma proposta que subsidie dar condição a utilização de resíduos industriais, foram realizadas investigações sobre algumas composições de superplastificante por cimento (sp/c) em argamassas autoadensáveis (AGA) com a substituição parcial de areia natural, por cinza do bagaço da cana-de-açúcar (CBC). A CBC é oriunda do processo cogeração de energia nas usinas de etanol e açúcar. As argamassas foram desenvolvidas por meio de adaptações do ensaio do Tronco de Cone de Mesa sobre os parâmetros de espalhamento relativo (G_m) e escoamento relativo (R_m). Para a validação dos valores obtidos pelas técnicas reológicas foram analisados os coeficientes de determinação de erro R^2 advindos da técnica de regressão quadrática, a qual foi obtida pelo emprego de um algoritmo de Rede Neural *Multilayer Perceptron* (MLP) no software *Matlab*. Foi possível determinar que os valores obtidos pelas técnicas reológicas possuem uma boa representatividade, pois seus coeficientes de determinação R^2 apresentaram valores ótimos de 0,997547 para G_m e 0,990140 para o R_m para investigações com 1 iteração, 10 *folds* e 5 neurônios na camada oculta da rede neural. Portanto, a AGA com a relação de 0,45 de sp/c e 0,25 de substituição de areia por cinza do bagaço da cana-de-açúcar é capaz de proporcionar uma economia de 25% de areia.

Palavras chave: Argamassa autoadensável, cinza do bagaço da cana-de-açúcar, redes neurais *multilayer perceptron*, resíduo industrial.

Validation of rheological parameters of self-compacting mortar with sugarcane bagasse ash: a multilayer perceptron neural networks driven approach

Abstract:

In the development of self-compacting mortars, rheological tests are carried out to determine the optimum dosage of the components, including viscosity and cohesion controls, among other parameters. The consistency table cone trunk test and the mini-slump test stand out. Assuming a proposal to subsidize the condition of the use of industrial waste, investigations were carried out on some cement superplasticizer compositions in self-compacting mortars (SCM) with partial substitution of natural sand by ash from sugarcane bagasse. The sugarcane bagasse ash comes from the process of cogeneration of energy in the ethanol and sugar mills. The mortars were developed by means of

adaptations of the table cone trunk test on the relative spreading and relative flow parameters. For the validation of the values obtained by rheological techniques, the R² error determination coefficients derived from the quadratic regression technique were analyzed using a Multilayer Perceptron Neural Networks algorithm (MLP) in Matlab software. It was possible to determine that the values obtained by the rheological techniques have a good representation, since their R² presented optimal values of 0.997547 for relative spreading and 0.990140 for flow parameters for investigations with an unique iteration, 10 folds and 5 neurons in the layer of the neural network. Therefore, the self-compacting mortars with a ratio of 0.45 cement superplasticizer and 0.25 sand substitution by sugarcane bagasse ash is capable of saving 25% of sand.

Key-words: self-compacting mortars, sugarcane bagasse ash, multilayer perceptron neural networks, industrial waste.

1. Introdução

A busca por fontes de energia renovável para a sociedade é uma temática que impulsiona diversas iniciativas de desenvolvimento no mundo. No Brasil, há um bom tempo, destaca-se nessa alçada a atuação do setor sucroalcooleiro, o qual inclusive possui notória contribuição para a formação das receitas nacionais de energia e de alimento. Somente os processos industriais e agrícolas com a cana-de-açúcar representam uma fatia de cerca de 3,65% do PIB brasileiro (SOUZA *et al.*, 2007; MOISÉS, 2014).

Dentre os resíduos gerados na cadeia de produção de açúcar, de etanol e de energia nas usinas, encontra-se a cinza do bagaço da cana-de-açúcar oriunda da queima do bagaço nas caldeiras. A CBC é um resíduo sólido de categoria rural e natureza de classe II e não inerte (ABNT NBR 10004, 2004; MOISÉS 2014; DE PAULA *et al.*, 2009). De acordo com os estudos de FIESP/CIESP (2001) e baseados nos dados da Conab (2017), estima-se que somente no estado do Paraná, a área de plantio para a safra 2017/2018 seja de 624,6 mil ha. Assim, há uma projeção de produção de 39.947.400 toneladas de cana-de-açúcar com um potencial de geração de até 248.000 toneladas de CBC.

