



**Diogo Faria de Sousa**

**Uso da Inteligência Artificial para Predição da Retração por  
Secagem do Concreto**

**Dissertação de Mestrado**

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Engenharia Civil do departamento de Engenharia Civil e Ambiental da PUC-Rio.

Orientador: Prof. Flávio de Andrade Silva  
Co-orientadora: Profª. Amanda Lemette Teixeira Brandão

Rio de Janeiro  
Setembro de 2023



**Diogo Faria de Sousa**

**Uso da Inteligência Artificial para Predição da Retração por  
Secagem do Concreto**

Dissertação apresentada como requisito parcial para obtenção  
do grau de Mestre pelo Programa de Pós-Graduação em  
Engenharia Civil da PUC-Rio. Aprovada pela Comissão  
Examinadora abaixo.

**Prof. Flávio de Andrade Silva**

Orientador

Departamento de Engenharia Civil e Ambiental - PUC-Rio

**Prof.<sup>a</sup>. Amanda Lemette Teixeira Brandão**

Co-orientadora

Departamento de Engenharia Química e de Materiais – PUC-Rio

**Prof. Sérgio Botassi dos Santos**

Escola Politécnica e de Artes - PUC-Goiás

**Prof.<sup>a</sup>. Lourdes Maria Silva de Souza**

Departamento de Engenharia Civil e Ambiental - PUC-Rio

Rio de Janeiro, 27 de setembro de 2023

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, do autor e do orientador.

**Diogo Faria de Sousa**

Graduado em Engenharia Civil pela Escola de Engenharia da PUC Goiás (Dignidade Acadêmica *Cum Laude*) – em 2016.

**Ficha Catalográfica**

Sousa, Diogo Faria de

Uso da inteligência artificial para predição da retração por secagem do concreto / Diogo Faria de Sousa ; orientador: Flávio de Andrade Silva ; coorientadora: Amanda Lemette Teixeira Brandão. – 2023.

187 f. : il. color. ; 30 cm

Dissertação (mestrado)—Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Civil e Ambiental, 2023.

Inclui bibliografia

1. Engenharia Civil e Ambiental - Teses. 2. Retração do concreto. 3. Fissuração. 4. Predição. 5. Inteligência artificial. 6. Redes neurais artificiais. I. Silva, Flávio de Andrade. II. Brandão, Amanda Lemette Teixeira. III. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Civil e Ambiental. IV. Título.

CDD: 624

## Agradecimentos

Primeiramente gostaria de agradecer a Deus por esta oportunidade de cursar este mestrado, ao apoio da minha esposa, Tállita, e aos meus filhos, Bernardo e Arthur, por estarem ao meu lado e me apoiarem nos momentos de conciliação do tempo com o mestrado, a família e o trabalho. Aos meus pais Júnior e Sônia por todo apoio desde a graduação, acreditando sempre que o caminho dos estudos pode levar sempre mais longe.

Ao meu orientador Flávio de Andrade Silva, por me incentivar e acreditar em meu potencial na pesquisa aplicada, confiando este grande trabalho a minha pessoa e sempre apoiando no desenvolvimento do profissional em campo através da pesquisa.

Gostaria de agradecer a minha co-orientadora Amanda Lemette Teixeira Brandão pelo auxílio fundamental da minha pesquisa ao ingresso no mundo da inteligência artificial. Ao amigo Francisco José Burok Teixeira Leite Strunck nas orientações do modelo para o desenvolvimento deste estudo.

Aos novos amigos que fiz na PUC-Rio, que me acompanharam nas matérias e que me ajudaram no desenvolvimento do trabalho.

À Chimica Edile do Brasil, pela doação do banco de dados para realização desta pesquisa e ao Prof. Zdeněk Bažant pelo livre acesso ao banco mundial de dados de concreto.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

## **Resumo**

Faria, Diogo de Sousa; Silva, Flávio de Andrade (Orientador). **Uso da Inteligência Artificial para Predição da Retração por Secagem do Concreto.** Rio de Janeiro, 2023. 187p. Dissertação de Mestrado – Departamento de Engenharia Civil e Ambiental, Pontifícia Universidade Católica do Rio de Janeiro.

Devido a variações volumétricas do concreto, a compreensão dos mecanismos da retração tornou-se ponto importante para redução de fissuras e, consequentemente, da penetração de agentes agressivos. Apesar do aumento do número de estudos experimentais de retração por secagem e autógena ainda é necessário o desenvolvimento de novos modelos analíticos e numéricos para a predição da retração apoiando assim o projeto de estruturas de concreto. Este estudo propôs um modelo de redes neurais artificiais para a predição da retração por secagem do concreto. Um banco de dados nacionais contendo 689 leituras de retração por secagem em mais de 90 dosagens diferentes de concreto convencional foi construído, de acordo com a NBR 16834. O modelo teve como dados de entrada para a predição da retração o consumo e tipo de cimento, aditivo retardador e plastificante, compensador de retração, relação água/cimento e idade do concreto. O modelo apresentou coeficientes de determinação ( $R^2$ ) para dados de treino e teste acima de 0,998 e 0,906, respectivamente, comprovando que o modelo é uma importante ferramenta para a predição da retração por secagem para tomadas de decisão durante os estudos iniciais na fase de projeto e dosagem do concreto.

## **Palavras-chave**

Retração do concreto; Fissuração; Predição; Inteligência Artificial; Redes Neurais Artificiais.

## **Abstract**

Faria, Diogo de Sousa; Silva, Flávio de Andrade (Advisor). **The Use of Artificial Intelligent for Predicting Concrete Drying Shrinkage.** Rio de Janeiro, 2023. 187p. Dissertação de Mestrado – Departamento de Engenharia Civil e Ambiental, Pontifícia Universidade Católica do Rio de Janeiro.

Due to volume change effects of concrete, understanding the mechanisms of shrinkage has become an important point for reducing cracks and, consequently, the penetration of deleterious agents into concrete structures. Despite the increase in experimental studies on concrete drying and autogenous shrinkage there is still a need to develop new analytical and numerical methods to predict shrinkage supporting the design of concrete structures. This study proposed an Artificial Neural Network (ANN) model to predict the concrete drying shrinkage. A national database containing 689 experimental shrinkage data records, in more than 90 different mixtures of conventional concrete was constructed, in accordance with NBR 16834. The model had as input data for predicting shrinkage the consumption and type of cement, retarding and plasticizer additive, shrinkage compensator, water/cement ratio and age of concrete. The model presented coefficients of determination( $R^2$ ) for training and test data above 0,998 and 0,906, proving that the model is an important tool for predicting drying shrinkage for decision making during the initial study in the design phase and concrete mix design .

## **Keywords**

Shrinkage; Cracks; Prediction; Machine Learning; Artificial Neural Network.

## **Sumário**

<b>1 Introdução</b>	<b>17</b>
1.1. Panorama Geral	17
1.2. Objetivos	18
1.3. Estrutura da Dissertação	18
<b>2 Revisão bibliográfica</b>	<b>20</b>
2.1. Retração do Concreto	20
2.2. Tipos e Ensaios de Retração do Concreto	22
2.3. Métodos de Predição	25
2.4. Meios de Mitigação para Retração do Concreto	26
2.4.1. Dosagem	27
2.4.2. Aditivos Redutores de Retração	28
2.4.3. Adição - Fibra	28
2.4.4. Concreto com Retração Compensada	30
2.4.5. Cura Interna do Concreto	32
2.5. Inteligência Artificial	34
2.5.1. Redes Neurais Artificiais	37
2.5.2. Uso de RNAs para Predizer Características do Concreto	40
<b>3 Metodologia</b>	<b>47</b>
3.1. Aquisição dos Bancos de Dados	47
3.2. Análise dos Dados Nacionais	48
3.3. Desenvolvimento do Modelo de Redes	57
<b>4 Resultados e Discussões</b>	<b>61</b>
4.1. RNA Treinamento e Performance	61
4.2. RNA Teste	62
4.3. RNA Avaliação	64
4.4. RNA para o Banco de Dados Internacionais	65
<b>5 Conclusões</b>	<b>73</b>



## **Lista de Figuras**

Figura 1 - Esquema de representação de diferentes estágios do movimento da água interlamelar, adaptado de Wittimann apud Kovler et al. [9]. .....	21
Figura 2 - Representação esquemática das proporções volumétricas da pasta de cimento hidrata ( $a/c=0,475$ ) em diferentes estágios de hidratação, adaptado de Neville apud Kovler et al. [9]. .....	22
Figura 3 - Valor da retração, conforme o ACI 209R-92 e Hansen & Almudaiheen [6]. .....	25
Figura 4 - Comportamento da fissuração de UHPFRC com fibra de aço, adaptado de Yoo et al. [28]. .....	29
Figura 5 – (a) ilustração esquemática das relações tensão-deformação para concreto simples e reforçado com fibra; (b) a atuação das fibras na abertura de fissuras no concreto. (em inglês, Fiber Reinforced Concrete - FRC), adaptado de Afroughsabet et al. [29]. .....	30
Figura 6 - Sistema de hidratação de cimentos CSAs, adaptado de Gregorova et al. [10]. .....	32
Figura 7 - Comportamento comparativo de concreto com e sem agente expensor, adaptado ACI 223-R10 [30]. .....	32
Figura 8 - Ilustração do processo de cura externa e interna do concreto, adaptado de Lu et al. [32]. .....	33
Figura 9 - Relação baseada em conhecimento entre IA, ML e DL, adaptado de Mohtsham et al. [35].....	35
Figura 10 - Variedade de algoritmos de aprendizado de máquina comumente usados, adaptado de Taffese et al. [38].....	36
Figura 11 - Estrutura de rede neural artificial, adaptado de Mohtasham et al. [35]. .....	38
Figura 12 - Redes neurais artificiais com uma camada oculta, adaptado de Hwang et al. [42].....	40
Figura 13 - Arquitetura selecionada para predição de retração por secagem de concreto, adaptado de Bal et al. [45]. .....	41
Figura 14 - Resultados valores preditos pela NNMPs e experimentais, adaptado de Bal et al. [45]. .....	42

Figura 15 - Representação sistemática da arquitetura RNA, adaptado de Congro et al. [46].....	43
Figura 16 - Resultados de validação de RNA 1 (a), 2 (b) e 3 (c), adaptado de Congro et al. [46].....	44
Figura 17 - Valores de retração autógena medidos em comparação como previsto para a/c=0,22, adaptado de Nehdi et al. [1].....	45
Figura 18 - Desvio entre os valores de retração autógena medidos e previsto [1].	45
Figura 19. Aparato para determinação para o ensaio de variação dimensional. A seta azul indica a posição do corpo de prova durante o ensaio.....	48
Figura 21 - Número de leituras por região. ....	49
Figura 22 - Número de leituras por tipo de cimento. ....	49
Figura 23 - Histogramas de resultados de retração com diferentes tipos de cimento, sendo: (a) CP II E, (b) CP II E 40, (c) CP II E 40 RS, (d) CP II F 32 RS, (e) CP II F40, (f) CP II Z 32, (g) CP III 40 RS, (h) CP V ARI e (i) CP V ARI RS. ....	51
Figura 24 - Gráfico de dispersão de dados de acordo com os resultados de retração por secagem, sendo: (a) Região, (b) a/c, (c) consumo de cimento, (d) polifuncional, (e) <i>mid range</i> , (f) compensador, (g) tipo de cimento. ....	54
Figura 25 - Gráfico de dispersão de dados de acordo os resultados de retração por secagem em relação ao fator água/cimento com e sem compensador de retração, sendo: (a) Dia 1, (b) Dia 2, (c) Dia 7, (d) Dia 14, (e) Dia 28, (f) Dia 56. ....	56
Figura 26 - Comportamento comparativo de concreto com e sem agente expansor. ....	57
Figura 20 - Representação esquemática da arquitetura da RNA.....	60
Figura 27 - Gráfico de comparação entre previsto e observado da dispersão do modelo de treino. ....	62
Figura 28 - Gráfico de comparação entre previsto e observado da dispersão do modelo de teste. ....	63
Figura 29 - Histograma dos valores de erro entre os valores de retração e expansão previstos e experimentais.....	64
Figura 30 - Análise de importância de recursos usando a biblioteca SHAP em código Python. ....	65

Figura 31 - Gráfico de comparação entre previsto e observado da dispersão do modelo treino (a) e teste (b).....	70
Figura 32 - Histograma dos valores de erro entre os valores de retração e expansão previstos e experimentais dos dados internacionais. ....	71
Figura 33 - Análise de importância de recursos usando a biblioteca SHAP em código Python dos dados internacionais.....	72

## **Lista de Tabelas**

Tabela 1 - Coeficientes de correlação entre dados experimentais e retração calculada de acordo com vários modelos [45].....	42
Tabela 2 - Valores de regressão para cada conjunto de dados de ANN [46]. .....	43
Tabela 4 - Dados correlacionados. ....	52
Tabela 5 - Dados brutos: quantidades de dados, média, desvio padrão, 1°, 2°, 3° e 4° quartis e valores mínimo e máximo. ....	55
Tabela 3 – Variáveis de entrada e saída do modelo. ....	58
Tabela 6 - Dados de avaliação de desempenho do treinamento. ....	61
Tabela 7 - Dados de avaliação de desempenho de teste. ....	63
Tabela 8 - Variáveis de entrada e saída do modelo com dados internacionais. ....	66
Tabela 9 – Quantidades parciais de dados, média, desvio padrão, 1°, 2° e 3° quartis e valores mínimos e máximos do banco de dados internacional.....	68
Tabela 10 - Matriz de coeficiente de correlação de Spearman dos dados internacionais.....	68
Tabela 11 - Dados de avaliação de desempenho do treinamento e teste. ....	69

“O temor do Senhor ensina a sabedoria, e a  
humildade antecede a honra”.

Provérbios. 15.33.

# 1

## Introdução

### 1.1.

#### Panorama Geral

O concreto é o material mais utilizado em todo o mundo, justificando a importância de estudar várias características deste material. Especificamente, estudar a durabilidade do concreto, que é afetado pela retração, é de particular interesse por causa do seu efeito significativo na vida útil da estrutura. A retração do concreto promove o surgimento de fissuras que podem levar ao ingresso de agentes deletérios, consequentemente a diminuição da durabilidade, assim como afetar a rigidez estrutural e levar até seu colapso. Consequentemente, a retração do concreto tem sido motivo de grande preocupação em projetos de estruturas duráveis [1,2].

As diferentes fases do concreto (pasta, argamassa e o concreto) são materiais que se deformam pela variação de umidade e temperatura independente da aplicação de forças externas. Dentre as deformações causadas por forças de origem interna está a deformação por retração. Tal fenômeno ocorre devido à redução de volume da mistura sem que haja nenhum esforço mecânico, e pode ocorrer por diferentes causas. A retração ocorre com o tempo principalmente devido à migração de umidade do concreto com o meio externo, ou por consumo de água interna pela hidratação do cimento. As retrações mais comuns relacionadas ao concreto são a retração plástica, por secagem, autógena e química [3].

A prevenção da retração do concreto resulta no desenvolvimento em menores valores de tensões de tração. Se estas tensões de tração excedem a resistência a tração do concreto, é provável o surgimento de fissuras. Vários fatores podem influenciar o potencial de fissuração, como a magnitude de retração, grau de restrição, fluência, condições de ambiente externo, propriedades dos materiais, geometria da estrutura e resistência a tração do concreto [4].

A retração tem como resultado a fissuração da estrutura, assim gerando uma ameaça à integridade estrutural do concreto e se não inibida, levará à deterioração

prematura, redução da vida útil da estrutura e o aumento dos custos de manutenção [5]. Embora os materiais, dosagens de concreto, especificações de projeto e tecnologias da construção tenham avançado muito ao longo dos anos, a fissuração por retração ainda permanece um problema significativo na construção civil. A escassez de estudos sobre os mecanismos de fissuração por retração, as técnicas de mitigação e equações analíticas que permitem a predição das deformações diferidas no tempo mostram a relevância da presente pesquisa.

## **1.2. Objetivos**

Os objetivos dessa pesquisa incluem:

- Apresentar o potencial do modelo da inteligência artificial para prever a retração por secagem;
- Desenvolver um modelo de redes neurais artificiais para predição da retração do concreto por meio de banco de dados adquiridos por empresas nacionais e literatura técnica para os dados internacionais;
- Apresentar a viabilidade dos modelos de Redes Neurais Artificiais em capturar as inter-relações entre as principais variáveis do conjunto;
- Apresentar a precisão no treinamento e teste para prever a retração por secagem para os dados nacionais e internacionais no modelo de RNAs;
- Apresentar a capacidade das RNAs em prever a retração por secagem em diferentes idades através de parâmetros de dosagem;
- Apresentar o ganho na redução da retração por secagem com o uso da adição do compensador de retração (CR).

## **1.3. Estrutura da Dissertação**

O Capítulo 1 traz uma introdução ao tema, os objetivos da pesquisa e a organização da dissertação.

O Capítulo 2 apresenta uma revisão bibliográfica acerca do tema, mostrando os mecanismos, diferentes tipos, métodos de predição, meios de mitigação a retração do concreto e o uso da inteligência artificial para predizer características do concreto.

O Capítulo 3 descreve como a metodologia do trabalho, apresentando como foi a montagem da base de dados e o desenvolvimento do modelo de redes.

O Capítulo 4 mostra os resultados dos modelos desenvolvidos e as discussões acerca do tema.

O Capítulo 5 apresenta as conclusões e oferece sugestões de trabalhos futuros relacionados ao tema deste estudo.

## 2

### Revisão bibliográfica

#### 2.1. Retração do Concreto

A movimentação de água no interior do concreto no estado fresco ou até em idades mais avançadas, causando variações volumétricas, é caracterizado como retração [6]. Tal movimentação pode ser classificada pelo modo que a água é encontrada na pasta de cimento hidratada em diferentes formas e de acordo com o grau de dificuldade ou facilidade com que pode ser removida da pasta [7].

Segundo Metha e Monteiro [8] a água presente no interior do concreto pode ser encontrada de diversas formas. A água capilar é a água disponível que está livre de influência das forças de atração exercidas pela superfície sólida, dentro de poros capilares, se retida por tensão capilar em pequenos poros, caso seja removida, haverá retração do sistema. A água que se encontra próximo à superfície sólida dos produtos de hidratação e que está sob influência das forças de atração é descrita como água adsorvida; na presença de umidade relativa de 30% pode haver perda de água. Já a água interlamelar é a água associada com a estrutura do silicato de cálcio hidratado (em inglês *Calcium Silicate Hydrated*, C-S-H), podendo haver perda somente por forte secagem, isto é, umidade relativa abaixo de 11%. Água quimicamente combinada integra parte da microestrutura de vários produtos de hidratação do cimento, essa água não se perde na secagem, ela é liberada quando os hidratos se decompõem por aquecimento.

As partículas do C-S-H são compostas por camadas laminares, cuja grande área superficial possui tensão superficial de atração. Essas partículas formam uma microestrutura em camadas, atraem moléculas de água altamente polarizadas na interface com poucas monocamadas de distância. O movimento desta água para fora da estrutura da partícula de C-S-H em camadas afetará o espaçamento entre as camadas causando assim mudanças de volume [9]. A representação esquemática deste processo é mostrada na Figura 1.

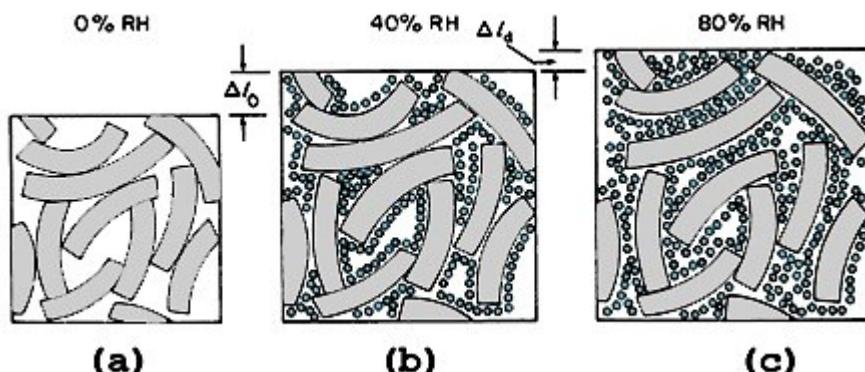


Figura 1 - Esquema de representação de diferentes estágios do movimento da água interlamelar, adaptado de Wittmann apud Kovler et al. [9].