A argamassa autoadensável (AGA - *self-compacting mortar SCM*) tem aplicação direta na produção de outros produtos fins da indústria da construção civil, como em peças da indústria de pré-moldados ou para o desenvolvimento de fases preliminares de outros componentes, como no caso para o concreto autoadensável (CAA). Existem estudos que avaliam a utilização de resíduos, subprodutos, compostos e até nano partículas na composição de AGA (GÜNEYISI *et al.*, 2016; LING; KOU; POON, 2016; KHOTBEHSARA *et al.*, 2015; SAFI *et al.*, 2015; GOMES, 2002; EFNARC, 2005; GOMES e BARROS, 2009; OKAMURA e OUCHI, 2003).

A AGA utiliza materiais finos, como a areia, que além de possuir forma e granulometrias muito próximas da CBC também apresenta como principal constituinte o dióxido de silício, SiO₂ (MOLIN FILHO, 2012; MOISÉS, 2014). As composições de AGA estudadas nesse trabalho foram desenvolvidas com a substituição parcial da areia por cinza dos bagaço da cana-de-açúcar conforme proposto por Molin Filho (2012). Os valores experimentais que foram assumidos pelas comprovações reológicas de Espalhamento Relativo (G_m) e Escoamento Relativo (R_m) foram validados pela análise de regressão quadrática. Como *outputs* destas análises foram gerados os coeficientes de determinação R² pelo emprego de um algoritmo de Rede Neural *Multilayer Perceptron (MLP)* desenvolvido no software *Matlab (Mathworks, Natick, USA)*.

2. Materiais e métodos

As composições estudadas continham cimento (CP II E 32), filer calcário calcítico, aditivo

químico superplastificante de terceira geração (Glenium 51 – Fabricante Basf), areia de origem quartzoza, CBC cristalina (queima na usina acima de 700 °C) e água em conformidade com ABNT NBR 15900. A areia possuía Massa Específica de 2642,5 kg/m³, diâmetro máximo característico de 0,6 mm e módulo de finura = 1,7 %. Já a CBC utilizada possuía a Massa Específica = 2640 kg/m³ com predominância de pelo menos 85% de SiO₂. A tabela 1 apresenta a composição da CBC estudada, pela investigação da Fluorescência de Raio-X (FRX). Trata-se da mesma amostra de cinza do trabalho de Moises (2014), a qual possuía um padrão difratográfico equivalente à cristais de quartzo quando submetida a análise de Difração de Raio-X (DRX).

Elementos	% em massa
SiO ₂	86,2
Al ₂ O ₃	2,8
K ₂ O	2,4
CaO	1,5
Fe ₂ O ₃	2,9
P ₂ O ₅	1,6
TiO ₂	1,9
Outros	0,7
Elementos	

Tabela 1 – Resultados da composição da CBC no FRX

As obtenções das argamassas estudadas foram baseadas nas técnicas empregadas por Molin Filho (2012), as quais foram adaptadas de Okamura (1999) e Okamura e Ouchi (2003). Realça-se que neste estudo serão considerados os parâmetros de dosagem que representam as relações unitárias em massa de superplastificante/cimento (sp/c) e de CBC por areia (CBC/ar).

Em suma, os valores do deslocamento em milímetro e do tempo em segundo obtidos nos ensaios de Molin Filho (2012) serviram para estimar os parâmetros reológicos R_m e G_m com base nas equações 1 e 2.

$$G_m = \left(\frac{d}{d_0} \right)^2 - 1,0$$

Equação 1 – Cálculo do parâmetro reológico de deslocamento G_m

Onde:

G_m = Espalhamento relativo, espera-se G_m de $5 \pm 0,5$,

d_0 = diâmetro inicial da mistura (mm),

d = diâmetro final do espalhamento (mm).

$$R_m = \frac{10}{t}$$

Equação 2 – Cálculo do tempo de escoamento relativo R_m

Onde:

R_m = Tempo de escoamento relativo, espera-se $R_m = 1 \pm 0,1$,

t = tempo de fluxo da argamassa (segundos).

Foram assumidas para as análises as faixas de substituição de: 5%, 10%, 20%, 25% de areia por CBC com melhores resultados de G_m e R_m .

3. O estudo de validação com Redes Neurais

As Redes Neurais Artificiais (RNs) – em inglês *Artificial Neural Networks*, ou simplesmente Redes Neurais (RN), são modelos capazes de descrever comportamentos de fenômenos não-lineares, que são, geralmente mais comuns na natureza e mais complexos (pois não podem ser descritos por uma combinação linear de suas variáveis) que fenômenos lineares (HAYKIN, 2001). As RN inspiram-se no comportamento biológico dos neurônios do cérebro humano com o objetivo de solucionar problemas de reconhecimento de padrões pela própria reprodução mimetizada e simplificada do cérebro na forma de sistemas computacionais (THOM DE SOUZA, 2008; CASTRO, 2007).

De maneira simplificada, as tarefas de reconhecimento de padrões realizadas pelas RN podem ser categorizadas em aprendizagem supervisionada e não-supervisionada. O presente artigo propõe a resolução de uma tarefa de aprendizagem supervisionada conhecida como regressão. Além disso, existem diversas abordagens de RN na literatura, tais como *Multilayer Perceptron (MLP)*, Função de Base Radial, Redes Recorrentes, Mapas Auto-organizáveis, entre outras. A abordagem assumida foi a *MLP*, utilizou para treinamento o algoritmo conhecido como *back-propagation* (THOM DE SOUZA, 2008; HAYKIN, 2001).

3.1 Análise dos coeficientes de determinação R^2 na Rede Neural

Classicamente a base da técnica de regressão quadrática para determinação do coeficiente de erro R^2 possui na sua conotação as relações da equação 3.

$$R^2 = \frac{\sum_{i=1}^n (y_i^* - y_m)^2}{\sum_{i=1}^n (y_i - y_m)^2} \Rightarrow \frac{SQ_{\text{preditos}}}{SQ_{\text{calculados}}}$$

Equação 3 – Cálculo convencional do coeficiente de determinação R^2

Onde:

SQ = representa a soma dos quadrados preditos (algoritmo) e dos calculados (equações 1 e 2)

R^2 = coeficiente de determinação

n = número de observações

y_i = valor observado na iteração

y_m = média das observações

y^* = é o valor calculado de G_m e R_m

Na tabela 2 os dados experimentais que foram objetos de estudo no algoritmo desenvolvido no *Matlab*. Ao todo foram utilizados treze conjuntos de dados, sendo 26 *inputs* e 26 *outputs*, agrupados sempre em duas colunas de *inputs* e uma de *outputs*.

Ensaio	Dependentes		Independentes (calculados)			
	sp/c %	Cbc %	G _m	Tempo (s)	R _m	Esp. (mm)
1	0,30	0,05	1,03	2,84	3,5	178
2	0,35	0,05	3,24	6,45	1,6	258
3	0,40	0,05	3,41	7,80	1,3	263
4	0,45	0,05	5,86	10,60	0,9	328
5	0,35	0,1	3,53	5,86	1,7	266
6	0,40	0,1	4,76	8,37	1,2	300
7	0,45	0,1	5,23	11,20	0,9	312
8	0,35	0,2	3,08	6,24	1,6	253
9	0,40	0,2	3,49	8,88	1,1	265
10	0,45	0,2	5,80	11,50	0,9	326
11	0,35	0,25	2,76	7,50	1,3	243
12	0,40	0,25	3,23	9,10	1,1	257
13	0,45	0,25	4,78	10,00	1,0	301

Tabela 2 – Dados utilizados na análise da RN

Os destaques em negrito na tabela 2 representam as dosagens que atendem plenamente os parâmetros de R_m e G_m estipulados nas equações 1 e 2.

3.2 A composição da Rede Neural *Multilayer Perceptron* (MLP).

A avaliação da capacidade preditiva de uma RN fundamenta-se nas fases de treinamento e validação. A implementação destas fases no presente artigo adotou o método conhecido como *cross validation* e assumiu como critério de avaliação de desempenho a análise do coeficiente de determinação R² na fase de validação. As demais informações operacionais de alimentação do algoritmo estão representadas nas alíneas.

- Estruturação de dez *folds* (*stratified 10-fold cross validation*) para organização de dados na RN, configuráveis no algoritmo;
- Utilização de apenas uma camada oculta de neurônio na transformação “caixa preta”;
- Cada um dos dois arquivos possuía três colunas com treze linhas (treze conjuntos de três dados) configuradas em uma tabela de formato “.csv”. A primeira coluna da tabela apresentava os *outputs*. A segunda e terceira colunas da tabela continham o conjunto de *inputs*. Isto tanto para a tabela G_m (parametrização 1), como para a R_m (parametrização 2);
- Variação de neurônios (perceptrons) de 2 a 5 na camada oculta para cada iteração de análise;
- Relação de cruzamento de *folds* de 90% treinamento versus 10% de validação. Sendo assim, cada iteração realizou dez investigações combinadas (Figura 1).