Quase todas as reações químicas são acompanhadas por mudanças de volume. As principais fases que constituem o cimento Portland, são a alita ( $C_3S$ ), belita ( $C_2S$ ), aluminato ( $C_3A$ ) e ferrita ( $C_4AF$ ). Essas fases reagem com a água e formamos produtos de hidratação. Dessa forma, a hidratação do cimento não é uma única reação química, mas um conjunto complexo de algumas reações e cada reação tem seu próprio volume estequiométrico. No que diz respeito à hidratação, os dois silicatos de cálcio resultam nos mesmos produtos: silicato de cálcio hidratado ( $C-S-H$ ) ou tobermorita e hidróxido de cálcio [ $Ca(OH)_2$ ], conhecido também por portlandita. O  $C_3A$ , na presença de sulfato de cálcio e água, reage e forma etringita e posteriormente o monosulfato. A reação do  $C_4AF$  com sulfato de cálcio procede mais lentamente do que a reação  $C_3A$ , formando  $C_3AH_6$  e  $C_3FH_6$ . Como os silicatos de cálcio representam maior parte do cimento Portland, a variação volumétrica que ocorre durante a hidratação é preponderante [9]. Se, por exemplo, o volume C de cimento seco reage com volume W de água, sendo a água não evaporável (ou seja, mais ou menos combinada quimicamente), o volume P resultante dos produtos de hidratação é sempre tal que  $P < C + W$ , como ilustrado na Figura 2.

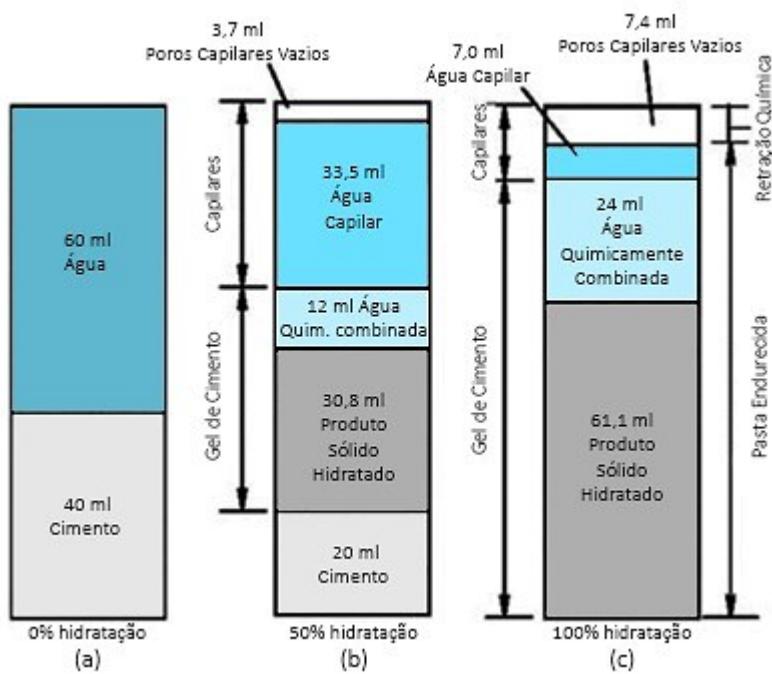


Figura 2 - Representação esquemática das proporções volumétricas da pasta de cimento hidratado ( $a/c=0,475$ ) em diferentes estágios de hidratação, adaptado de Neville apud Kovler et al. [9].

A retração geralmente depende do consumo e composição do cimento, quantidade de água, do teor de finos, o método de cura do concreto no estado fresco e endurecido, a idade do concreto e as condições ambientais (temperatura, umidade relativa e velocidade do vento). A retração do concreto pode ser dividida em duas principais fases: em idades iniciais e ao longo do tempo. A fase inicial é comumente definida como o primeiro dia (dentro das primeiras 24 horas), enquanto o concreto está em seu período de endurecimento. Após o concreto endurecido, a água que não foi consumida pela hidratação do cimento sai do sistema de poros, caso não haja equilíbrio entre o teor de umidade no concreto o ambiente externo. Durante a secagem, forças capilares são formadas no sistema de poros juntamente com a tensão superficial da água causando redução dos poros e volume do material [10].

## 2.2.

### Tipos e Ensaios de Retração do Concreto

Enquanto o concreto está em estado fresco, pode perder água pela superfície pela evaporação, por semelhança, uma sucção de camadas inferiores de concreto ou solo seco. Essa perda de volume é conhecida como retração plástica, devido ao

concreto estar ainda no estado plástico. A temperatura, umidade relativa do ar e velocidade do vento intensificam a retração plástica com a perda de água na superfície do concreto [11]. Caso a quantidade de água levada a superfície pela exsudação seja inferior a quantidade de água evaporada por unidade de área, poderá ocorrer fissuração por retração plástica [6].

A hidratação de cimento promove a saída de água dos poros capilares acarretando o processo conhecido como autodessecção. Esse mecanismo é designado como retração autógena, fenômeno que ocorre no interior da massa de concreto sem que ocorra perda de água para o ambiente [12]. A retração autógena tende a aumentar com consumos elevados de cimento, possivelmente, com cimentos mais finos e elevados teores de C<sub>3</sub>A e C<sub>4</sub>AF, e com temperaturas elevadas. Em concretos de alto desempenho, geralmente, há maior consumo de cimento e baixas relações água/cimento resultando em uma estrutura mais rígida da pasta de cimento hidratada, assim a autodessecção tem valores de retração bastante alto, registrado valor de  $700 \times 10^{-6}$  para um concreto com relação água/cimento de 0,17 [6,13].

Como descrito anteriormente, a saída de água dos poros da pasta de cimento, sem que esteja sob influência de tensão capilar em pequenos poros, não resulta em retração. Com a remoção da água adsorvida a retração do sistema cimentício tem início, sendo classificado esse processo como retração por secagem [6]. A principal razão para a retração por secagem é a evaporação da água de poros capilares existentes na pasta de cimento hidratada através da superfície do concreto que fica exposto a ambiente com baixa umidade relativa. A água disponível nos poros capilares seria mantida por foças capilares em função do tamanho dos poros, uma vez que quanto menores os poros, maior a tensão capilar [14].

A retração química é o mecanismo no qual os produtos da hidratação do cimento resultam em um volume menor do que seus reagentes segundo a ASTM C1608, ou seja, redução do volume de produtos de hidratação dos aglomerantes em comparação com os volumes dos componentes iniciais, aglomerante seco e água. Após a pega do cimento, isso causa a dessaturação dos poros [15,16].

A pasta de cimento, geralmente, contém hidróxido de cálcio livre, que é produzido durante a hidratação do cimento. Na presença de água o hidróxido de cálcio reage com o dióxido de carbono atmosférico. Essa reação, chamada de carbonatação, é acompanhada por uma diminuição do volume da pasta de cimento,

ou seja, por retração por carbonatação, devido a dissolução de cristais de Ca(OH)<sub>2</sub>. A retração por carbonatação é afetada pela umidade relativa do ambiente, pela concentração de CO<sub>2</sub>, pela pasta porosa e pelo seu teor de umidade [9].

Para a retração por secagem o método utilizado é descrito pela ASTM C157 e NBR 1683 [17,18], que consiste na determinação das variações de comprimento em corpos de prova prismáticos que são produzidas pela perda da água do concreto para o ambiente. A medição da variação do comprimento permite a avaliação do potencial de retração do concreto devida à secagem, e é particularmente útil para comparação do potencial de retração para diferentes argamassas ou misturas de concreto. No entanto, pesquisadores [5] avaliam esses ensaios como não sendo um indicador de desempenho de fissuração, uma vez que o concreto nesses métodos de avaliação não é restrinido, assim não é possível diferenciar a contribuição de diferentes materiais, como a fibra para o controle de fissuração. Outro ponto é a representatividade do ensaio em relação à estrutura real, como o histórico de exposição ao ambiente, geometria do elemento estrutural, etc. Assim, a tomada de decisão não se limita somente à esse ensaio, mas é necessário avaliar cada estrutura de forma particular.

A ASTM 1581 [19] descreve o método para avaliação da retração por secagem restrinuida, que consiste na moldagem do concreto em torno de um anel de aço. No processo de secagem, um anel de concreto tenderia a retrair, mas o anel de aço impediria isso resultando em um processo de fissuração. Embora esse método de teste possa ser usado para estudar a tendência de fissuração do concreto com diferentes materiais, esse teste não é aplicável para concreto fresco para avaliação da retração plástica [5]. Os autores Younis et al. [20] em seus estudos levanta alguns pontos de desvantagens nesse método: o teste só reflete uma tendência de fissuração, não simula e não pode prever a fissuração na vida útil real do concreto; as deformações usadas para calcular as tensões elásticas não são medidas diretamente no concreto; e o teste não quantifica a tensão residual do concreto fissurado.

### 2.3.

#### Métodos de Predição

Quando se deseja estimar a retração, pode-se prever, de acordo com ACI 209R-92 [21], com a seguinte equação ao longo do tempo:

$$s_t = \frac{t}{t + 35} s_{ult} \quad (2.1)$$

Sendo que:  $s_t$  é a retração após  $t$  dias desde o término da cura úmida de sete dias,  $s_{ult}$  é retração final e  $t$  é o tempo em dias desde o fim da cura úmida.

O autor [6], na Figura 3 ilustra que pode ser estimada a retração em uma determinada umidade relativa com base em um valor conhecido de retração em outra umidade relativa, pode ser utilizada a relação do ACI 209R-92 [21] e a relação proposta por Hansen & Almudaiheem [22].

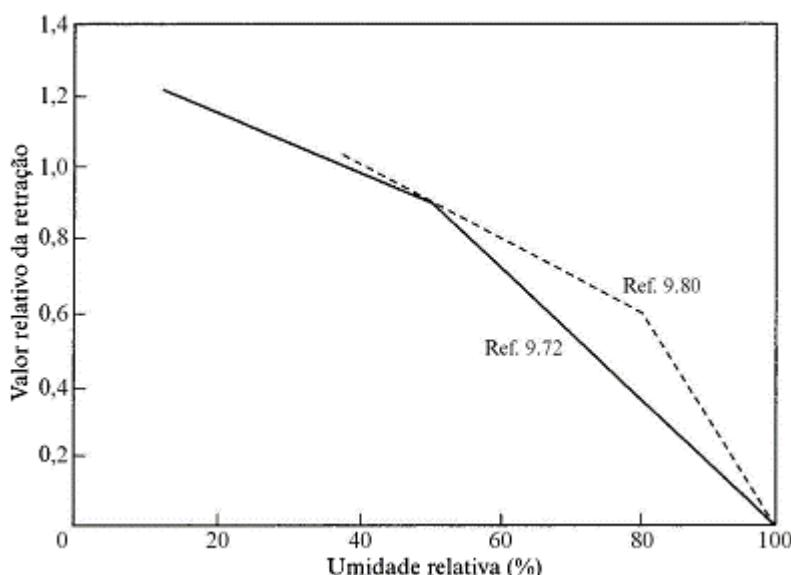


Figura 3 - Valor da retração, conforme o ACI 209R-92 e Hansen & Almudaiheen [6].

Pesquisadores avaliam esse modelo de previsão como não confiável por causa da diferença significativa em estudos realizados entre o monitorado e o resultado calculado, pela incapacidade de prever a distribuição das fissuras, por fatores básicos não considerados no modelo (característica da superfície do agregado) e pelas limitações significativas no modelo [2].

Segundo Zhang et al. [23], a retração química pode ser calculada baseada na diferença entre o volume inicial das reações e final da hidratação de cada componente cimentício usando os pesos moleculares e densidades dos reagentes e

reação de cada produto. Com a soma da relação entre os produtos da retração química pela massa de todos componentes ( $V_{CS}$ ) obtém-se valor total da retração química da pasta de cimento, como demonstrado na equação 2.2.

$$V_{CS} = 0.0775[C_3S] + 0.0742[C_2S] + 0.171[C_3A] + 0.117[C_4AF] \quad (2.2)$$

Onde  $[C_3S]$ ,  $[C_2S]$ ,  $[C_3A]$ ,  $[C_4AF]$  são percentuais de massas individuais da fase do cimento Portland, respectivamente.

Atualmente, fórmulas de modelos de predição vêm sendo aprimoradas. O estudo de Liu et al. [24] utiliza uma fórmula que foi derivada para a energia de ativação da reação de hidratação do sistema cimentício complexo contendo materiais suplementares, como cinzas volantes e escórias. O grau de hidratação ao invés do tempo foi adotado como parâmetro básico para descrever a evolução das propriedades do concreto com interação entre os materiais, a temperatura e umidade. Um modelo de acoplamento multi-campo, que considera a hidratação e as propriedades do sistema complexo cimentício do concreto, foi introduzido para calcular a retração e risco de fissuração. Os resultados monitorados e calculados mostraram que a fissuração por retração do concreto pode ser significativamente mitigada pela adoção do método do modelo de acoplamento multi-campo utilizando os diferentes materiais suplementares combinados com as condições ambientais, temperatura e umidade.

## 2.4. Meios de Mitigação para Retração do Concreto

Meios de mitigação para retração do concreto podem ser geralmente divididos em soluções ativas e passivas. Soluções ativas visam limitar a perda precoce de água umidificando a superfície do concreto com água, aplicando cura química que impede a perda d'água para o ambiente externo, cobrindo a superfície do concreto com lonas plásticas ou protegendo os elementos do sol e/ou vento. Uma solução passiva consiste em elaborar misturas de concreto com menor risco de retração, que muitas vezes inclui fibras, aditivos redutores e compensadores de retração e cura interna [11]. Há diversas formas de mitigação encontrada na bibliografia, neste trabalho será apresentado mitigações mais usuais em campo.

### **2.4.1.**

#### **Dosagem**

Quanto maior for a disponibilidade de água no sistema para movimentação, devido ao valor elevado da relação a/c, maior será a retração por secagem, pois determina a quantidade de água evaporável existente na pasta de cimento e a velocidade com que pode se mover para a superfície do concreto. Valores de relação a/c entre 0,2 e 0,6 estão diretamente proporcionais a retração, segundo estudos [6].

O teor de cimento influência diretamente na retração. Em termos práticos, com a relação a/c constante, o aumento do teor de cimento aumenta a retração, devido ao maior volume de pasta de cimento hidratada, que é passível de retração. Entretanto, o aumento do consumo de cimento, uma vez que a quantidade de água é constante, implica na diminuição do fator a/c e assim tem maior capacidade de resistir a retração com o ganho de resistência [6].

A maior influência detectada na retração por pesquisadores é exercida pelo agregado, que restringe a retração que pode realmente ocorrer. Granulometria e dimensão do agregado em si não influenciam na retração, mas agregados maiores tornam o uso de misturas com menor teor de cimento, resultando em menor retração. Neville [6] apresenta em seus estudos que uma alteração da dimensão máxima do agregado de 6,3 para 152 mm aumentando o teor de agregado de 60 para 80% do volume total do concreto, resultou em uma redução da retração em três vezes. As propriedades do agregado determinam a compressibilidade do material. Desse modo, o módulo de elasticidade do concreto está relacionado diretamente a retração, um exemplo é o agregado de aço que resulta em uma retração menor do que agregado comum em 1/3. Agregados doleritos, basaltos e algumas rochas sedimentares, como a grauvaca e o argilito estão mais propensos a retração, assim como rochas que possuem elevada porosidade. Por outro lado, o granito, calcário e o quartzito têm apresentado valores não propensos à retração.

Um fator relevante para o cimento é somente a finura em que as partículas maiores do que 75  $\mu\text{m}$  que resultam em pouca hidratação e exercem um efeito de restrição similar ao do agregado. Há divergências na literatura no posicionamento sobre o efeito do cimento com altos teores de cinza volante e escória de alto-forno. Neville [6] em seus estudos, apresenta resultados de um aumento na retração de até 20% com cinza volante e até 60% com adição de escória de alto-forno, com uma

relação a/c constante. Já os autores Pendergrass et al. [25] defendem que o uso de escória, bem como a sílica ativa, pode reduzir a retração pela permeabilidade reduzida que o sistema apresenta, assim a água dentro da pasta de cimento é incapaz de atingir a superfície e evaporar. Com o tempo, essa água fica presa em produtos de hidratação e não mais disponível para secagem.

#### **2.4.2.**

#### **Aditivos Redutores de Retração**

Pesquisas começaram a ser desenvolvidas na década de 1980 no Japão e em seguida no EUA com a exploração de novas formulações de Aditivos Redutores de Retração (em inglês, *Shrinkage Reducing Admixtures – SRA*) e vem sendo utilizado cada vez mais em concretos para conseguir mitigar o efeito da retração. Esses aditivos atuam na diminuição da tensão superficial do fluido do poro, reduzindo a perda de umidade no interior do concreto, que resulta em graus maiores de saturação, uma vez que a água que percola pelos poros capilares gera menos esforços de tração. No entanto, a utilização de SRAs também afeta a viscosidade do concreto, ângulo de contato e densidade, alterando significativamente a trabalhabilidade do concreto [26]. Estudo realizado por Qiao et al. [27], verificou que a distribuição do tamanho e volume de poros de concretos contendo SRA foi semelhante ao do concreto convencional, indicando que tem pouca influência na microestrutura. No entanto, como esperado, menos água foi perdida durante a secagem isotérmica em concreto contendo SRA e que a entrada de cloreto foi reduzida em testes de difusão, o que mostra o benefício do SRA em melhorar a durabilidade do concreto.

#### **2.4.3.**

#### **Adição - Fibra**

A retração plástica ocorre nas primeiras idades com a resistência ainda muito baixa do concreto, ocorrendo variações volumétricas devido à perda d'água por evaporação e reações químicas. Embora as fibras não afetem a taxa de perda de água, sua adição aumenta a capacidade de força e tensão pós-fissuração resultando em um controle de abertura e propagação de fissuras. Fibras de alta rigidez, como as de aço, carbono, basalto e vidro, servem para aumentar a resistência ao

crescimento de fissuras e a capacidade de carga de deformação, fornecem um mecanismo de restrição adicional para distribuir a retração e manter uma largura de fissura baixa [5]. A Figura 4 mostra o comportamento de fissuração em um concreto reforçado com fibra de ultra alto desempenho. Um alto volume de microfibras adicionadas inibiu a abertura de fissuras e, assim, múltiplas microfissuras foram formadas perto da maior trinca localizada.

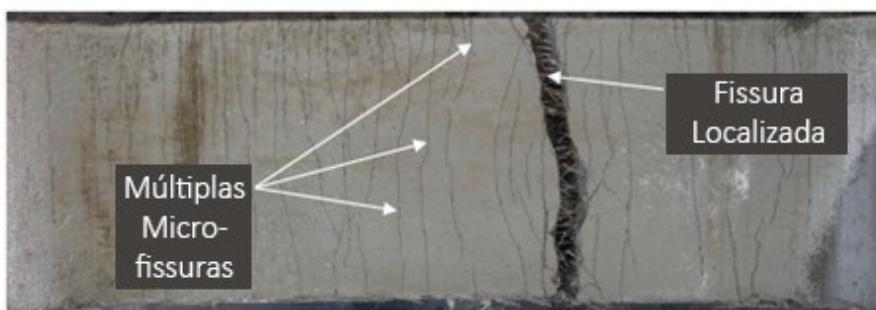


Figura 4 - Comportamento da fissuração de UHPFRC com fibra de aço, adaptado de Yoo et al. [28].

As fibras dispersas na matriz do concreto implementam um reforço tridimensional e são capazes de absorver tensões de tração atuando em qualquer direção. Além disso, ao distribuir as tensões, as fibras impedem a rápida disseminação de fissuras e especialmente limita sua abertura. Outra característica, o concreto reforçado com fibra mostra também uma maior capacidade de dissipar energia associado a carga de impactos se comparado ao concreto tradicional [4].

A Figura 5 apresenta o processo de fissuração do início ao rompimento do concreto com e sem fibra que pode ser dividido em três zonas: zona de microfissuração e crescimento de macrofissuras, zona de ponte e zona livre de tração [29]. Como pode ser observado, o concreto sem fibra tem menor capacidade em continuar a absorver energia (curva vermelha), uma vez que, após a fissuração não há mais transferência de tensão para a matriz como em concretos com fibra, responsável em fazer a ponte de transferência de carga após a fissuração.