<table><tr><td></td><td>2</td><td>3</td><td>4</td><td>5</td></tr><tr><td>6</td><td>7</td><td>8</td><td>9</td><td>10</td></tr></table> Estágio 1		2	3	4	5	6	7	8	9	10	<table><tr><td>1</td><td></td><td>3</td><td>4</td><td>5</td></tr><tr><td>6</td><td>7</td><td>8</td><td>9</td><td>10</td></tr></table> Estágio 2	1		3	4	5	6	7	8	9	10
	2	3	4	5																	
6	7	8	9	10																	
1		3	4	5																	
6	7	8	9	10																	
<table><tr><td>1</td><td>2</td><td></td><td>4</td><td>5</td></tr><tr><td>6</td><td>7</td><td>8</td><td>9</td><td>10</td></tr></table> Estágio 3	1	2		4	5	6	7	8	9	10	<table><tr><td>1</td><td>2</td><td>3</td><td></td><td>5</td></tr><tr><td>6</td><td>7</td><td>8</td><td>9</td><td>10</td></tr></table> Estágio 4	1	2	3		5	6	7	8	9	10
1	2		4	5																	
6	7	8	9	10																	
1	2	3		5																	
6	7	8	9	10																	
<table><tr><td>1</td><td>2</td><td>3</td><td>4</td><td></td></tr><tr><td>6</td><td>7</td><td>8</td><td>9</td><td>10</td></tr></table> Estágio 5	1	2	3	4		6	7	8	9	10	<table><tr><td>1</td><td>2</td><td>3</td><td>4</td><td>5</td></tr><tr><td></td><td>7</td><td>8</td><td>9</td><td>10</td></tr></table> Estágio 6	1	2	3	4	5		7	8	9	10
1	2	3	4																		
6	7	8	9	10																	
1	2	3	4	5																	
	7	8	9	10																	
<table><tr><td>1</td><td>2</td><td>3</td><td>4</td><td>5</td></tr><tr><td>6</td><td></td><td>8</td><td>9</td><td>10</td></tr></table> Estágio 7	1	2	3	4	5	6		8	9	10	<table><tr><td>1</td><td>2</td><td>3</td><td>4</td><td>5</td></tr><tr><td>6</td><td>7</td><td></td><td>9</td><td>10</td></tr></table> Estágio 8	1	2	3	4	5	6	7		9	10
1	2	3	4	5																	
6		8	9	10																	
1	2	3	4	5																	
6	7		9	10																	
<table><tr><td>1</td><td>2</td><td>3</td><td>4</td><td>5</td></tr><tr><td>6</td><td>7</td><td>8</td><td></td><td>10</td></tr></table> Estágio 9	1	2	3	4	5	6	7	8		10	<table><tr><td>1</td><td>2</td><td>3</td><td>4</td><td>5</td></tr><tr><td>6</td><td>7</td><td>8</td><td>9</td><td></td></tr></table> Estágio 10	1	2	3	4	5	6	7	8	9	
1	2	3	4	5																	
6	7	8		10																	
1	2	3	4	5																	
6	7	8	9																		

Figura 1 – Validação cruzada para dez *folds* em uma iteração

Na figura 1 estão apresentadas as definições dos *folds* de validação. Os *folds* destacados com o fundo em negro em cada estágio, são os validadores após o treino. Durante a validação cruzada dos resultados, como por exemplo, no estágio 2, os *folds* 1, 3, 4, 5, 6, 7, 8, 9 e 10 (90% dos *folds*) são utilizados para a fase de treinamento e os *inputs* do *fold* 2 (10% dos *folds*) para a fase de validação.