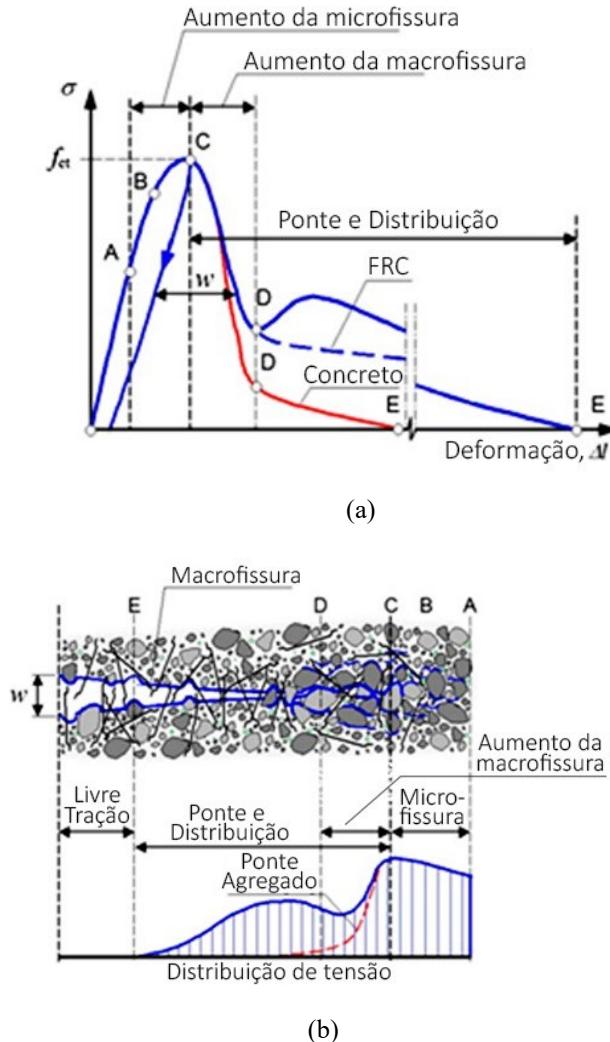


Figura 5 – (a) ilustração esquemática das relações tensão-deformação para concreto simples e reforçado com fibra; (b) a atuação das fibras na abertura de fissuras no concreto. (em inglês, Fiber Reinforced Concrete - FRC), adaptado de Afroughsabet et al. [29].

Em geral, o objetivo da adição de fibra ao concreto fresco é fornecer em seu estado endurecido capacidade mecânica para que possa moderar o desenvolvimento de fissuras por retração e ter ganho na tensão residual pós-fissuração do concreto.

#### 2.4.4. Concreto com Retração Compensada

O concreto com adição de material expansivo, seja por cimento expansivo ou adição expansiva, apresenta expansão nos primeiros dias, e um tipo de protensão é obtida pela restrição de sua expansão com uma armadura. O aço é submetido à tração e o concreto à compressão. Quando a magnitude da compressão é pequena, sendo da ordem de 0,1 a 0,7 MPa, a qual normalmente é adequada para compensar

a tensão de tração devida à retração, o concreto é conhecido como cimento de retração compensada [6,8].

Cimentos expansivos são compostos por cimento Portland, um agente expansor e um estabilizador. O agente expansor é obtido pela calcinação de uma mistura de gipsita, bauxita e giz, formando sulfato de cálcio e aluminato de cálcio. Esses compostos reagem na presença de água formando sulfoaluminato de cálcio hidratado (etringita), com consequente expansão da pasta de cimento. O estabilizador, escória de alto-forno, lentamente retém o excesso de sulfato de cálcio e termina com a expansão [6].

Atualmente, são produzidos três tipos principais de cimento expansivo, mas somente o tipo K está disponível comercialmente nos Estados Unidos. No Japão, é produzido um cimento expansivo denominado tipo O, que utiliza um óxido de cálcio processado especialmente para produzir a expansão a partir do CaO livre [6,12]. No Brasil ainda não tem no mercado um tipo de cimento com a classificação de expansivo.

O cimento de sulfoaluminato de cálcio (em inglês, *Calcium Sulfoaluminate Cemente* – CSA) foi desenvolvido no Japão. Este cimento especial distingue-se do cimento Portland por uma ligação de alta velocidade, rápido desenvolvimento da resistência, e uma redução na retração. É produzido pela Trituração de um sinterizado composto principalmente de calcário, gesso e bauxita (óxido de cálcio, sulfato de cálcio e óxido de alumínio). A composição química do clínquer CSA sinterizado principalmente consiste em hauyne, cal livre e gesso livre. A hidratação desses minerais forma a etringita ( $3\text{CaO} \cdot \text{AL}_2\text{O}_3 \cdot 3\text{CaSO}_4 \cdot 32\text{H}_2\text{O}$ ), um cristal muito pequeno com dimensões de vários micrões, como ilustrado na Figura 6. Durante o endurecimento da pasta de cimento, este cristal semelhante a colóide torna-se similar a rebarbas de gel em um minuto. Portanto, a presença de etringita aumenta a densidade da matriz de concreto, reduz a retração do concreto endurecido e induz tensões de compressão em uma estrutura de concreto. Através do mecanismo acima, o CSA reduz a fissuração por retração por secagem no concreto e aumenta a estanqueidade das estruturas de concreto [10].

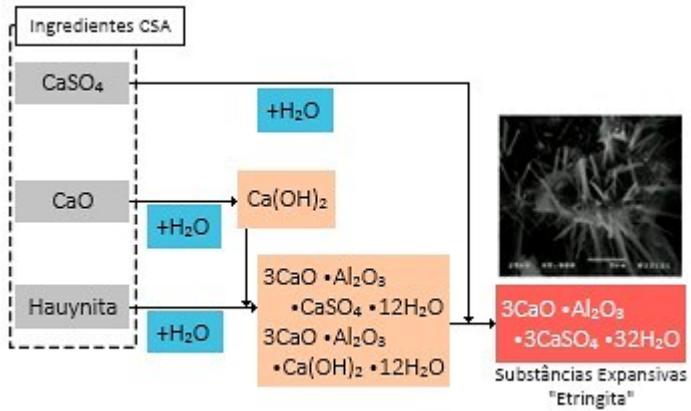


Figura 6 - Sistema de hidratação de cimentos CSAs, adaptado de Gregorova et al. [10].

Hoje é encontrado no mercado da construção civil no Brasil, nos Estados Unidos e na Europa um aditivo com a finalidade de compensar a retração do concreto através de sua expansão no sistema. O óxido de cálcio, não necessariamente, é disponibilizado na composição do cimento, como é no Japão no cimento tipo O. O tipo de expansor de óxido de cálcio supercalcinado atua em sua expansão do resultado da hidratação do óxido de cálcio ( $\text{CaO}$ ), transformando em  $\text{Ca(OH)}_2$ , cuja ocorrência independe e praticamente não é influenciada pela hidratação do cimento [30]. A Figura 7 apresenta esquematicamente um comparativo de concreto com e sem aditivo expansor.

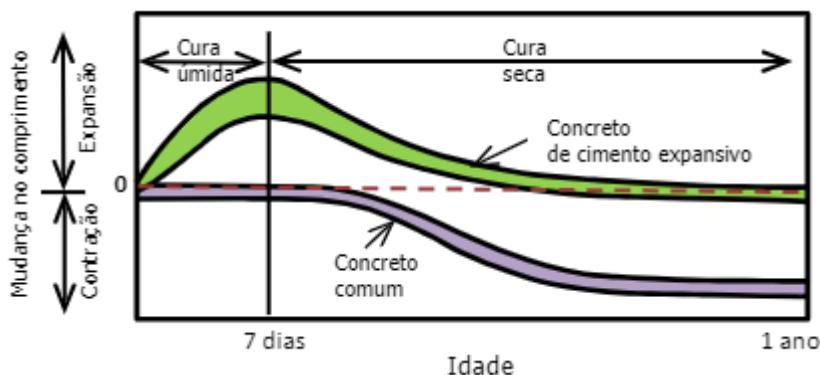


Figura 7 - Comportamento comparativo de concreto com e sem agente expansor, adaptado ACI 223-R10 [30].

#### 2.4.5. Cura Interna do Concreto

O agregado leve (em inglês, *lightweight aggregates* – LWA), após prévia umidificação, atua na liberação de água em resposta a sucção capilar que se desenvolve no processo de perda de água do sistema, resultando em uma influência

positiva para retração do concreto, uma vez que a água fornecida pelo LWA pode reduzir a quantidade e a abertura das fissuras de retração se tornando um agente de cura interna do concreto [11].

O uso do agregado leve como agente de cura interna é caracterizado pela sua porosidade que permite o armazenamento de água e, assim, cria um reservatório que irá liberar água sempre que o sistema precisar. Enquanto a água permanece no interior do LWA durante a mistura, transporte e moldagem, ela pode ser retirada do agregado leve devido à pressão que é desenvolvida nos poros do concreto com a movimentação da perda para o ambiente externo da água da mistura [31]. A Figura 8 apresenta de forma esquemática o sistema de cura interna, onde parte dos agregados de peso normal (pontos pretos) são substituídos por agregados leves pré-umedecidos (pontos azuis). Com o tempo a pressão capilar aumenta e o fornecimento de água pelo LWA tem início, resultando na cura interna.

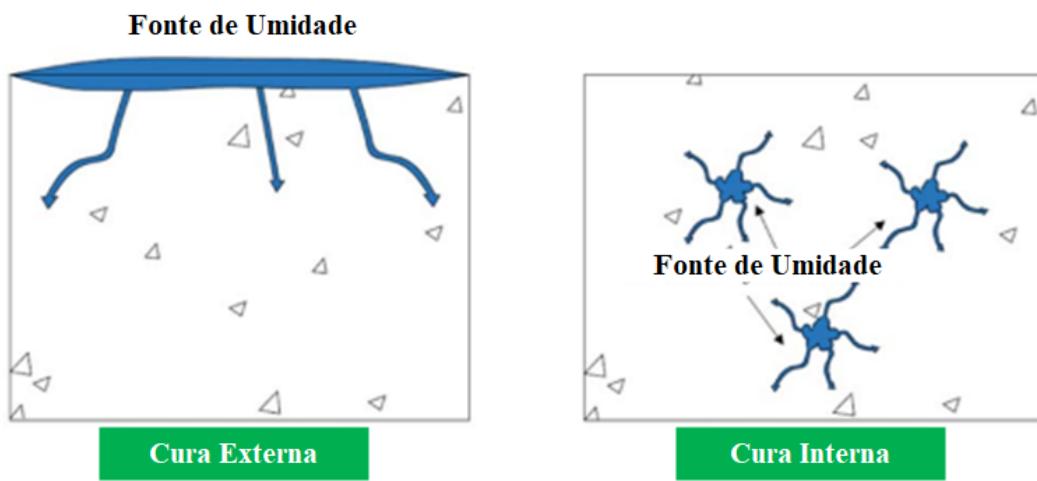


Figura 8 - Ilustração do processo de cura externa e interna do concreto, adaptado de Lu et al. [32].

Outra alternativa de cura interna são os polímeros superabsorventes (em inglês, *Superabsorbent Polymers – SAP*) são relativamente novos aditivos para concreto com muitas vantagens. Recentemente, muitas pesquisas têm sido desenvolvidas com o objetivo de utilizar os SAPs para reduzir/mitigar retração em materiais cimentícios, apresentando que uma dosagem na faixa de 0,2 – 0,6% em relação à massa de cimento deve ser suficiente para reduzir consideravelmente ou mitigar completamente a deformação devida a retração do concreto [33].

SAP (ou hidrogéis) são um material 3D natural ou sintético insolúvel em água com rede de cadeias poliméricas reticuladas por ligação química ou física. Eles

possuem a capacidade de absorver uma quantidade significativa de fluidos do meio ambiente (em quantidades de 500 vezes o seu próprio peso). Uma vez em contato com a água da mistura do material cimentício, os SAPs absorvem e retêm uma certa quantidade de água, posteriormente atuando como reservatórios para o sistema, mantendo seus níveis de umidade relativa interna elevados por um período de tempo considerável [33].

Os polímeros superabsorventes tem capacidade de absorver soluções aquosas (em caso particular do concreto, solução de poros) e então liberar essas soluções quando os poros se esvaziam e a umidade relativa interna no sistema cimentício em gotas, em um processo chamado de cura interna. Muitos SAP estão disponíveis no mercado em diferentes formatos, com diferentes composições poliméricas e diferentes capacidades de absorção, e apenas alguns poucos são adequados para o concreto. O SAP tem que ser capaz de absorver e reter água em um ambiente altamente alcalino na presença de íons de cálcio e não deve se desintegrar durante a mistura do concreto. Os SAP são normalmente adicionados aos constituintes secos. Usualmente, água adicional é adicionada à mistura de concreto para abastecer SAP com água a ser absorvida. Se a quantidade de água a ser absorvida pelo SAP durante a mistura não é considerada no projeto, a trabalhabilidade é substancialmente reduzida, o que pode ser compensado pelo aumento da dosagem de superplastificante [34].

## **2.5. Inteligência Artificial**

Atualmente, a inteligência artificial (IA), definida como o “estudo e desenho de agentes inteligentes”, influencia significativamente o mundo. Esses agentes inteligentes são sistemas que têm capacidade de entender o ambiente e tomar medidas para maximizar suas chances de acerto e alcançar o sucesso [35]. Por exemplo, reconhecimento de imagem, alto-falantes inteligentes e carros autônomos, tudo isso é possível devido aos avanços da IA demonstrando a capacidade de um sistema de interpretar dados externos corretamente, aprender com esses dados e usar esses aprendizados para atingir metas e tarefas específicas por meio de adaptação flexível. Estabelecida como uma disciplina acadêmica na década de 1950, a IA permaneceu uma área de relativa obscuridade científica e interesse

prático limitado por mais de meio século. Hoje, devido à ascensão de Big Data e melhorias no poder da computação, ela entrou no ambiente de negócios e na conversa pública [36].

O aprendizado de máquina, conhecido em inglês como *machine learning* (ML), começou a surgir como um ramo da inteligência artificial na década de 1990 [35] (Figura 9). Em vez de usar abordagens simbólicas, utiliza métodos derivados da estatística e da teoria de probabilidade. Na verdade, os algoritmos de aprendizado de máquina permitem que máquinas adquiram conhecimento para executar uma tarefa específica, analisando um número suficiente de amostra de dados. Antes de utilizar o algoritmo, é necessário realizar a etapa chamada de extração de atributos, na qual são identificados os atributos que mais representam informações específicas. A próxima etapa do processo é baseada em um método de treinamento de ML específico para treinar o sistema para comunicar as características e separar os padrões [37].

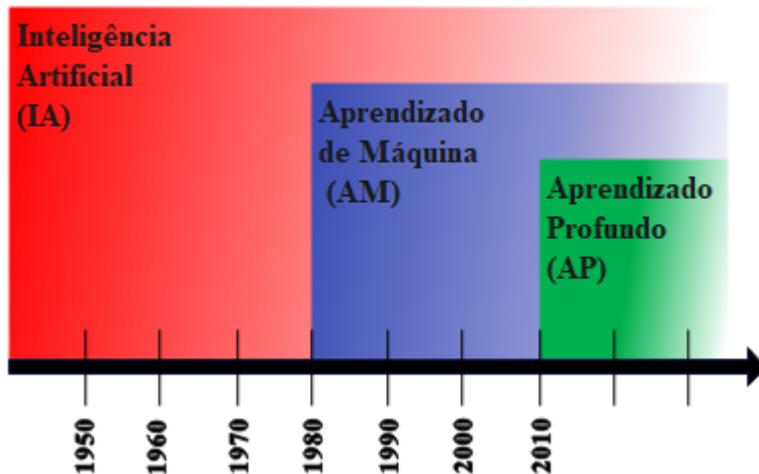


Figura 9 - Relação baseada em conhecimento entre IA, ML e DL, adaptado de Mohtsham et al. [35].

*Machine Learning* (ML) ou *Deep Learning* (DL), por exemplo, redes neurais profundas (em inglês, *Deep Neural Networks* – DNNs), estão cada vez mais prevalentes no processo científico, substituindo métodos estatísticos e modelos mecanísticos, modelos este que faz somente a descrição quantitativa dos mecanismos e processos que causam as respostas, em várias aplicações e campos, incluindo educação, ciências naturais, medicina, engenharia e ciências sociais. ML também é aplicada a engenharia civil, comparado aos métodos de regressão tradicionais, possui algoritmos especiais que podem aprender com os dados e exibir resultados mais precisos [35].

Geralmente, o desenvolvimento de um modelo de ML envolve um pequeno número de escolhas de design: o tipo de experiência de aprendizado, desempenho de meta de aprendizagem, exibição de desempenho de meta, e um algoritmo para aprender o desempenho objetivo de exemplos instrucionais. Além disso, o ML é dividido em aprendizado supervisionado, não supervisionado, semi-supervisionado e reforçado dependendo dos recursos de treinamento. Aprendizado supervisionado e não supervisionado são os tipos mais comuns de aprendizado de máquina em várias aplicações. No aprendizado supervisionado, há um conjunto de exemplos de aprendizado, que para cada entrada, valor de saída, ou a função também é especificada. O sistema de aprendizagem visa obter uma hipótese que adivinha a função ou relação de entrada e saída. Mas no aprendizado não supervisionado, há um conjunto de exemplos de aprendizado em que apenas as entradas são conhecidas e nenhuma informação sobre a saída correta está disponível. O aprendizado não supervisionado é usado para agrupar entradas e prever o próximo valor com base na situação atual. Os tipos comuns de algoritmos supervisionados e não supervisionados no aprendizado de máquina são mostrados na Figura 10.

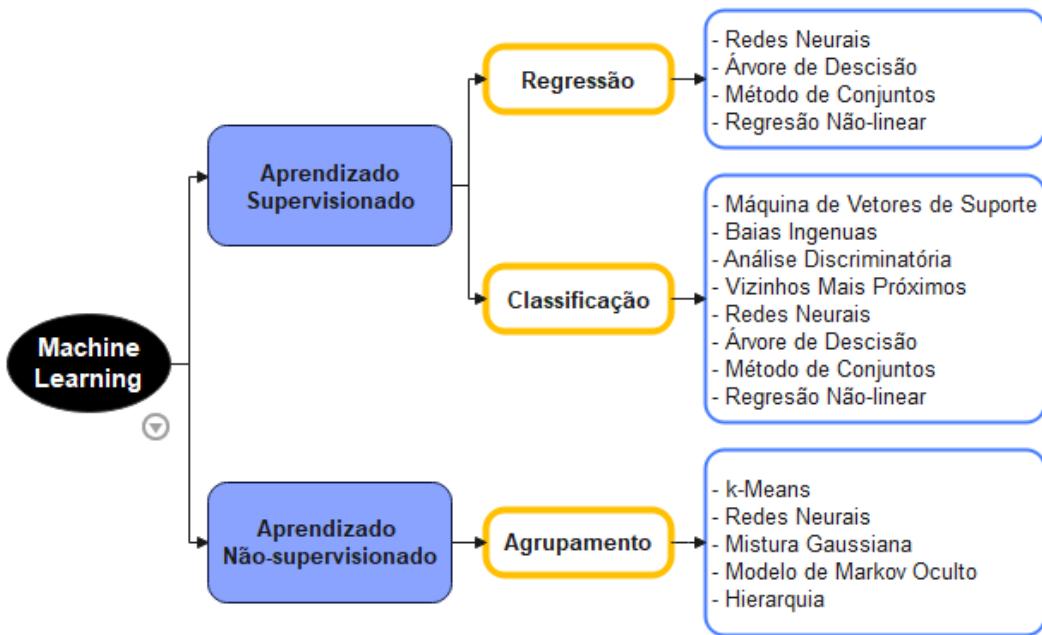


Figura 10 - Variedade de algoritmos de aprendizado de máquina comumente usados, adaptado de Taffese et al. [38].

As categorias de ML estão resumidas da seguinte forma [35]:

- *Classificação (classification)*: o objetivo desta etapa é identificar a categoria a que pertence a entrada.

- *Regressão (regression)*: esta etapa visa modelar as relações entre entradas e saídas numéricas.

- *Predição (prediction)*: o objetivo é prever valores futuros durante um determinado período de tempo. Esta etapa é um tipo especial de regressão.

- *Agrupamento (clustering)*: para extrair pontos semelhantes entre dois ou mais conjuntos de dados. O agrupamento é realizado de acordo com um método não supervisionado, em vez das tarefas definidas para três etapas anteriores (classificação, regressão e predição), que são realizadas com base em métodos supervisionados.

Redes Neurais Artificiais (RNAs) são técnicas computacionais em sistemas paralelos distribuídos compostos por unidades simples de processamento (neurônios) que apresentam um modelo matemático inspirado na estrutura neural dos organismos inteligentes e que adquirem conhecimento através da experiência. A capacidade de aprender e generalizar a informação aprendida, através de um banco de dados ou um conjunto de exemplos, é o principal atrativo das RNAs que, além de mapear relações de entrada e saída, são capazes de extrair informações não-explicadas nos exemplos, com auto-organização e processo temporal [37]. Neste trabalho, a pesquisa foi desenvolvida em redes neurais artificiais. Nas próximas seções são detalhados os estudos do uso dessa técnica computacional.

### **2.5.1. Redes Neurais Artificiais**

Os computadores tornaram possível implementar algoritmos computacionais para simular o comportamento computacional do cérebro humano nas últimas décadas. Muitos trabalhos de pesquisas foram iniciados por cientistas da computação, engenheiros e matemáticos que contribuíram para o campo da inteligência artificial. Rede neural artificial (RNA) é uma ideia inspirada no sistema nervoso biológico para processar informações e, como o cérebro, processa informações. O cérebro é altamente não linear e complexo. Tem potencial para organizar a sua estrutura constituinte (neurônios) para realizar certos cálculos (por exemplo, percepção e controle motor) muito mais rápido do que o mais rápido computador digital hoje. As RNAs são usadas para resolver problemas da mesma forma que o cérebro humano faria. Ela pode fornecer soluções poderosas para

problemas em uma gama muito ampla de disciplinas, particularmente em problemas que precisam de classificação, previsão, filtragem, otimização, padrão de reconhecimento e aproximação de funções [39].

O elemento crítico da RNA é a estrutura do sistema de processamento de informações, que consiste em muitos elementos de processamento altamente interconectados trabalhando juntos para resolver um problema. A saída de cada neurônio é multiplicada por coeficientes dada à potência de entrada como uma função de ativação não linear [35], conforme a Figura 11.

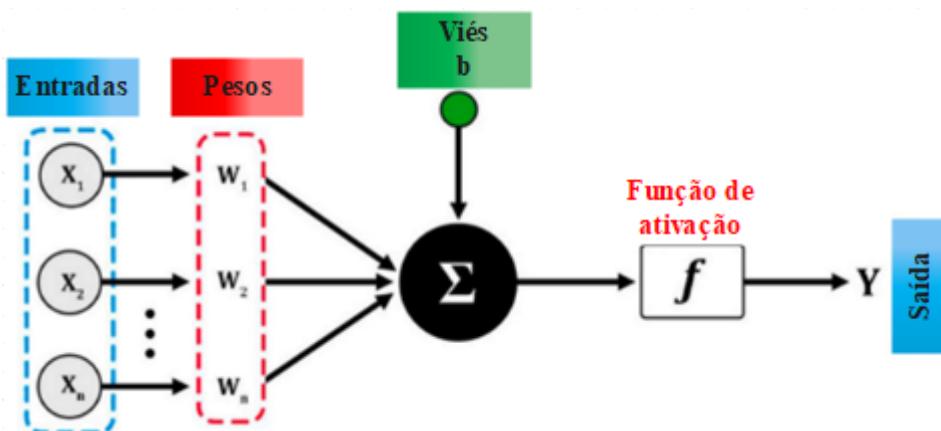


Figura 11 - Estrutura de rede neural artificial, adaptado de Mohtasham et al. [35].

Existem muitas vantagens em técnicas de inteligência artificial. As mais importantes são: exige menos treinamento estatístico formal; detecta relações não lineares implicitamente complexas entre variáveis independentes e dependentes; RNAs são capazes de detectar todas as interações prováveis entre variáveis preditoras; e a disponibilidade de algoritmo de treinamento múltiplo [39].

A estrutura das RNAs consiste em três partes principais, que são: camada de entrada, que contém os parâmetros de entrada e os repassa para a próxima camada; camada oculta, essa camada é responsável pela conexão entre a camada de entrada e a camada de saída e é a parte central da arquitetura das RNAs, e cada camada oculta contém um conjunto de neurônios; e camada de saída, uma camada que é responsável por produzir o resultado [35].

As RNAs podem ser amplamente agrupadas em duas categorias; *feedforward neural networks* (FFNN) e *recurrent neural networks* (RNN). As RNAs típicas são rasas e consistem em três camadas principais. A primeira camada é visível e recebe os dados de entrada, e então os dados de entrada são ponderados e transferidos para

a próxima camada oculta por uma série de conexões chamadas “pesos sinápticos”. Os nós, que se assemelham aos neurônios humanos, residem nesta camada e processam os dados de entrada e, em seguida, transfere os dados processados para camada de saída. Este processo é chamado de *feedforward* e continua até que a métrica de desempenho selecionada seja satisfeita. Outras abordagens para alimentar uma RNA também existem, como rede perceptron multicamadas, rede carpenter, rede Hopfeld e retropropagação. A arquitetura mencionada pode ser estendida para uma rede neural profunda com várias camadas ocultas [40]. As etapas associadas a uma típica análise de RNA estão descritas abaixo:

- Receber variáveis de entrada ( $x_1, x_2, x_3 \dots, x_n$ );
- Soma de dados de entrada e atribuição de peso a eles ( $h_i = \sum_{i=1}^m w_{ji}x_i + b_j$ );
- Aplicação de uma função de ativação como:
  - Linear:  $f_n = a \cdot n + b$
  - Hiperbólica:  $f_n = \tanh(n)$
  - Logarítmica:  $f_n = \frac{1}{1+e} - n$

Uma RNA tem uma arquitetura paralela distribuída com um número de nós interconectados, comumente chamados de neurônios. Os neurônios interagem entre si por meio de conexões ponderadas. Cada neurônio é conectado a todos os outros neurônios na próxima camada. De longe o modelo RNA mais comum é conhecido como algoritmo de rede neural de retropropagação. Neste algoritmo, a RNA aprende o complicado relacionamento do modelo a partir de exemplos de padrões de entrada e saída modificando por meio da modificação dos pesos de conexão para reduzi-los entre os valores de saída reais e os valores de saída de destino. Isso é realizado minimizando a função de erro definida usando a abordagem do gradiente descendente. A validação do desempenho da rede neural é realizada por teste com um conjunto separado de dados que nunca foi usado no processo de treinamento, para avaliar a capacidade de generalização do treinamento do modelo neural para produzir o mapeamento de entrada e saída correto. As aplicações de RNA em problemas de engenharia têm sido usados em muitos estudos [41].

A Figura 12 mostra as RNAs de forma esquemática, que consistem em uma camada de entrada, uma camada oculta e uma camada de saída. Por simplicidade, no estudo de Hwang et al. [42], foi considerado uma camada oculta. A camada de

entrada recebe os valores de variáveis de entrada selecionadas, e cada nó da camada de entrada é conectado a nós da camada oculta.

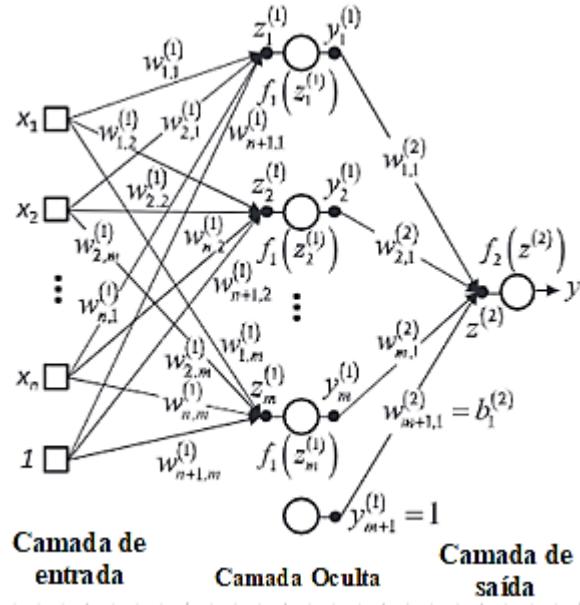


Figura 12 - Redes neurais artificiais com uma camada oculta, adaptado de Hwang et al. [42].

### 2.5.2.

#### Uso de RNAs para Predizer Características do Concreto

Durante os últimos 50 anos, várias equações paramétricas de retração foram propostas como o *American Concrete Institute 209* (ACI 209) [43], *Comité Européen du Beton* (CEB) selecionado para Eurocode 2, B3 por Bazant e Baweja [44], entre outros. Os resultados dessas equações podem ser comparados com dados obtidos por modelos não paramétricos usando técnicas de aprendizado de máquina. A técnica ML apresenta a vantagem de usar um número muito elevado de número de parâmetros característicos do fenômeno, se diferenciando dos métodos estatísticos.

Técnicas de aprendizado de máquina têm sido amplamente utilizadas para prever características e propriedades mecânicas para diferentes tipos de concreto. Recentemente, Redes Neurais Artificiais (RNAs) foram empregadas como metodologia principal aumentando tanto em número quanto em diversidade nas pesquisas para predição das propriedades do concreto.

Bal et al. [45] desenvolveram um estudo de predição da retração por secagem em RNA. Os parâmetros foram escolhidos com base em seu efeito sobre a retração

do concreto, como as proporções de mistura, a umidade relativa, a razão volume da amostra em sua superfície de secagem, o tempo final de cura úmida, a resistência média à compressão aos 28 dias e o módulo de elasticidade. Em uma primeira etapa, a matriz de entrada e saída é padronizada. Em segundo lugar, o processo de aprendizagem é engajado pela inicialização dos coeficientes de correlação usados para as três fases (aprendizagem, teste e validação), depois do número de neurônios por camada oculta, testando primeiro a camada oculta, depois duas camadas ocultas criando um ciclo que é incrementado de 1 a 20 para os neurônios da camada oculta, e da mesma forma para a segunda camada. A construção da rede neural passa pelo uso de uma função de transferência para cada camada e de um algoritmo de aprendizagem, após várias tentativas, a técnica de propagação de volta Levenberg-Marquardt foi a mais eficaz e confiável, segundo esse estudo. A Figura 13 apresenta a arquitetura deste trabalho.

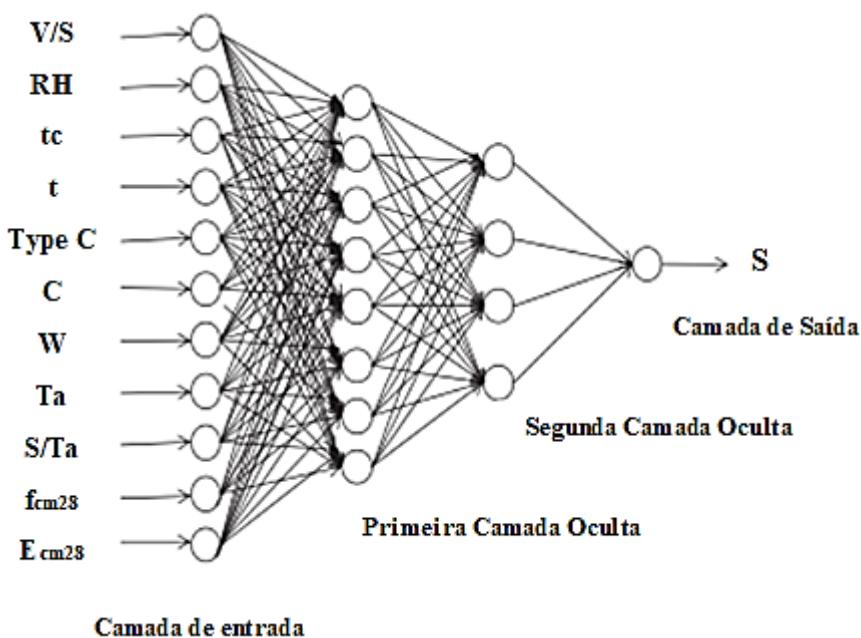


Figura 13 - Arquitetura selecionada para predição de retração por secagem de concreto, adaptado de Bal et al. [45].

Os resultados fornecidos pela modelo de RNA selecionado são comparados com os dados pelas diferentes formulações paramétricas de referência. A Tabela 1 apresenta as características de correlação entre os valores experimentais e os fornecidos pelos diferentes modelos e formulações: NNMPS, ACI, CEB, GL 2000, B3 e ATLANTA [45].

Tabela 1 - Coeficientes de correlação entre dados experimentais e retração calculada de acordo com vários modelos [45].

<i><b>Modelos</b></i>	<i><b>Coeficientes de Correlação</b></i>	
	<i><b>R</b></i>	<i><b>R</b></i> <sup>2</sup>
NNMPS	0,9834	0,9672
ACI	0,7842	0,6149
CEB	0,9076	0,8238
GL2000	0,9277	0,8606
B3	0,9390	0,8818
ATLANTA	0,8993	0,8088
S.B3	0,8887	0,7898

A Figura 14 apresenta o gráfico dos resultados experimentais versus valores calculados. Esse gráfico mostra claramente a boa concordância para valores emitidos a partir do modelo NNMPS (em inglês, *Neural Network Model for the Prediction of Shrinkage*). No entanto, uma pequena diferença pode ser observada nas primeiras idades, ou em idades mais avançadas. O modelo NNMPS requer um tempo de computação menor do que formulações paramétricas.

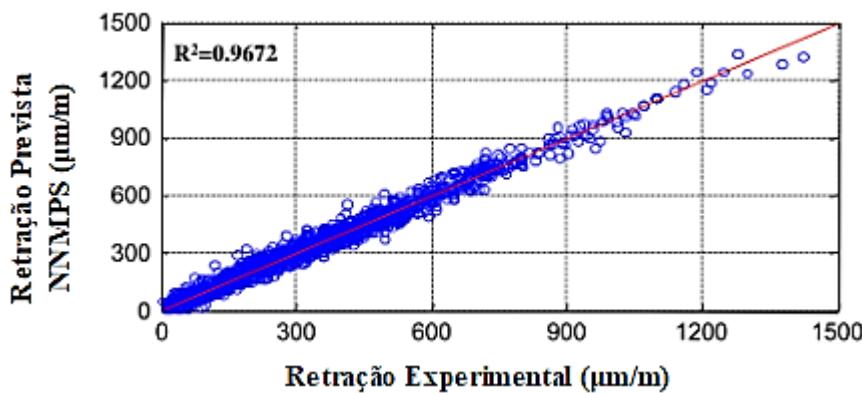


Figura 14 - Resultados valores preditos pela NNMPS e experimentais, adaptado de Bal et al. [45].

O estudo desenvolvido por Congro et al. [46], compilou um banco de dados com 400 ensaios de tração a flexão de três pontos para obtenção da tensão residual do concreto fibroso, conforme EN 14651, em diferentes fontes da literatura para predizer a resistência à flexão residual do concreto reforçado com fibra usando redes neurais artificiais. A Figura 15 apresenta a arquitetura ilustrada da RNA.

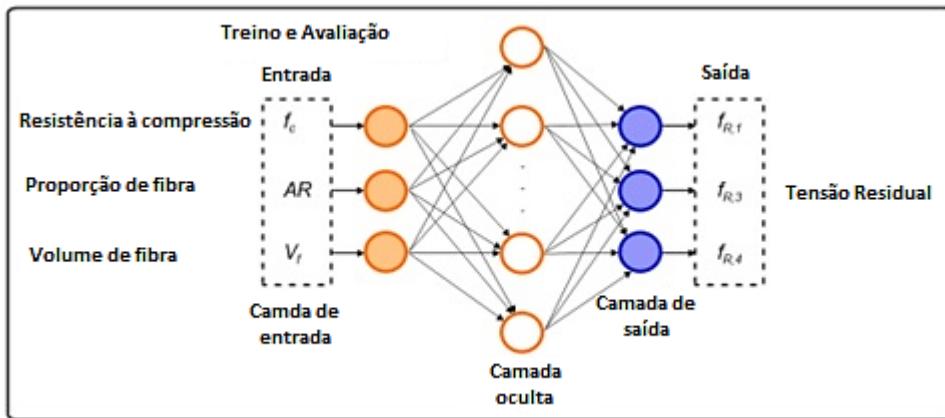


Figura 15 - Representação sistemática da arquitetura RNA, adaptado de Congro et al. [46].

Os parâmetros analisados foram a resistência média a compressão ( $f_c$ ), fração volumétrica da fibra ( $V_f$ ), proporção da fibra ( $AR$ ) para obtenção dos valores médios da resistência a flexão pós-pico ( $f_{R,1}$ ,  $f_{R,3}$  e  $f_{R,4}$ ). Cinco arquiteturas de neurônios distintas foram testadas para gerar a melhor rede neural artificial. O número de neurônios para as redes varia entre vinte e quarenta e dois, mostrando excelente concordância. Uma camada foi considerada para as análises. Os valores de regressão para todas as cinco RNAs estão acima de 0,92, o que indica um bom fator entre valores previstos e experimentais, como apresentado na Tabela 2.

Tabela 2 - Valores de regressão para cada conjunto de dados de ANN [46].

<b>ANN</b>	<b>R<sup>2</sup> Training</b>	<b>R<sup>2</sup> Test</b>	<b>R<sup>2</sup> Global</b>
ANN 1	0,9252	0,9291	0,9261
ANN 2	0,9338	0,9317	0,9331
ANN 3	0,9446	0,9336	0,9485
ANN 4	0,9437	0,9053	0,9385
ANN 5	0,9353	0,9372	0,9355

A Figura 16 apresenta os resultados da validação da RNA, onde a figura 16 (a), 16 (b) e 16 (c) mostram os resultados experimentais versus os previstos por cada RNAs. De acordo com o critério combinado considerando regressão, o modelo de RNA 3 (treinada com 1000 iterações, 226 parâmetros efetivos e um gradiente de 4,30e-6) foi o melhor sistema, com um erro absoluto inferior a 0,65 MPa e um erro relativo inferior a 15%.

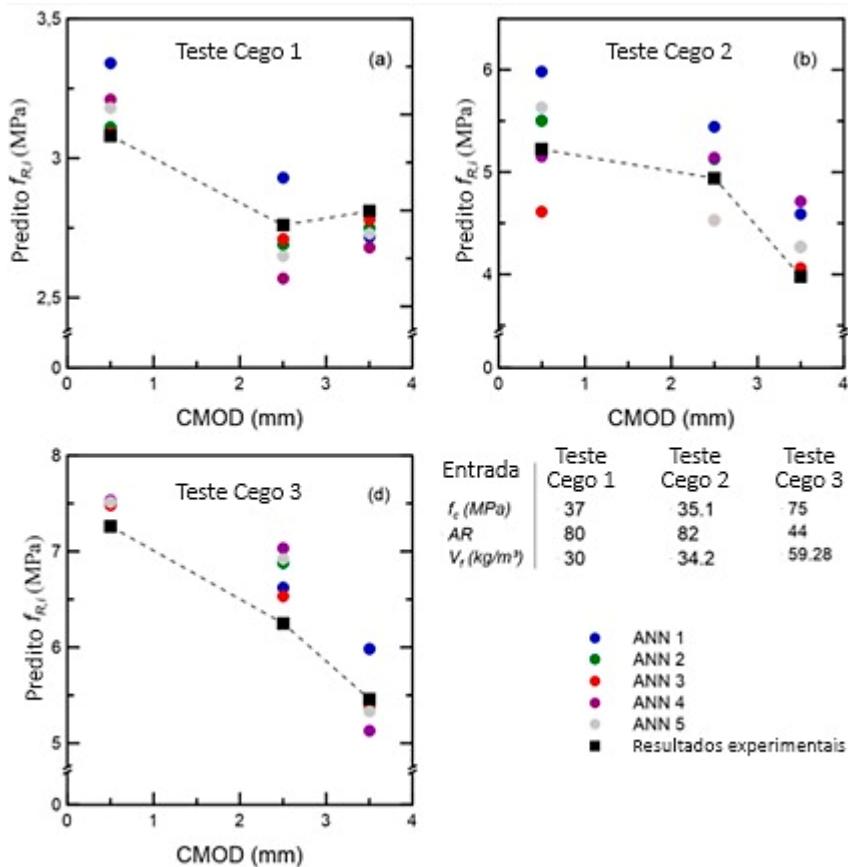


Figura 16 - Resultados de validação de RNA 1 (a), 2 (b) e 3 (c), adaptado de Congro et al. [46].

O estudo apresentado por Nehdi et al. [1] demonstra o potencial uso de RNAs para prever a retração autógena do concreto sob diferentes temperaturas de cura. Além disso, a influência de parâmetros importantes, incluindo fator a/c, dosagem de aditivo plastificante e temperatura de cura na retração autógena foram analisados quantitativamente e avaliados com relação ao conhecimento disponível na literatura. As curvas de retração autógena resultantes de análises experimentais e de modelos são ilustradas na Figura 17.