3.3 A interface de interação do algoritmo RN MLP no Matlab

Para o desenvolvimento da análise de regressão quadrática foi utilizado um algoritmo RN MLP no Matlab, designado como *Main.m*. Ele está na plataforma de um algoritmo de regressão assumido como *Regression Algorithm* e determina o direcionamento das ações de outros algoritmos satélites desenvolvidos. Na sequência, nas figuras de 2 a 7 serão apresentadas as informações para o MLP na parametrização 1 de G_m , para favorecer a compreensão de como é a interface usual da plataforma do algoritmo *Main.m*.



```

5 - disp(['REGRESSION ALGORITHM']);
6 - disp([' ']);
7
8 *****
9  * INPUT *
10 *****
11
12
Command Window
REGRESSION ALGORITHM
Choose the number of iterations:

```

Figura 2 – Tela inicial

Após clicar em “Run” na tela operacional do Matlab abre-se no “Command Window” o

pedido pelo número de iterações propostas. Na sequência, a figura 3 ilustra a opção pela geração pelo parâmetro G_m , no caso opção 1.

```
REGRESSION ALGORITHM

Choose the number of iterations: 1

Choose the dataset:
1 = gm
2 = rm
```

Figura 3 – Seleção do parâmetro 1 (Gm) ou do parâmetro 2 (Rm)

Na próxima etapa o algoritmo carrega uma tabela “.csv” com os parâmetros lançados correspondente de *outputs* (primeira coluna) e *inputs* (segunda e terceira), no caso para G_m (Figura 4).

```
dataSet =

1.0300    0.3000    0.0500
3.2400    0.3500    0.0500
3.4100    0.4000    0.0500
5.8600    0.4500    0.0500
3.5300    0.3500    0.1000
4.7600    0.4000    0.1000
5.2300    0.4500    0.1000
3.0800    0.3500    0.2000
3.4900    0.4000    0.2000
5.8000    0.4500    0.2000
2.7600    0.3500    0.2500
3.2300    0.4000    0.2500
4.7800    0.4500    0.2500

Choose the number of folds to the stratified cross-validation:
```

Figura 4 – O algoritmo carrega a tabela de origem .csv

Na sequência determina-se o número de *folds*, conforme ilustra a figura 5. Nesta exemplificação assumem-se 10.

```
Choose the number of folds to the stratified cross-validation:

10
```

Figura 5 – Escolhendo o número de *folds*

O algoritmo desenvolvido além da análise MLP (opção 2) também realiza análises de regressões lineares, declarada no algoritmo como *Linear Regression* (opção 1). Logo, a próxima etapa foi a definição do algoritmo a ser utilizado conforme apresenta a figura 6, a opção assumida é a 2.

```
Choose the number of folds to the stratified cross-validation:

10

Choose the regression algorithm:
1 = Linear Regression
2 = MLP NN
```

Figura 6 – Escolhendo o algoritmo

A última escolha de refinamento fica por conta da definição da quantidade de neurônios (*perceptrons*) da camada oculta, conforme apresenta a figura 7. Assumiu-se como padrão 5 neurônios.

```
Choose the regression algorithm:
1 = Linear Regression
2 = MLP NN

2
Choose the number of neurons in hidden layer:
5
```

Figura 7 – Escolha do número de perceptrons

Os *outputs* gerados pelo algoritmo estão apresentados na figura 8, onde observa-se o coeficiente R^2 e o custo computacional baseado no tempo em segundos (*Computational cost*).

```
Choose the number of neurons in hidden layer:
5

Iteration #1 | R2: 96.4289%

Dataset: gm.csv
Number of Instances: 13
Number of Prediction Attributes: 2
Validation algorithm: 10-fold Cross-Validation
Algorithm: MLP NN
Number of iterations: 1
R2: 96.4289%
Computational cost: 37.1623 seconds
```

Figura 8 – Demonstrativo final do algoritmo

Na figura VIII apresenta-se o estrato dos resultados finais do algoritmo de redes neurais com um valor interessante de 96,4289% para o R^2 . O custo computacional nesta simulação foi de 37.1623 segundos.

3.4 Análise dos resultados

Os resultados obtidos pelas análise *Multilayer Perceptron (MLP)* no *Matlab*, com apenas uma iteração, estão apresentados na tabela 3.

Algoritmo (10 folds)	Neurônios na camada oculta	R ² (%)	
		G _m	R _m
Multilayer Perceptron (MLP) com uma única camada oculta	2	98,6995	91,9706
	3	98,3580	99,3954
	4	91,7932	81,7990
	5	99,7547	99,0014

Tabela 3 – Valores de R^2 para análise de *outputs* G_m e R_m

Considerando os dados da tabela 2 é possível relacionar que os valores preditos (algoritmo) versus o valor calculado (equações 1 e 2) possuem ótimos valores de correlação. Foram obtidos resultados superiores a 90% em três das quatro análises. Os treinamentos/validações dos valores dos *inputs* mostraram que é possível obter resultados bem satisfatórios para G_m e R_m, mesmo com apenas uma iteração, para as redes de 2, 3 e 5 neurônios na camada oculta. Todos os custos computacionais foram inferiores a 38 segundos para um computador com processador Core™ i5. A figura 9 ilustra dois momentos de leituras no algoritmo *Main.m*. para dois dos dez *folds*. No primeiro momento (figura 9a) uma leitura de iteração de um *fold* com apenas um neurônio e no segundo momento (figura 9b) a leitura de um *fold* com 2 neurônios.




Figura 9 – Exemplos de gráficos gerados pelo algoritmo

Realça-se que o algoritmo *Main.m* forma a composição dos valores de *sp/c* (*Dependent Variable*) com a iteração dinâmica dos testes e validações. No instante apresentado na figura 9a, a leitura no algoritmo neural *mean* apresenta o valor de 0,05 para *sp/c*, tal qual o valor suposto de observação pela rede neural, porém diferente do valor de predição do cálculo instantâneo do parâmetro, que era de 0,17. Na figura 9b realiza-se a leitura dupla pela presença de dois neurônios no mesmo *fold*, observa-se que o valor *mean* mantém-se constante.

Contudo, enfatiza-se que um número maior de iteração poderia favorecer o entendimento melhor sobre a relação R^2 dos valores experimentais. Da mesma forma, pode-se realizar novas simulações com um número de *folds* menor, relevando-se que foi adotado um padrão de *folds* grande em relação a população amostral. No entanto, enfatiza-se que o foco era de fato realizar bons treinos para favorecer um teste mais assertivo de valores para avaliação do R^2 .

4. Conclusão

As análises realizadas com o auxílio do algoritmo de redes neurais *MLP* no *Matlab*, apresentaram bons índices de desempenho para o coeficiente de determinação de correlação R^2 . O algoritmo de *RN MLP* apresentou um melhor desempenho nas bases de correlação quando utilizou 5 neurônios na camada oculta.

As composições 7 (*sp/c* 0,45 e *CBC/ar* 0,10) e 13 (*sp/c* 0,45 e *CBC/ar* 0,25) da tabela 1 podem ser utilizadas para produzir AGA pois atendem as especificações de G_m e R_m e, os respectivos coeficientes R^2 das suas categorias, investigados com 5 neurônios na camada oculta apresentam excelentes resultados, 0,997547 e 0,990140. Em termos diretos é possível substituir 25% da areia por cinza do bagaço de cana-de-açúcar para a produção de argamassa autoadensável.

Por fim, realça-se que para implementações futuras, vale a perspectiva de treinar/validar novos valores com a rede neural para posteriores testes experimentais de comprovação. Para isso, recomenda-se uma maior quantidade de iterações e com um número maior de *inputs* e *outputs*.

Referências

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. ABNT NBR 10004. *Resíduos Sólidos – classificação*. Rio de Janeiro, 2004.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. ABNT NBR 15900. *Água para amassamento do concreto - requisitos*. Rio de Janeiro, 2009.

CASTRO, L. N. *Fundamentals of natural computing: an overview*. Physics of Life Reviews, Vol. 4, No. 1, p. 1-36, 2007.

CONAB - COMPANHIA NACIONAL DE ABASTECIMENTO. *Acompanhamento de safra brasileira: cana-de-açúcar*. Primeiro levantamento, abril. Brasília : CONAB 2017. Disponível em: < <http://www.conab.gov.br/conteudos.php?a=1253&> >. Acesso em: 02 ago. 2017.

DE PAULA, M. O.; TINÔCO, I.F.F.; RODRIGUES, C. S.; DA SILVA, E. N.; SOUZA, C. F.; Potencial da cinza do bagaço da cana-de-açúcar como material de substituição parcial de cimento Portland. *Revista Brasileira de Engenharia Agrícola e Ambiental*.v.13, n.3, p.353-357, 2009.