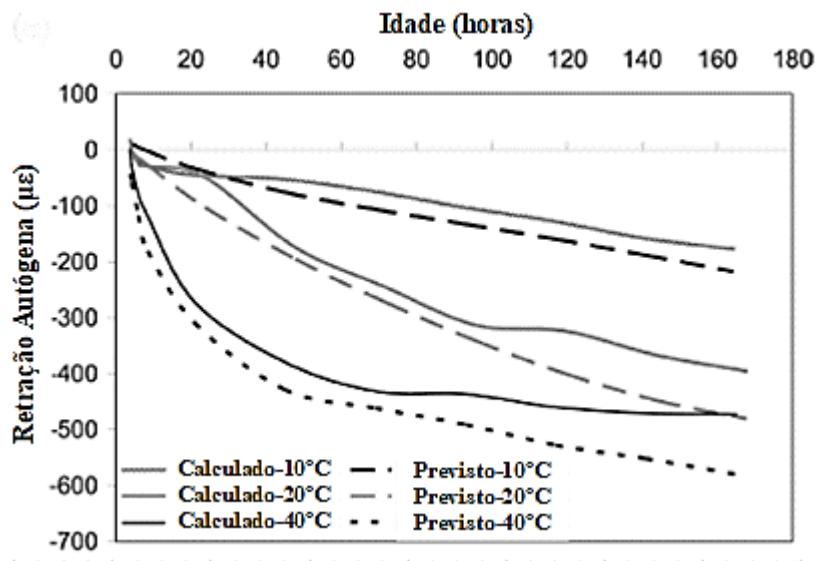


Figura 17 - Valores de retração autógena medidos em comparação como previsto para  $a/c=0,22$ , adaptado de Nehdi et al. [1].

Pode-se observar que as previsões da RNA estavam de acordo com os resultados medidos em toda a faixa do comportamento da retração. Uma comparação entre os valores de retração autógena medidos e previstos pela RNA mostra um desvio de aproximadamente  $\pm 20\%$ , o que é bastante razoável (Figura 18).

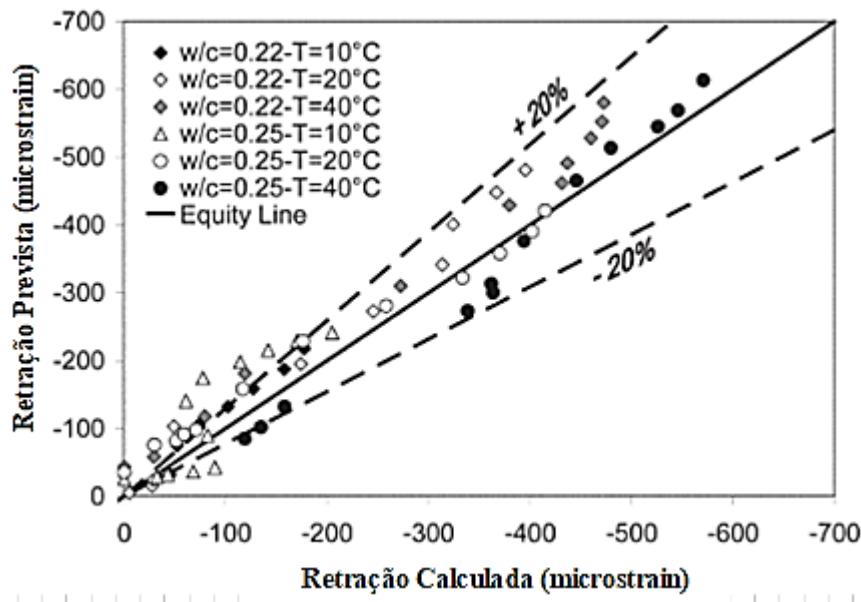


Figura 18 - Desvio entre os valores de retração autógena medidos e previsto [1].

A retração autógena é um mecanismo altamente complexo o que torna a modelagem de seu comportamento uma tarefa difícil. O estudo de Nehdi et al. [1]

teve como objetivo demonstrar a possibilidade de adaptação de RNAs para prever a retração autógena do concreto em função do seu dimensionamento de mistura sob diferentes temperaturas de cura.

### 3 Metodologia

#### 3.1. Aquisição dos Bancos de Dados

O conjunto de dados nacionais de ensaios de retração do concreto por secagem foram obtidos da empresa Chimica Edile do Brasil com a realização de estudos de dosagem de concreto para piso industriais com e sem compensador de retração no ano de 2021 e 2022 nos laboratórios da Qualitec Controle Tecnológico e da Bianco Tecnologia do Concreto. O banco de dados nacionais está no anexo II deste trabalho, com o total de 689 leituras de retração.

Um segundo banco de dados foi obtido de uma base de dados mundial disponível por Bazant [47], foram compilados dados de pesquisas publicadas em diferentes países que são base para análise da fissuração e o efeito da retração. Dados como a localização, dosagem, umidade relativa, razão volume da amostra com a superfície de secagem, idade final da cura úmida, resistência à compressão, o módulo de elasticidade aos 28 dias, composição química do cimento, aditivos e adições, tipo de agregado foram catalogados. O período de coleta desses dados foi entre 1958 a 2017. Neste trabalho foi adotado o período entre 2000 e 2017 para afins de análises, que resultou em 5.149 leituras de retração, uma vez que os materiais ao longo do tempo são modificados, como exemplo o cimento e os aditivos. Teve como premissa na construção do banco de dados internacionais o agrupamento dos resultados que foram oriundos de ensaio de retração livre em prismas e os demais resultados foram removidos da base de dados para não utilização no modelo.

Para obtenção dos dados nacionais, a execução dos ensaios seguiu conforme a NBR 16834:2020. Os ensaios consistiram na moldagem de corpos de prova prismáticos 75x75x285mm (largura x altura x comprimento) em laboratório com temperatura e umidade relativa controlada,  $23 \pm 2^\circ\text{C}$  e  $50 \pm 5\%$ , respectivamente. A leitura inicial é efetuada logo após a desforma com o prazo máximo de 20 h após a moldagem e armazenado até a idade de sete dias em câmara úmida com umidade

relativa do ar  $\geq 95\%$ , realizando leituras de um dia, dois dias e sete dias. Após a leitura de sete dias, os corpos de prova foram mantidos em câmara seca com temperatura de  $23 \pm 2^\circ\text{C}$  e umidade relativa do ar de  $50 \pm 5\%$  até a idade de 56 dias e efetua leituras de 14 dias, 28 dias e 56 dias. Os resultados são apresentados em valores correspondente às variações dimensionais, valores positivos indicam expansão e negativos indicam retração. A Figura 19 ilustra a leitura de um corpo de prova.



Figura 19. Aparato para determinação para o ensaio de variação dimensional. A seta azul indica a posição do corpo de prova durante o ensaio.

Neste banco de dados foi adicionado para cada corpos de prova características de mistura, como a identificação da localidade dos materiais, relação água/cimento, relação agregados/cimento, teor de argamassa, relação agregado miúdo artificial/agregado miúdo total, consumo de agregados/ $\text{m}^3$ , consumo de cimento e tipo de cimento, consumo de microfibra e macrofibra sintética ou metálica. Juntamente com as informações anteriores, foram acrescentado os aditivos, como a dosagem dos aditivos redutor de água tipo 1(RA1), redutor de água tipo 1/retardador (RA1-R), redutor de água tipo 2 (RA2) e compensador de retração (CR), segundo a classificação da NBR 11768-1:2019, conhecidos comercialmente como polifuncional, mid ranger e superplastificante, respectivamente.

### 3.2.

#### Análise dos Dados Nacionais

O banco de dados foi analisado utilizando as bibliotecas gráficas e de pré-processamento de dados como *Pandas*, *Matplotlib* e *Seaborn* que foram programadas em linguagem *Python* e são ferramentas *open-source*.

A Figura 20 apresenta a frequência das leituras por região, observa-se que a região sudeste tem o maior número de resultados neste banco de dados . A Figura 21 ilustra o total de quantitativo por tipo de cimento, onde o CP V ARI RS foi o mais utilizados nas dosagens, ao oposto do CP V ARI, menos utilizado.

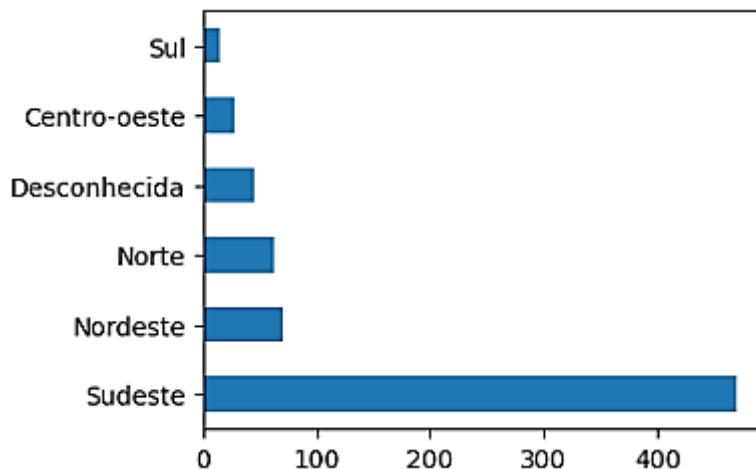


Figura 20 - Número de leituras por região.

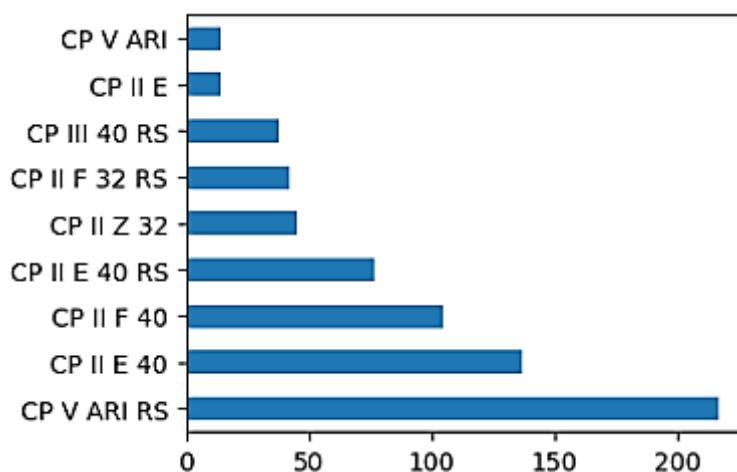
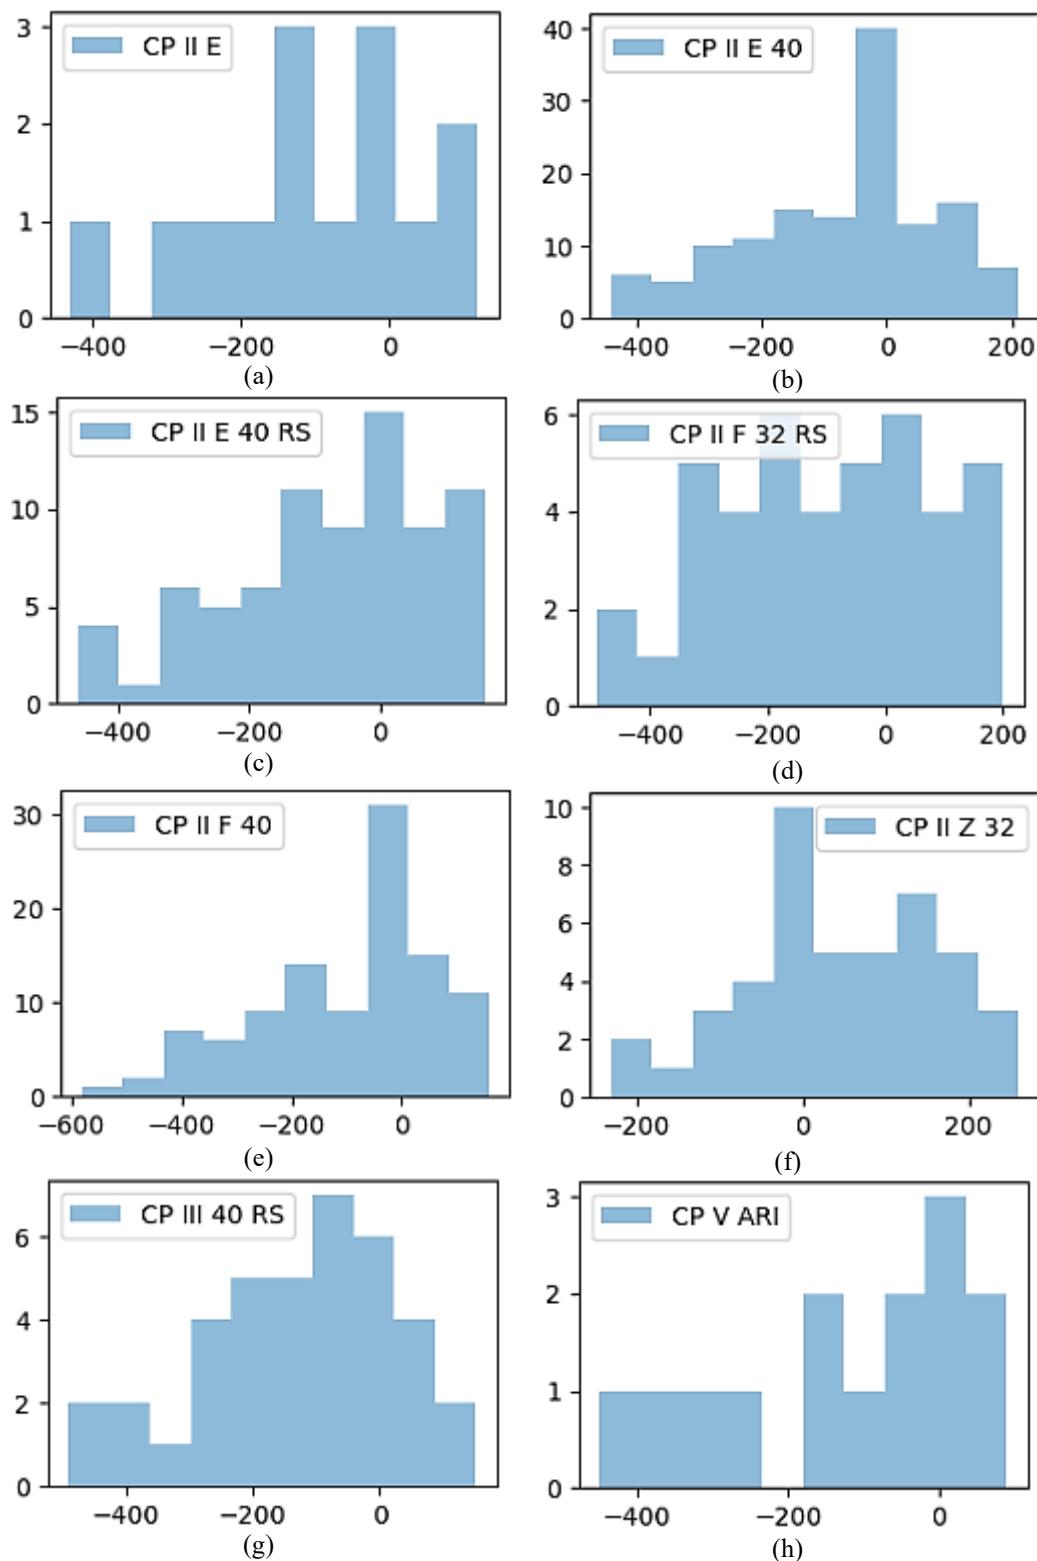


Figura 21 - Número de leituras por tipo de cimento.

Os resultados de leituras de retração relacionado com o tipo de cimento são apresentados na Figura 22. Observa-se que o cimento tipo CP II Z 32 teve a menor amplitude de resultados de retração, variando de uma expansão de 200  $\mu\text{m}/\text{m}$  a retração de -200  $\mu\text{m}/\text{m}$ . O cimento CP II F 40 e o CP V ARI RS estão com os maiores número de valores de retração que chega próximo a -600  $\mu\text{m}/\text{m}$ .



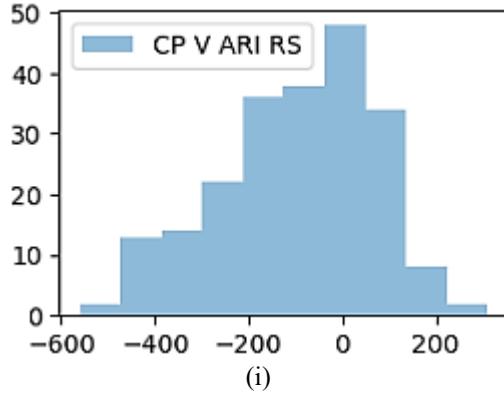


Figura 22 - Histogramas de resultados de retração em  $\mu\text{m}/\text{m}$  com diferentes tipos de cimento, sendo: (a) CP II E, (b) CP II E 40, (c) CP II E 40 RS, (d) CP II F 32 RS, (e) CP II F40, (f) CP II Z 32, (g) CP III 40 RS, (h) CP V ARI e (i) CP V ARI RS.

As relações lineares entre variáveis podem ser mostradas e quantificadas como uma matriz de correlação. A matriz de correlação é uma matriz quadrada que mede a dependência linear entre pares de atributos. Os coeficientes de correlação variam de -1 a 1, onde dois atributos têm uma correlação positiva perfeita se igual a 1, sem correlação igual a zero e uma correlação negativa perfeita se igual a -1.

A análise de correlação pelo método Spearman foi usada para avaliar todas a variáveis de entrada disponíveis, não somente as correlações lineares, mas qualquer relação monotônica entre duas variáveis. As variáveis de entrada com correlações significativas foram mantidas enquanto aquelas com correlações insignificantes foram eliminadas para redução do modelo. Os cálculos foram feitos através da equação 3.1.

$$\rho_{S_i} = \frac{\sum_{j=1}^m (R_i^j - \bar{R}_i)(S_j - \bar{S})}{\sqrt{\sum_{j=1}^m (R_i^j - \bar{R}_i)^2 \sum_{j=1}^m (S_j - \bar{S})^2}} \quad (3.1)$$

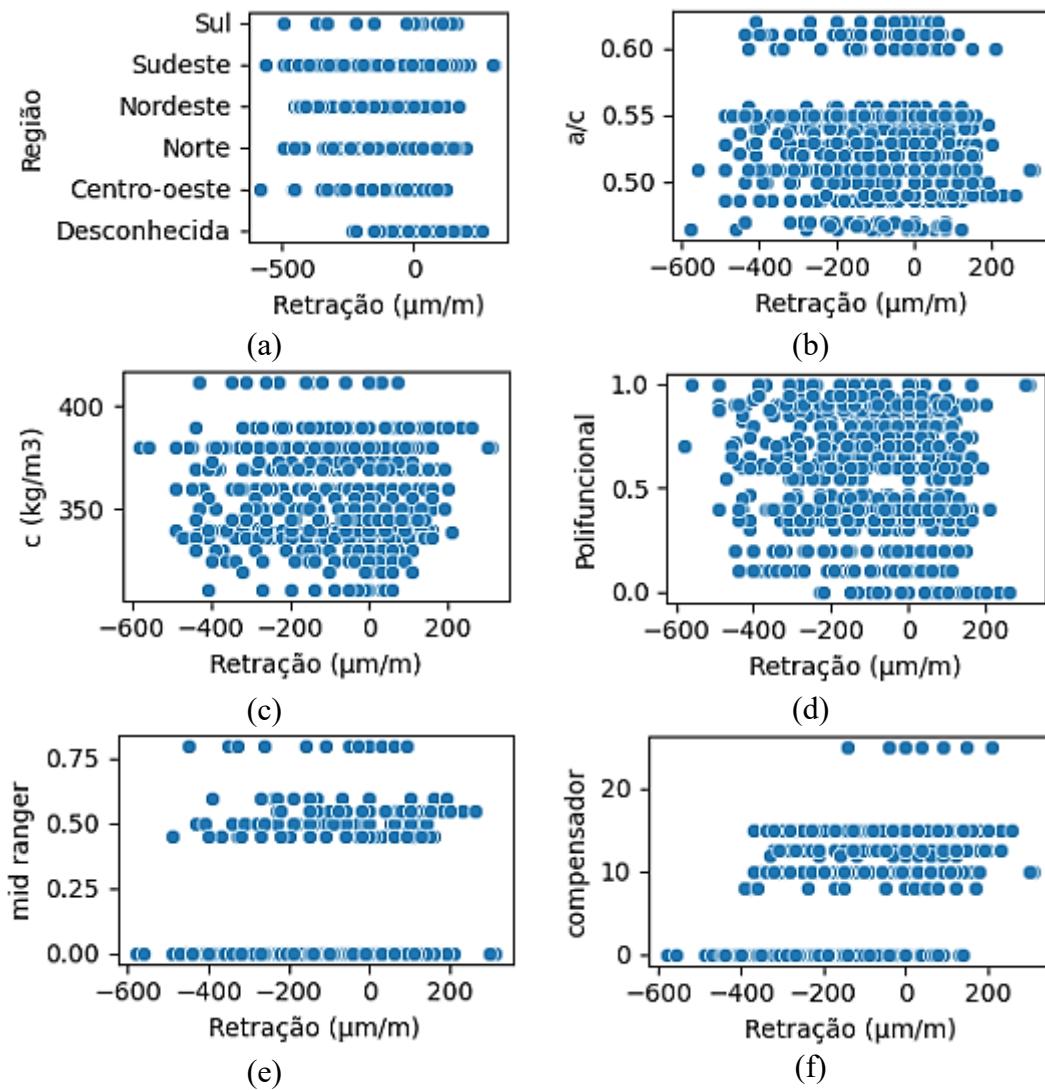
Onde  $\rho_{S_i}$  representa o coeficiente para a correlação entre a  $i$ -ésima variável de entrada e variável de saída,  $m$  representa o número de grupos que representam amostras,  $R_i^j$  e  $\bar{R}_i$  representam a ordem do  $j$ -ésimo grupo de valores de amostras de dados e a ordem média do  $m$ -ésimo grupo de amostras de dados da  $i$ -ésima variável de entrada, respectivamente, e  $S_j$  e  $\bar{S}$  representam a ordem e ordem média da retração por secagem do concreto do  $j$ -ésimo grupo de dados de amostra, respectivamente [50].

Tabela 3 - Dados correlacionados.

<b>Dados Correlacionados</b>	<b>Faixa</b>	<b>Retração (%)</b>
a/c	0,465 – 0,620	0,01
ag/c	4,04 – 6,04	-0,01
argamassa (%)	43,6 – 61,0	-0,02
artificial/natural	0,00 – 0,80	-0,02
c (kg/m3)	311 – 412	0,01
polifuncional (%)	0,00 – 1,0	-0,15
mid ranger (%)	0,00 – 0,80	0,12
superplastificante (%)	0,00 – 1,12	-0,03
compensador (kg)	0,0 – 25,0	0,45
microfibra de PP (kg)	0,000 – 0,600	-0,11
macrofibra de PP (kg)	0,00 – 6,00	0,05
macrofibra de aço (kg)	0,00 – 25,00	0,03
dt (dias)	0 – 56	-0,66
Região_Centro-oeste	-	-0,03
Região_Desconhecida	-	0,20
Região_Nordeste	-	-0,06
Região_Norte	-	-0,02
Região_Sudeste	-	-0,05
Região_Sul	-	0,03
cimento_CP II E	-	-0,01
cimento_CP II E 40	-	0,03
cimento_CP II E 40 RS	-	0,01
cimento_CP II F 32 RS	-	-0,03
cimento_CP II F 40	-	-0,02
cimento_CP II Z 32	-	0,20
cimento_CP III 40 RS	-	-0,07
cimento_CP V ARI	-	-0,03
cimento_CP V ARI RS	-	-0,05

Os dados de entrada como fator a/c, teor de argamassa, relação entre agregado artificial e agregado natural, superplastificante, microfibra, macrofibra de polipropileno e aço foram removidos dos dados de entrada do modelo, uma vez que os resultados de correlação foram baixos. Os resultados apresentados pelo modelo

de correlação de Spearman são apresentados na Tabela 3 somente com correlação com a retração, devido à limitação da apresentação da dimensão da matriz completa neste trabalho. Na bibliografia, estudos e pesquisas apresentam correlação direta entre a/c (água/cimento) e c (consumo de cimento) para resultado da retração, no presente trabalho permanecem como dados de entrada para o modelo proposto por mais que neste banco de dados os valores de correlação apresentem valores baixos.



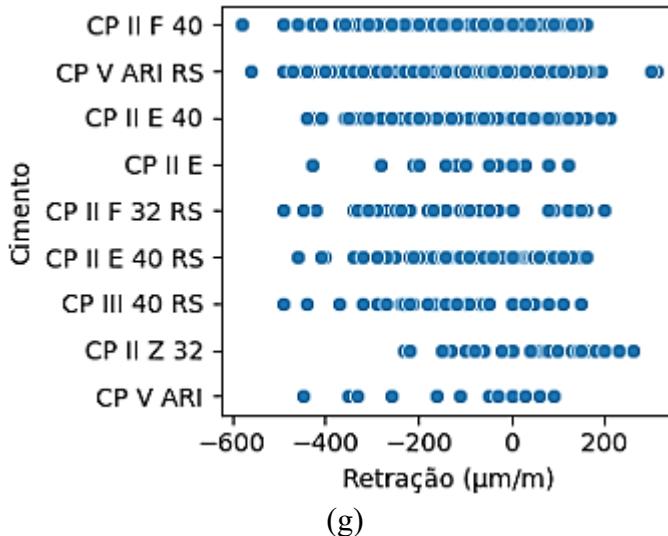


Figura 23 - Gráfico de dispersão de dados de acordo com os resultados de retração por secagem, sendo: (a) Região, (b) a/c, (c) consumo de cimento, (d) polifuncional, (e) *mid range*, (f) compensador, (g) tipo de cimento.

Na Figura 23 são apresentados os gráficos de dispersão de dados em relação aos dados de retração por secagem do concreto do banco de dados obtido após a exclusão dos dados de entrada com baixa correlação. Nota-se que há uma grande dispersão de pontos nos gráficos acarretando em uma correlação não evidente entre a retração, necessitando de um tratamento de dados mais refinado. Os pesquisadores [6,8] em seus estudos apresentam que quanto maior for a relação a/c maior será a retração devido a quantidade de água evaporável existente na pasta de cimento, assim como o aumento do consumo de cimento, para relação a/c constante, devido resultar em um maior volume de pasta de cimento hidratada, que é passível de retração. O que se explica nesse estudo em não apresentar essa correlação direta é que a faixa obtida no banco de dados está com a amplitude com os valores mínimos e máximos próximos, de tal modo que não conseguiu uma amplitude que consiga captar as correlações apresentadas nas bibliografias.

A Tabela 4 mostra a quantidade total de dados, média, desvio padrão, primeiro, segundo, terceiro e quarto quartis e os valores mínimo e máximo para cada variável observada dos dados brutos.

Tabela 4 - Dados brutos: quantidades de dados, média, desvio padrão, 1º, 2º, 3º e 4º quartis e valores mínimo e máximo.

	<i>a/c</i>	<i>c</i> (kg/m3)	<i>polifuncional</i> (%)	<i>mid ranger</i> (%)	<i>compensador</i> (kg)	<i>dt (dias)</i>
quant.	689	689	689	689	689	689
média	0,53	354,72	0,53	0,11	7,03	14,99
DP	0,04	22,60	0,29	0,22	6,54	18,42
mín	0,47	311,00	0,00	0,00	0,00	0,00
25%	0,51	336,00	0,35	0,00	0,00	1,00
50%	0,54	345,00	0,60	0,00	10,00	7,00
75%	0,55	373,00	0,80	0,00	12,50	28,00
máx	0,62	412,00	1,00	0,80	25,00	56,00
	<i>CP II E</i>	<i>CP II E 40</i>	<i>CP II E 40 RS</i>	<i>CP II F 32 RS</i>	<i>CP II F 40</i>	<i>CP II Z 32</i>
quant.	689	689	689	689	689	689
média	0,02	0,20	0,11	0,06	0,15	0,07
DP	0,14	0,40	0,32	0,24	0,36	0,25
mín	0,00	0,00	0,00	0,00	0,00	0,00
25%	0,00	0,00	0,00	0,00	0,00	0,00
50%	0,00	0,00	0,00	0,00	0,00	0,00
75%	0,00	0,00	0,00	0,00	0,00	0,00
máx	1,00	1,00	1,00	1,00	1,00	1,00
	<i>CP III 40 RS</i>	<i>CP V ARI</i>	<i>CP VARI RS</i>	<i>retração (%)</i>		
quant.	689	689	689	689		
média	0,06	0,02	0,31	-0,008		
DP	0,23	0,14	0,46	0,016		
mín	0,00	0,00	0,00	-0,058		
25%	0,00	0,00	0,00	-0,019		
50%	0,00	0,00	0,00	-0,005		
75%	0,00	0,00	1,00	0,003		
máx	1,00	1,00	1,00	0,031		

Na Figura 24 é apresentado os concretos que tiveram em sua dosagem a adição do compensador de retração contraposto aos que não tiveram, em diferentes gráficos de acordo com a idade do concreto, conforme leitura da retração da NBR 16834 (2020). Observa-se nos dados que os concretos com compensador de retração estão mais descolados a direita, apresentando menor retração enquanto as dosagens sem CR apresentaram maiores valores de retração, dados descolados mais à esquerda.

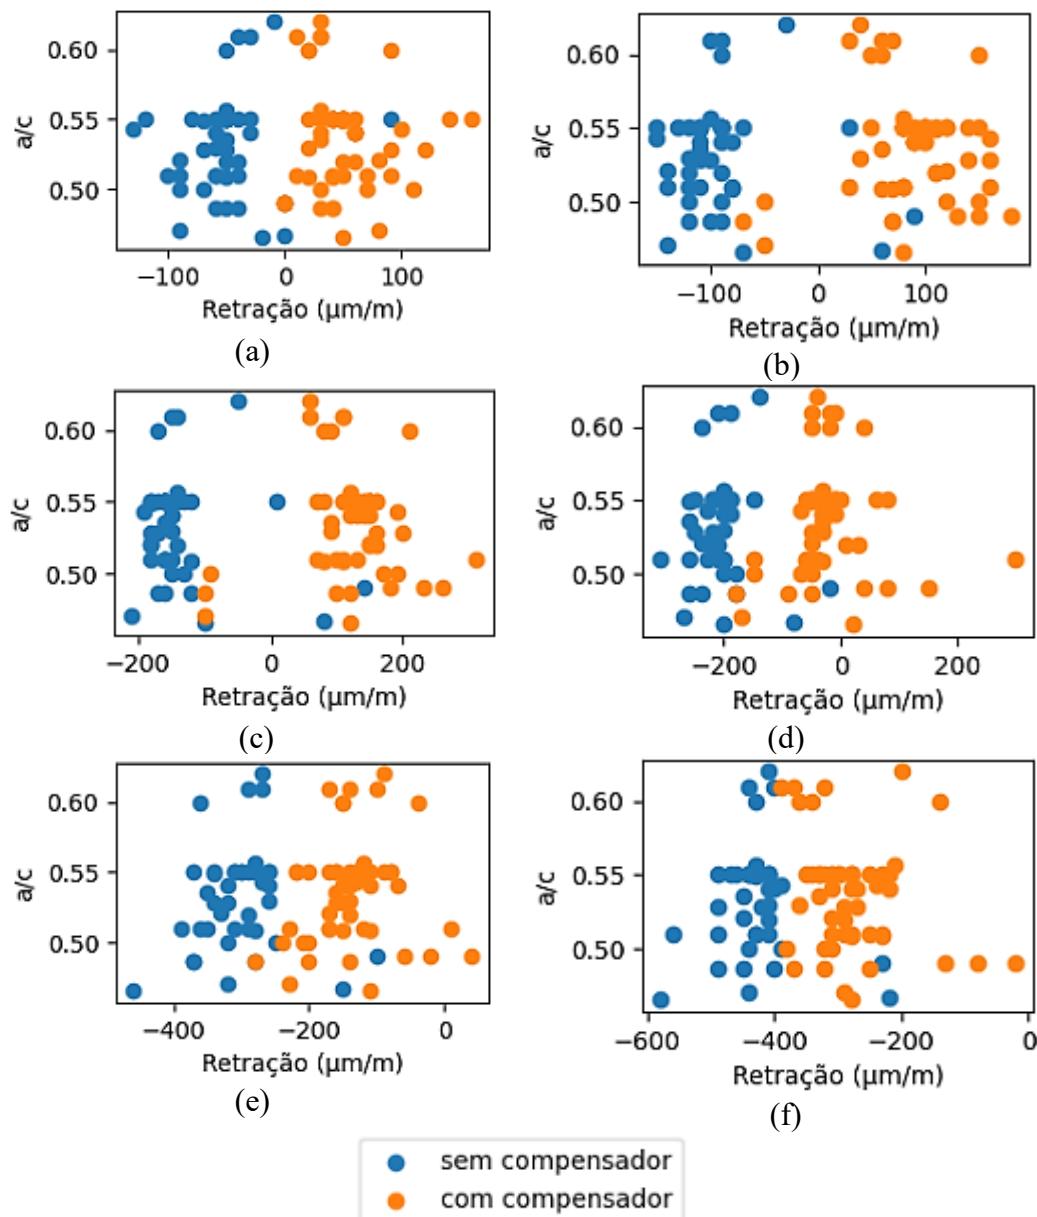


Figura 24 - Gráfico de dispersão de dados de acordo os resultados de retração por secagem em relação ao fator água/cimento com e sem compensador de retração, sendo: (a) Dia 1, (b) Dia 2, (c) Dia 7, (d) Dia 14, (e) Dia 28, (f) Dia 56.

Os dados com o comparativo do comportamento do concreto com e sem CR ao longo do tempo são apresentados na Figura 25. Nota-se que os resultados até o décimo dia de idade do concreto com compensador apresentaram expansão e após o 56º dia com valores de retração, na média, próximo de  $-300\mu\text{m/m}$ . Este valor é inferior em 40% ao valor médio do concreto sem o aditivo, com valor médio de  $-500\mu\text{m/m}$

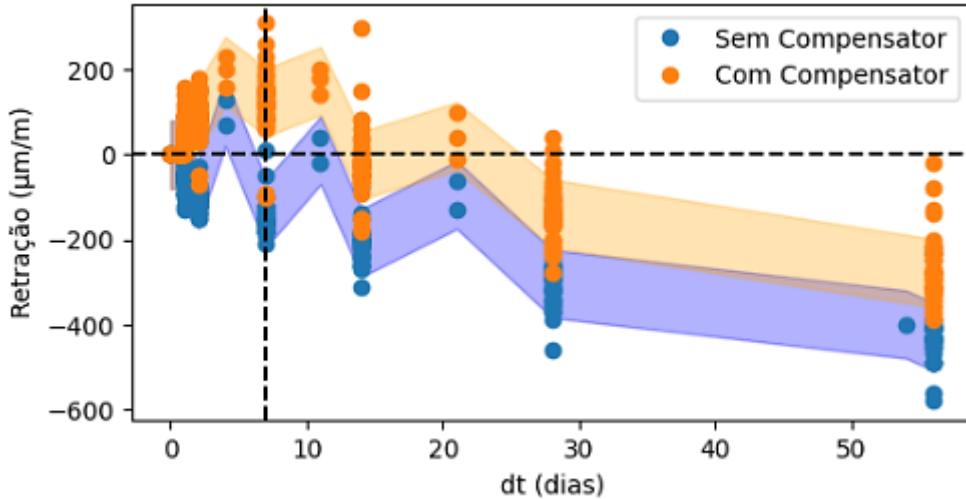


Figura 25 - Comportamento comparativo de concreto com e sem agente expensor.

### 3.3. Desenvolvimento do Modelo de Redes

Este estudo usa função de ativação para camadas a função *ReLU*, para estimar os alvos corretos, esta função é responsável pela decisão se a informação que o neurônio está recebendo é relevante para a informação fornecida ou deve ser ignorada sem que ative todos os neurônios ao mesmo tempo, e a função de ativação linear é usada para a camada de saída. Todas a simulações e testes para o modelo de rede neurais artificiais foram realizadas usando a biblioteca *Keras* da linguagem de programação *Python*, biblioteca de rede neural de código aberto para *Deep Learning*. O número de épocas é definido em 1.000, número este de vezes que todo o conjunto de dados é passado pela rede, mas a função de parada antecipada interrompe o treinamento após a parada do desempenho do modelo para melhorar a validação do conjunto de dados.

A técnica de regularização de parada antecipada é usada para reduzir o *overfitting*. O fenômeno *overfitting* ocorre quando o modelo acaba memorizando os dados de treinamento, sem ser capaz de generalizar e fazer previsões precisas de novos dados. A parada antecipada objetiva sempre que métricas de validação não melhoram para determinado número de rodadas na fase de treinamento da rede, mesmo se as métricas de desempenho de treinamento continuam a aumentar [49].

O desenvolvimento do modelo de pré-processamento separa os dados brutos em atributos de entrada (entradas do modelo, variável X) e alvos (valores de saída do modelo, variável Y) são apresentados na Tabela 5.

Tabela 5 – Variáveis de entrada e saída do modelo.

Variáveis	Classificação	Tipo
a/c	numérica	entrada
consumo de cimento (kg/m3)	numérica	entrada
tipo de cimento	categórica	entrada
aditivo polifuncional	numérica	entrada
aditivo plastificante ( <i>mid ranger</i> )	numérica	entrada
aditivo compensador de retração	numérica	entrada
dt (dias)	numérica	entrada
retração (%)	numérica	saída

Depois de definir os dados de entrada e saída, os dados são divididos novamente em conjuntos de treinamento e teste. O conjunto de dados de treinamento é usado pelo algoritmo de aprendizado supervisionado para estimar os parâmetros do modelo, que é a amostra de dados usada para ajustá-lo. O conjunto de teste também é usado durante o desenvolvimento do modelo que faz uma avaliação recorrente enquanto ajusta hiperparâmetros de nível superior. Foram utilizadas 689 leituras de retração para desenvolver e avaliar os modelos em redes neurais onde 70% foram usados para treinamento e 30% para teste.

Métricas de desempenho adicionais são adotadas para avaliar o desempenho do modelo de vários ângulos. Essas métricas são matemáticas ou construções de lógica que examinam como as previsões do modelo convergem ou divergem dos valores reais. Algumas das métricas comumente usadas em análise de RNA são listadas abaixo. Quando desempenho do modelo for adequado, então o treinamento termina e o modelo é implantado. Caso contrário o modelo deve ser ajustado até que um desempenho satisfatório seja alcançado. Tal ajuste pode envolver a adoção de diferentes estratégias de treinamento. Essas estratégias necessitam de dados/observações adicionais, ou ajustes de hiperparâmetros do modelo [40]. As métricas aqui utilizadas são :  $R^2$  (equação 4.1), coeficiente de determinação ajustado ( $R_{adj}^2$  – equação 4.2), erro absoluto médio (em inglês, *Mean Absolute Error*, *MAE* – equação 4.3), erro quadrático médio (em inglês, *Mean Squared Error*, *MSE* – equação 4.4) e raiz quadrada do erro médio (em inglês, *Root Mean Square Error*, *RMSE* – equação 4.5).

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}^{(i)} - \bar{y})^2}{\sum_{i=1}^n (y^{(i)} - \bar{y})^2} \quad (4.1)$$

$$R_{adj}^2 = 1 - \left[ \frac{(1 - R^2)(n - 1)}{n - k - 1} \right] \quad (4.2)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}^{(i)} - \bar{y}| \quad (4.3)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}^{(i)} - \bar{y})^2 \quad (4.4)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}^{(i)} - \bar{y})^2} \quad (4.5)$$

Estabelecer a arquitetura da RNA é outro passo importante para definição do modelo. Vários parâmetros precisam ser definidos durante esta etapa, tais como: o número de neurônios, camadas ocultas e a função de ativação para obter os alvos corretos. Dada a variabilidade aleatória dos métodos de inteligência artificial, várias rodadas foram realizadas, considerando diferentes arquiteturas para obter a rede mais precisa.

A rede mais eficiente teve cinco camadas distribuídas com a seguinte estrutura: camada de entrada com sete neurônios, três camadas ocultas de processamento, com a seguinte estrutura: primeira com 2.000, segunda 500 e terceira com 2.000 neurônios. Para obtenção dos resultados, implementou-se uma camada com um neurônio de output para predição da retração por secagem do concreto, conforme Figura 26.