EFNARC - EUROPEAN FEDERATION FOR SPECIALIST CONSTRUCTION CHEMICALS AND CONCRETE SYSTEMS. The Europe Guidelines for Self-Compacting Concrete – Specification, Production and Use. In: *EFNARC* Maio, 2005. Disponível em: <http://www.EFNARC.org/pdf/SCCGuidelinesMay2005.pdf>. Acesso em: 12 ago. 2017.

FIESP/CIESP – FEDERAÇÃO DA INDÚSTRIAS DO ESTADO DE SÃO PAULO/ CENTRO DAS INDÚSTRIAS DO ESTADO DE SÃO PAULO. *Ampliação da oferta de energia através da biomassa*. São Paulo: 2001. Disponível em: < <http://www.fiesp.com.br/indices-pesquisas-e-publicacoes/ampliacao-da-oferta-de-energia-atraves-de-biomassa/> >. Acessado em: 03 ago. 2017.

GOMES, P. C. C. *Optimization and Characterization of High-Strength Self- Compacting Concrete*. 2002, 139 p. Tese de Doutorado. Curso de Pós-Graduação em Engenharia Civil, Universitat Politècnica de Catalunya, Barcelona, 2002.

GOMES, P. C. C.; BARROS, A. R. de. *Métodos de dosagem de concreto autoadensável*. São Paulo: Pini, 2009.

GÜNEYISI, E.; GESOGLU, M.; GHANIM, H.; İPEK, S.; TAHA, I. Influence of the artificial lightweight aggregate on fresh properties and compressive strength of the self-compacting mortars. *Construction and Building Materials*, 30 July 2016, Vol.116, pp.151-158.

HAYKIN, S. S. *Redes neurais: princípios e prática*. 2a ed. Porto Alegre, RS: Bookman, 2001.

KHOTBEHSARA, M. M.; MOHSENI, E.; YAZDI, M. A.; SARKER, P.; RANJBAR, M. M. Effect of nano-CuO and fly ash on the properties of self-compacting mortar. *Construction and Building Materials*, 30 September 2015. Vol.94, pp.758-766

LING, T-C.; KOU, S-C.; POON, C. S. Precast architectural tiles produced by double-layer casting method. *Cement and Concrete Composites*, February 2016, Vol.66, pp.73-81.

MOISÉS, M. P. *Síntese de Zeólitas a partir de resíduos sólidos e sua aplicação como material bioativo e adsorvente de gases*. 2014, 89 p. Doutorado em Química. Universidade Estadual de Maringá, Maringá, 2014.

MOLIN FILHO, R. G. D. *Concreto auto-adensável com cinza do bagaço da cana-de-açúcar*. 2012, 164 p. Mestrado em Engenharia Urbana. Universidade Estadual de Maringá, Maringá, 2012.

OKAMURA, H. *Self-compacting concrete. Development, present use and future*. Edição: A. Skarendhal; Petersson. In: International Rilem Symposium on Self-compacting Concrete, 1st, 1999, Stockholm. Proceedings. RILEM Publications, France, 3-14, 1999.

OKAMURA, H.; OUCHI, M. Self-compacting concrete. *Jornal of advance concrete technology*, v. 1, n. 1, p 5-15, 2003.

SAFI, B.; SAIDI, M.; DAOUI, A.; BELLAL, AHMED ; MECHEKAK, ALI; TOUMI, K. The use of seashells as a fine aggregate (by sand substitution) in self-compacting mortar (SCM). *Construction and Building Materials*, 1 March 2015, Vol.78, pp.430-438.

SOUZA, G. N.; FORMAGINI, S.; CUSTÓDIO, F. O.; SILVEIRA, M. M. Desenvolvimento de Argamassas com Substituição Parcial do Cimento Portland por Cinzas Residuais do Bagaço de Cana-de-açúcar. 2007. In: 49º Congresso Brasileiro do Concreto – IBRACON. Anais... Bento Gonçalves, Brasil: IBRACON. CD- ROM.

THOM DE SOUZA, R. C. *Previsão de Séries Temporais Utilizando Rede Neural Treinada por Filtro de Kalman e Evolução Diferencial*. 2008, 85 p. Mestrado em Engenharia de Produção e Sistemas. Pontifícia Universidade Católica do Paraná, Curitiba, 2008.



Agradecimentos

A CAPES pelo incentivo dado aos pesquisadores. Ao laboratório de materiais de construção civil do DEC-UEM. A BASF S/A do Brasil pelo patrocínio do aditivo. Ao grupo Usaçúcar por todo incentivo e doação da CBC.