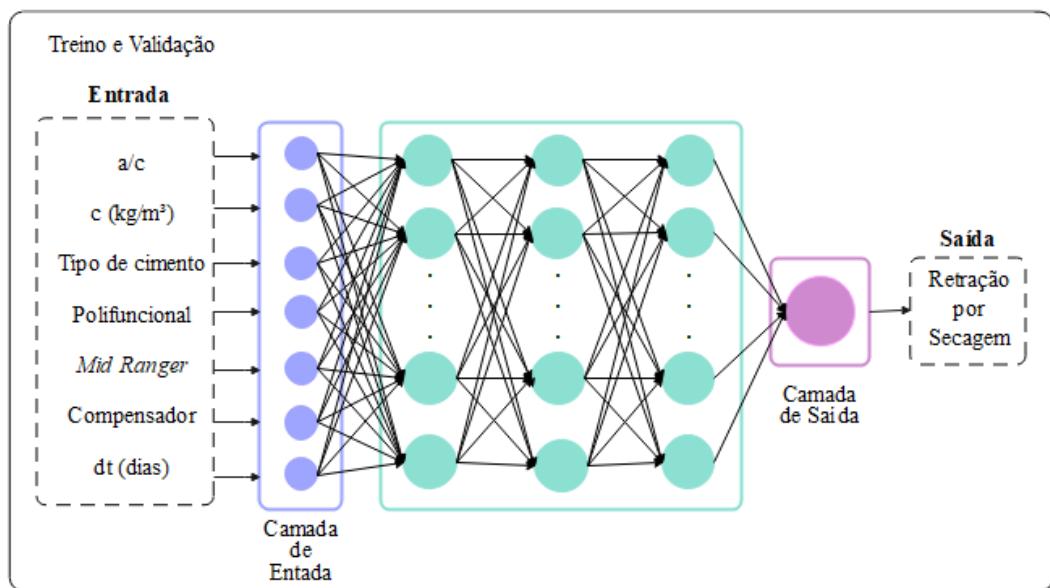


Figura 26 - Representação esquemática da arquitetura da RNA.

**4****Resultados e Discussões**

Como apresentado nas seções anteriores, uma metodologia de inteligência artificial foi proposta para prever a retração por secagem do concreto. Por meio de treinamento e teste foi definido o modelo da rede neural para avaliar os valores de retração com base de dados obtidos em ensaios experimentais em laboratórios nacionais e banco de dados internacionais obtido em literatura técnica disponível , de modo que consegue prever com precisão a retração por secagem do concreto através do modelo desenvolvido. Esta seção apresenta os principais resultados e discussões sobre a análise dos dados, desempenho dos modelos de rede neurais, curvas de regressão e RNA de treinamento e teste, considerando pontos não incluídos no processo de treinamento da RNA.

**4.1.****RNA Treinamento e Performance**

Arquiteturas distintas foram testadas para gerar o melhor modelo de rede neural artificial. O número de neurônios variou de 500 a 2.000 por camada, mostrando excelente concordância. Três camadas ocultas foram consideradas nas análises. Testes de regressão e avaliação de métricas de desempenho foram os critérios adotados para escolher a melhor RNA. A Tabela 6 resume os valores para a rede neural adotada.

Tabela 6 - Dados de avaliação de desempenho do treinamento.

<i>Métricas</i>	<i>Treino</i>
MSE	0,0021
MAE	0,0248
RMSE	0,0461
$R^2$	0,998
$R^2_{adj}$	0,998

Em geral, as métricas de desempenho indicam um alto desempenho para o modelo. Os valores de  $R^2$  excedem a 0,99 para o conjunto de dados, o que evidencia a alta proporção da variância na variável dependente (Y) que são explicados pelas

variáveis independentes (Xs). Semelhante aos valores de  $R^2$  obtidos no presente trabalho também foram relatados em trabalhos anteriores sobre a aplicação de RNAs para prever retração por secagem e retração autógena [1,45,51]. Como o coeficiente de valores de determinação não difere do coeficiente ajustado de determinação ( $R^2_{adj}$ ), o número de variáveis de entrada não mascara os resultados. Enquanto a média de erro absoluto (MAE) é menos sensível a valores atípicos, a média de erro quadrático (MSE) penaliza erros grandes. Embora não haja um valor padronizado para MAE e MSE, as pontuações são comparáveis para os subconjuntos de dados [49]. A raiz média de valores de erro ao quadrado (RMSE) são relatados na tabela com valor de 0,0461.

Na Figura 27 apresenta-se a curva de regressão para os valores previstos e observados para o conjunto de dados de treinamento. O alto grau de concordância entre os valores experimentais e as saídas do modelo sugerem que o modelo aprendeu o padrão dos dados mesmo em regiões não lineares. Pode-se notar que o modelo de RNAs capturou as relações de entrada-saída, porque os pontos estão localizados em sua maioria ou ligeiramente abaixo/acima da linha de equidade entre os valores de retração experimental e previsto.

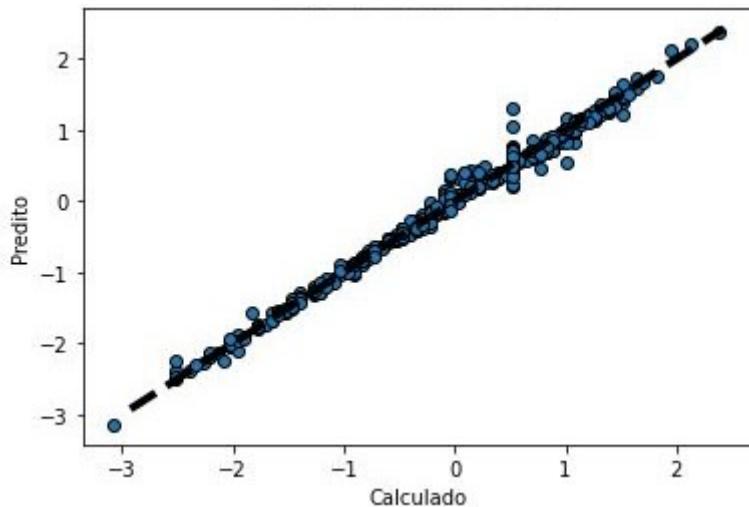


Figura 27 - Gráfico de comparação entre previsto e observado da dispersão do modelo de treino.

#### 4.2. RNA Teste

Para avaliar a capacidade de generalização da RNA, ela foi testada usando os dados de teste (30% do conjunto de dados experimentais). Tais pontos de teste não

foram previamente apresentados ao modelo, e assim a capacidade preditiva do modelo para novos dados pode ser avaliada. Os setes parâmetros de entradas dos pontos do conjunto de dados foram introduzidos no modelo de RNAs e a resposta é apresentada na Figura 28. Os dados de desempenho para avaliar a validação da rede são apresentados na Tabela 7. Semelhante ao caso dos dados de treinamento, observa-se que os valores de  $R^2$  estão acima de 0,90 para a base de dados analisada, apresentando o aprendizado do modelo com alta relação com os dados de *input* versus retração do concreto. O valor de coeficiente  $R^2_{adj}$  não difere do  $R^2$ , validando o número de variáveis de entrada. Os valores de MSE e MAE permanecem ainda pequenos quando comparados com todos os subconjuntos de dados. O valor de 0,30 de RMSE é apresentado na Tabela 7.

Tabela 7 - Dados de avaliação de desempenho de teste.

<b>Métricas</b>	<b>Teste</b>
MSE	0,0902
MAE	0,211
RMSE	0,30
$R^2$	0,906
$R^2_{adj}$	0,890

Os pontos de dados estão principalmente localizados próximos da linha de equidade, conforme apresentado na Figura 28. Assim, pode-se deduzir que a RNA teve uma capacidade de generalização satisfatória para prever retração por secagem do concreto.

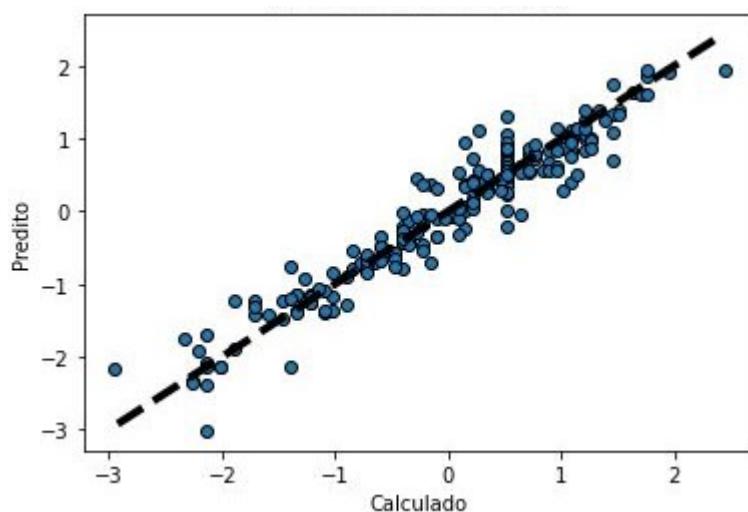


Figura 28 - Gráfico de comparação entre previsto e observado da dispersão do modelo de teste.

#### 4.3. RNA Avaliação

O histograma de erros entre valores previstos e experimentais do conjunto de dados de teste são apresentados na Figura 29. Os erros foram assimétricos para o conjunto de dados. Um pequeno erro padrão foi observado no caso do conjunto de dados de retração, valores a esquerda do gráfico, uma vez que o volume de dados de retração é maior, quando comparado com valores de expansão.

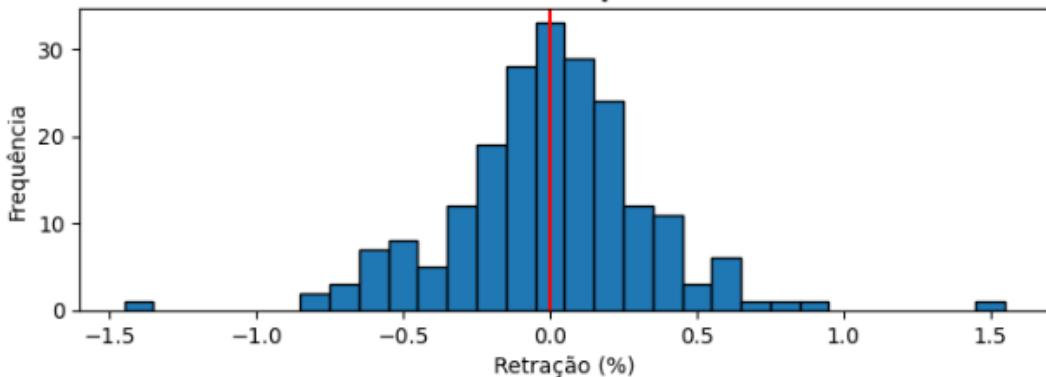


Figura 29 - Histograma dos valores de erro entre os valores de retração e expansão previstos e experimentais.

Neste estudo, o gráfico de SHAP (em inglês, *SHaple Additive exPlanation*) traz interpretações locais e globais de cada parâmetro de entrada. A SHAP ilustra informações comparáveis para caracterizar a importância que tem sido amplamente utilizada na literatura, mas é mais apropriada para modelos de aprendizado de máquina, pois é mais estável e fornece informações quantitativas [51].

Os valores SHAP de cada recurso, classificados em ordem de seu valor SHAP médio, são mostrados na Figura 30. Os dados listados no topo da figura podem ser associados à maiores contribuições para saídas do modelo. Os cinco parâmetros que mais influenciam as previsões de retração foram a idade do concreto (dt), aditivo compensador, cimento tipo CP II Z 32, relação água/cimento (a/c), aditivo tipo RA1 (multifuncional) e consumo de cimento (c).

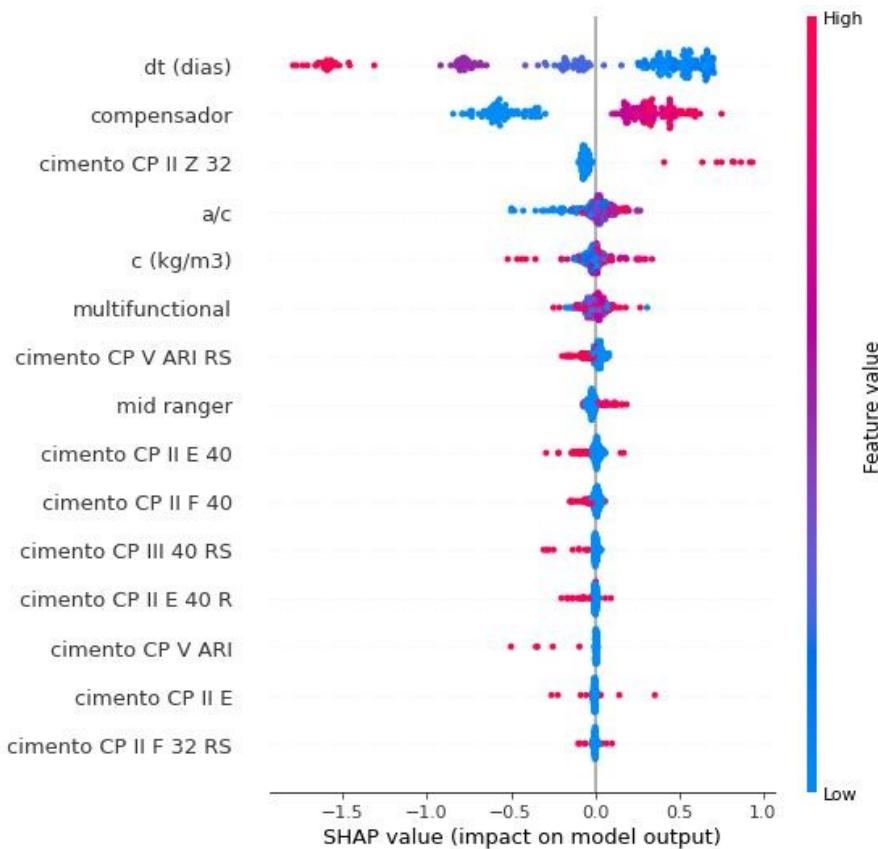


Figura 30 - Análise de importância de recursos usando a biblioteca SHAP em código Python.

Um limite claro pode ser observado para todos esses parâmetros. Os valores de dados altos e baixos influenciam na saída do modelo da seguinte forma: valores elevados de  $dt$  (representado na cor vermelha) diminui o valor SHAP, ou seja, aumenta a retração, um maior consumo do aditivo do tipo RA1 e consumo de cimento também aumentam a retração. Ao contrário o alto teor de aditivo tipo CR tende a diminuir a retração, assim como o cimento CP II Z 32 e aditivo tipo RA1-R.

#### 4.4. RNA para o Banco de Dados Internacionais

Nesta parte do trabalho foi proposto realizar um estudo de redes neurais artificiais em um conjunto de dados de retração por secagem do concreto obtido por meio de um banco de dados mundial disponível por Bazant [47]. Utilizando a mesma metodologia daquela realizada com os dados nacionais, foram compilados dados de pesquisas publicadas em diferentes países que são base para análise da fissuração e o efeito da retração. Os dados de entrada e saída para elaboração do

modelo de predição em RNAs são apresentados na Tabela 8. Somente os dados de entrada *cem\_R*, *cem\_RS* e *cem\_SL* são dados categóricos, demais são dados numéricos.

Tabela 8 - Variáveis de entrada e saída do modelo com dados internacionais.

<b>Variáveis</b>	<b>Descrição</b>	<b>Tipo</b>
dt (dias)	idade do concreto	entrada
t dry (dias)	tempo de cura	entrada
Super (kg)	plastificante	entrada
Re (kg)	retardador	entrada
AEA (kg)	incorporador de ar	entrada
fc <sub>28</sub> (MPa)	resistência aos 28 dias	entrada
SiO <sub>2</sub> (%)	sílica ativa	entrada
FlyAsh (%)	cinza volante	entrada
Slag (%)	escória	entrada
c (kg/m <sup>3</sup> )	consumo de cimento	entrada
w/c	água/cimento	entrada
a/c	agregado/cimento	entrada
cem_R	cimento comum	entrada
cem_RS	alta resistência inicial	entrada
cem_SL	baixo calor de hidratação	entrada
shrinkage (%)	retração	saída

Na

Tabela 9 é apresentado, para melhor visualização dos dados recorrentemente utilizados no modelo, a quantidade total de dados, média, desvio padrão, primeiro, segundo e terceiro quartis e os valores mínimos e máximo para cada variável observada dos dados filtrados. Outras informações que fazem parte do conjunto dados das análises não foram apresentadas na tabela abaixo devido à limitação do texto, tais como: sílica; cinza volante; escória; aditivo retardador, superplastificante e incorporador de ar;  $f_{c28}$ ; tempo de cura; e tipos de cimento.

Tabela 9 – Quantidades parciais de dados, média, desvio padrão, 1°, 2° e 3° quartis e valores mínimos e máximos do banco de dados internacional.

	<b>dt (d)</b>	<b>w/c</b>	<b>a/c</b>	<b>c (kg/m<sup>3</sup>)</b>	<b>f<sub>c28</sub> (MPa)</b>	<b>retração (%)</b>
Quantidade	5.149,0	5.149,0	5.149,0	5.149,0	5.149,0	5.149,0
Média	35,2	0,40	4,22	443,0	68,7	-0,0254
Desvio padrão	49,7	0,11	1,32	116,0	20,9	0,0176
Mínimo	-0,5	0,17	1,09	222,0	14,5	-0,0985
25%	4,5	0,30	3,09	340,0	56,5	-0,0381
50%	20,8	0,39	4,14	424,0	70,2	-0,0240
75%	55,4	0,50	5,36	550,0	78,2	-0,0106
Máximo	721,0	0,72	8,07	929,7	128,0	0,0133

A Tabela 10 apresenta a correlação de Spearman que mostra uma relação monótona entre duas variáveis de todo o conjunto de dados. Assim, é eficaz em identificar se duas variáveis são altamente correlacionadas ou não. É possível observar a existência de uma correlação fraca e moderada entre todas as variáveis do conjunto de dados. O par *cem\_SL* e *cem\_R* apresentam a correlação mais baixa, enquanto *dt* e retração tem a maior correlação, que é -0,68, o sinal negativo indica que ele tem uma dependência indireta, quando um aumenta, o outro diminui.

Tabela 10 - Matriz de coeficiente de correlação de Spearman dos dados internacionais.

<b>Dados Correlacionados</b>		<b>Faixa</b>	<b>Retração (%)</b>
dt		-0,50 – 721	-0,68
w/c		0,166 – 0,720	-0,09
a/c		1,08 – 8,07	-0,10
c (kg/m <sup>3</sup> )		222 – 929	0,10
SiO <sub>2</sub>		0,00 – 67,40	-0,21
FlyAsh		0,00 – 42,86	0,09
Slag		0,00 – 100,00	-0,05
Re (kg)		0,00 – 0,767	0,07
Super (kg)		0,00 – 11,824	-0,18
AEA (kg)		0,00 – 0,500	0,12
f <sub>c28</sub>		14,5 – 128,0	-0,05
t dry		0 – 28	-0,21
cem_R		-	0,03

cem_RS	-	0,04
cem_SL	-	-0,06

Embora existe alguma correlação entre as variáveis, a correlação não é alta, não justificando a exclusão de qualquer variável da investigação de modelagem. As baixas correlações gerais justificam o uso de um modelo complexo de inteligência artificial não linear para tentar capturar as relações de dependência entre as variáveis observadas que não são evidentes.

Arquitetura utilizada permaneceu como empregada nos dados nacionais, três camadas ocultas, a primeira e a terceira com 2.000 neurônios e a segunda com 500 neurônios, porém foi necessário treinar a rede novamente com essa base de dados internacionais, uma vez que não obteve resultados satisfatórios com a rede já treinada pelo banco de dados nacionais. A Tabela 11 resume os valores de métricas de desempenho do treinamento e validação.

Tabela 11 - Dados de avaliação de desempenho do treinamento e teste.

<b>Métricas</b>	<b>Treino</b>	<b>Teste</b>
MSE	0,0997	0,1610
MAE	0,1920	0,2680
RMSE	0,3160	0,4010
R <sup>2</sup>	0,899	0,841
R <sup>2</sup> <sub>adj</sub>	0,899	0,839

A Figura 31 mostra as curvas experimentais versus previstas da retração por secagem do concreto. Foi observado que os valores se R<sup>2</sup> para o treinamento (a) e teste (b) foram de 0,89 e 0,84, respectivamente, seguindo a mesma estrutura da RNAs dos dados nacionais, 70% dos dados para treinamento e 30% para teste. Portanto, observa-se que o modelo de RNAs com as entradas selecionadas executa o modelo com os parâmetros determinados e prevê bem os dados de treinamento e teste.

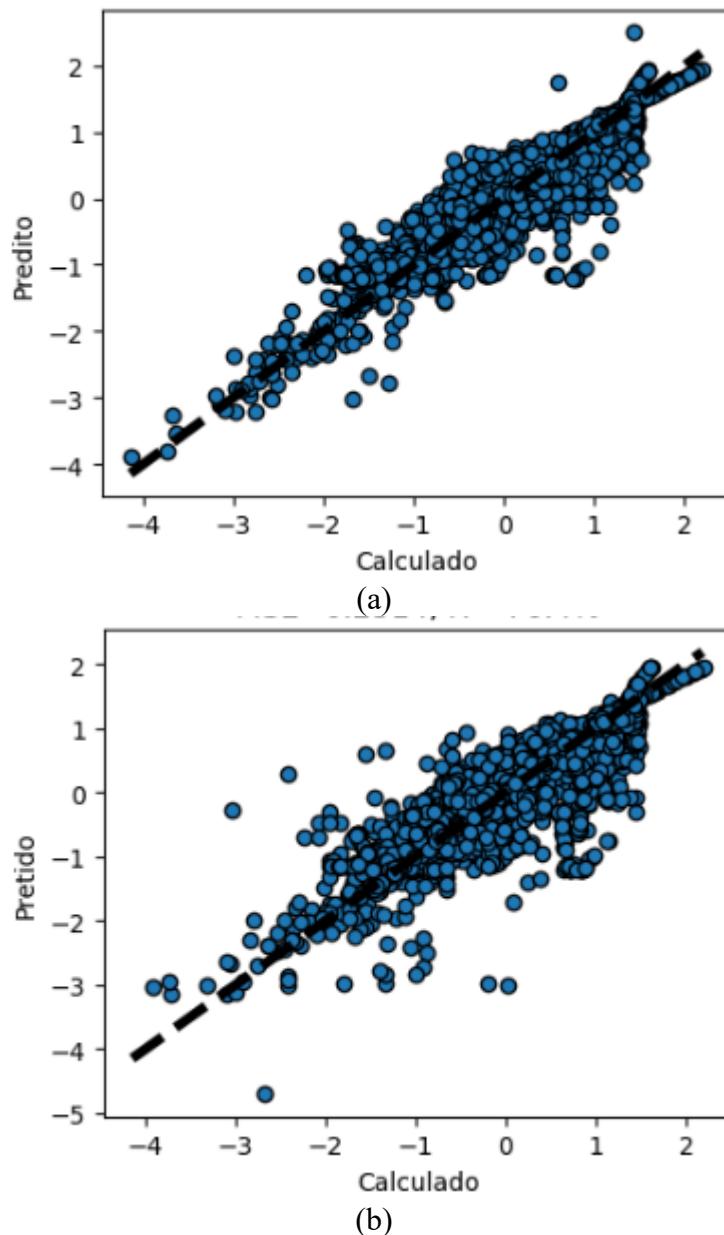


Figura 31 - Gráfico de comparação entre previsto e observado da dispersão do modelo treino (a) e teste (b).

O histograma de erros apresentado na Figura 32 ilustra os valores previstos e experimentais do conjunto de dados de teste dos dados internacionais. Os erros foram assimétricos para o conjunto de dados. A maior frequência de erro é identificada como nulo, enquanto um volume muito menor de erros varia entre  $\pm 0,5$  pontos. A esquerda o gráfico apresenta maior quantitativo de erros comparado aos dados positivos, concreto em expansão.

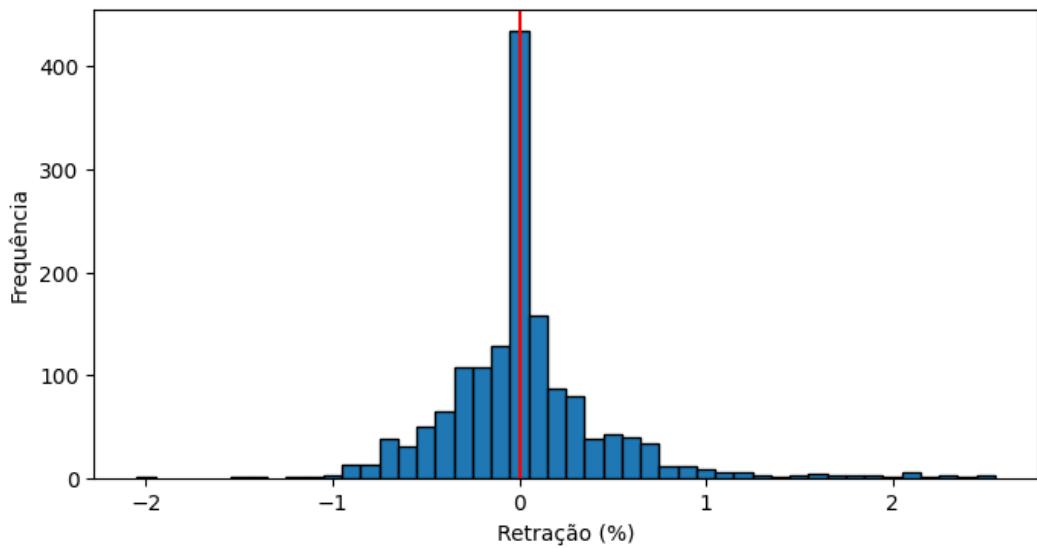


Figura 32 - Histograma dos valores de erro entre os valores de retração e expansão previstos e experimentais dos dados internacionais.

Nota-se que no gráfico SHAP, Figura 33, os dados de entrada de maior importância na obtenção da previsão da retração estão mais acima, em primeiro está o  $dt$ , seguido de  $t\ dry$  e  $Super\ (kg)$ . Enquanto  $AEA\ (kg)$ ,  $cem\_RS$  e  $cem\_SL$  são de menores importância para o modelo, respectivamente.

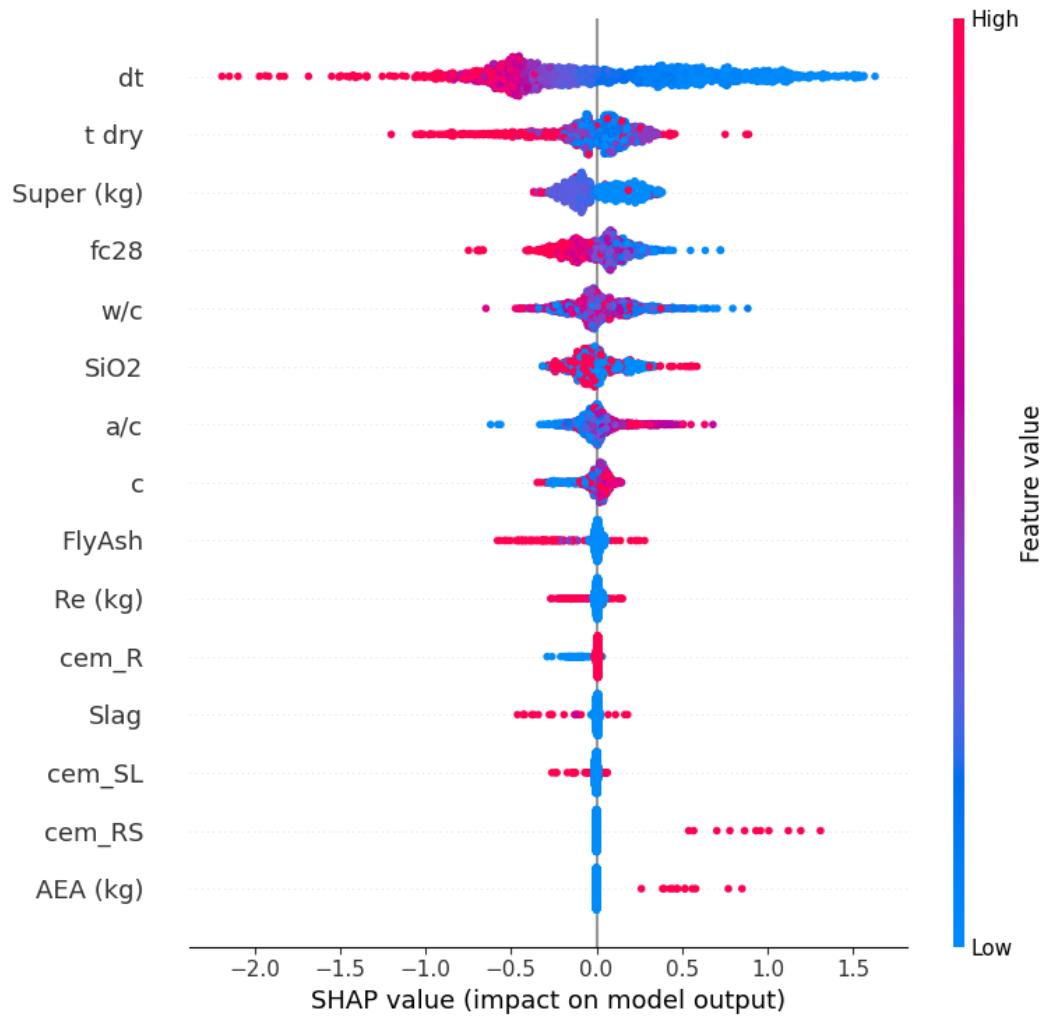


Figura 33 - Análise de importância de recursos usando a biblioteca SHAP em código Python dos dados internacionais.

Observa-se que na Figura 33 os valores elevados de *dt* tem a maior importância para prever a retração do concreto, uma vez que altos valores de *dt* (em vermelho) tem impacto negativo no valor de SHAP (eixo x) acarretando na retração. Logo quanto maior o período de análise no qual o concreto foi monitorado, maior é a retração desde o ponto de partida de referência das leituras.

## 5 Conclusões

A retração por secagem é um mecanismo altamente complexo o que torna a modelagem de seu comportamento uma tarefa difícil. Este estudo teve como objetivo apresentar o potencial do modelo da inteligência artificial para prever a retração por secagem do concreto mediante a característica da dosagem da mistura. Um banco de dados de retração por secagem experimental nacional e base de dados internacionais obtido por bibliografia foram obtidos para treinar e validar os modelos de RNAs. O modelo utilizado de *machine learning* foi construído com a biblioteca *Keras* na linguagem de programação em *Python*. Os desempenhos dos modelos foram estudados utilizando a biblioteca *Keras*. O Gráfico SHAP foi adotado para interpretar as dependências dos dados de entrada para o modelo de aprendizado desenvolvido. As seguintes conclusões foram obtidas:

- Os modelos de RNAs assim desenvolvidos são métodos viáveis para prever deformações de retração por secagem do concreto. Os modelos mostraram uma excelente capacidade de capturar as inter-relações entre as principais variáveis do conjunto;
- O modelo de aprendizado de máquina pode atingir precisão de treinamento e teste para prever a retração por secagem, atingindo os valores de 0,998 e 0,906 de  $R^2$  para os dados nacionais, respectivamente, e 0,899 e 0,841 de  $R^2$  para treinamento e teste para os dados internacionais;
- Usando as capacidades de generalização da RNA, os efeitos de vários parâmetros no desenvolvimento da retração por secagem em diferentes idades podem ser quantificados;
- Na análise dos dados nacionais observou-se que o uso do compensador de retração nas dosagens do concreto teve a magnitude na redução em valores próximos de 40% da retração por secagem do concreto comparado ao concreto sem o aditivo;

- Os modelos podem ser interpretados usando valores de SHAP. Os parâmetros mais correlacionados para RNAs dos dados nacionais foram: idade do concreto ( $dt$ ), consumo de aditivo do tipo CR, cimento CP II Z 32, relação água/cimento ( $a/c$ ), aditivo tipo RA1 e consumo de cimento ( $c$ ). Para a base dos dados internacionais foram: idade do concreto ( $dt$ ), tempo de cura ( $t_{dry}$ ), superplastificante ( $super$ ), resistência aos 28 dias ( $fc_{28}$ ) e relação água/cimento ( $a/c$ ).

O presente estudo pode abrir novos caminhos para pesquisas relacionadas ao uso de novas adições combinadas com outras em conjunto com a combinação de aditivos. Por exemplo, os resultados podem orientar a seleção de materiais constituintes do concreto para diminuir a retração por secagem de acordo com a disponibilidade de materiais da região de forma a buscar o melhor custo-benefício. O incremento de informações aos bancos de dados é incentivado para construir de forma colaborativa bancos de dados mais extensos, incluindo descrições químicas do cimento ou diferentes metodologias de medição da retração. Possíveis desenvolvimentos também podem ser acoplados aos resultados aqui relatados para obtenção de previsões de propriedades mecânicas. Esses modelos avançados podem ser de interesse futuro em relação ao desenvolvimento de materiais cimentícios sustentáveis e de alto ou ultra-desempenho.

## 6 Referências bibliográficas

1. Nehdi ML, Soliman AM. Artificial intelligence model for early-age autogenous shrinkage of concrete. *ACI Mater J.* 2012;109: 353–362. doi:10.14359/51683826
2. Abbasnia R, Shekarchi M, Ahmadi J. Evaluation of concrete drying shrinkage related to moisture loss. *ACI Mater J.* 2013;110: 269–277. doi:10.14359/51685660
3. Motta M dos S. Fluênciа e retrаção de pastas de cimento em idade jovem. Pontificia Universidade Católica do Rio de Janeiro. 2018.
4. Mazzoli A, Monosi S, Plescia ES. Evaluation of the early-age-shrinkage of Fiber Reinforced Concrete (FRC) using image analysis methods. *Constr Build Mater.* 2015;101: 596–601. doi:10.1016/j.conbuildmat.2015.10.090
5. BAKSHI M. Characterization and Modeling of Moisture Flow through hydrating Cemente-Based Materials under Early-age Drying and Shrinkage Conditions. Arizona State University. 2011.
6. NEVILLE AM. Propriedades do Concreto. 5º Edição. Bookman; 2016.
7. Lopes ANM, Silva Prof. EF, Dal Molin Prof. DCC, Filho Prof. RDT. Shrinkage-reducing admixture: Effects on durability of high-strength concrete. *ACI Mater J.* 2013;110: 365–374. doi:10.14359/51685783
8. MEHTA PK, MONTEIRO PJM. Concreto: Microestrutura, Propriedades e Materiais. 2º Edição. IBRACON; 2014.
9. Kovler K, Zhutovsky S. Overview and future trends of shrinkage research. *Mater Struct Constr.* 2006;39: 827–847. doi:10.1617/s11527-006-9114-z
10. Gregorova V, Stefkova Z, Ledererova M. Effects of expansive additive on cement composite properties. *IOP Conf Ser Mater Sci Eng.* 2018;385. doi:10.1088/1757-899X/385/1/012015
11. Wyrzykowski M, Trtik P, Münch B, Weiss J, Vontobel P, Lura P. Plastic shrinkage of mortars with shrinkage reducing admixture and lightweight aggregates studied by neutron tomography. *Cem Concr Res.* 2015;73: 238–

245. doi:10.1016/j.cemconres.2015.03.013
12. Slatnick S, Riding KA, Folliard KJ, Juenger MCG, Schindler AK. Evaluation of autogenous deformation of concrete at early ages. *ACI Mater J.* 2011;108: 21–28. doi:10.14359/51664212
  13. Wei Y, Hansen W, Biernacki JJ, Schlangen E. Unified shrinkage model for concrete from autogenous shrinkage test on paste with and without ground-granulated blast-furnace slag. *ACI Mater J.* 2011;108: 13–20. doi:10.14359/51664211
  14. Yousefieh N, Joshaghani A, Hajibandeh E, Shekarchi M. Influence of fibers on drying shrinkage in restrained concrete. *Constr Build Mater.* 2017;148: 833–845. doi:10.1016/j.conbuildmat.2017.05.093
  15. ASTM C 1608. Standard test method for chemical shrinkage of hydraulic cement paste. West Conshohocken: American Society for Testing and Materials 2007 pp. 667–670.
  16. Wyrzykowski M, Igarashi SI, Lura P, Mechtcherine V. Recommendation of RILEM TC 260-RSC: using superabsorbent polymers (SAP) to mitigate autogenous shrinkage. *Mater Struct Constr.* 2018;51: 1–7. doi:10.1617/s11527-018-1241-9
  17. ASTM C157. Standard Test Method for Length Change of Hardened Hydraulic-Cement, Mortar, and Concrete. ASTM Int West Conshohocken, PA. 1999;i: 1–7.
  18. NBR 16834. NBR 16834-2020: Concreto - Determinação da variação dimensional (retração ou expansão linear). 2020 p. 11.
  19. ASTM 1581. Standard Test Method for Determining Age at Cracking and Induced Tensile Stress Characteristics of Mortar and Concrete under Restrained Shrinkage. 2004; 1–6. Available: [www.astm.org](http://www.astm.org),
  20. Younis KH, Pilakoutas K. Assessment of post-restrained shrinkage mechanical properties of concrete. *ACI Mater J.* 2016;113: 267–276. doi:10.14359/51688699
  21. ACI 209R-92. Prediction of creep, shrinkage, and temperature effects in concrete structures. 1994 p. 47.
  22. W. Hansen and J. A. Almudaiheem. No TitleUltimate drying shrinkage of concrete - influence of major parameters. *ACI Mater J.* 1987;3: 84.
  23. ZHANG T, GAO P, LUO R, GUO Y, WEI J, YU Q. Measurement of

- chemical shrinkage of cement paste: Comparison study of ASTM C 1608 and an improved method. *Constr Build Mater.* 2013;48: 662–669.
24. Liu J, Tian Q, Wang Y, Li H, Xu W. Evaluation Method and Mitigation Strategies for Shrinkage Cracking of Modern Concrete. *Engineering.* 2021;7: 348–357. doi:10.1016/j.eng.2021.01.006
  25. Pendergrass B, Darwin D, Khajehdehi R, Feng M. Effects of internal curing, slag, and silica fume on concrete shrinkage. *ACI Mater J.* 2018;115: 585–593. doi:10.14359/51702193
  26. Villani C, Lucerò C, Bentz D, Hussey D, Jacobson DL, Weiss WJ. Analysis of drying processes in mortars with and without Shrinkage Reducing Admixtures. *Am Concr Institute, ACI Spec Publ.* 2016;2016-Janua: 49–73.
  27. Qiao C, Ni W, Weiss J. Transport due to Diffusion, Drying, and Wicking in Concrete Containing a Shrinkage-Reducing Admixture. *J Mater Civ Eng.* 2017;29: 04017146. doi:10.1061/(asce)mt.1943-5533.0001983
  28. Yoo DY, Park JJ, Kim SW, Yoon YS. Influence of ring size on the restrained shrinkage behavior of ultra high performance fiber reinforced concrete. *Mater Struct Constr.* 2014;47: 1161–1174. doi:10.1617/s11527-013-0119-0
  29. Afrougabsabet V, Biolzi L, Ozbaakkaloglu T. High-performance fiber-reinforced concrete: a review. *J Mater Sci.* 2016;51: 6517–6551. doi:10.1007/s10853-016-9917-4
  30. Rodrigues PPF. Pisos Industriais com concreto de retração compensada. 1° edição. J. J. Carol; 2019.
  31. BELLA C DI. Chloride Transport and Shrinkage of Plain and Internally Cured Concrete. Purdue University. 2012.
  32. Lu Y, Wang K, Zhu D, Meng Q, Cui L. Hydration and pore structure characteristics of concrete incorporating internal curing materials in a dry and largeeरature-difference environment. *Mater Res Express.* 2022;9. doi:10.1088/2053-1591/ac5a31
  33. Filho SJRT, Snoeck D, De Belie N. Monitoring the Early-Age Shrinkage Cracking of Concrete with Superabsorbent Polymers by Means of Optical Fiber (SOFO). *Curr Top Trends Durab Build Mater Components - Proc 15th Int Conf Durab Build Mater Components, DBMC 2020.* 2020; 1527–1534. doi:10.23967/dbmc.2020.099
  34. Boshoff W, Mechtherine V, Snoeck D, Schröfl C, De Belie N, Ribeiro AB,

- et al. The effect of superabsorbent polymers on the mitigation of plastic shrinkage cracking of conventional concrete, results of an inter-laboratory test by RILEM TC 260-RSC. *Mater Struct Constr.* 2020;53. doi:10.1617/s11527-020-01516-6
35. Mohtasham M, Saradar A, Rahmati K, Hosein S, Mousavinejad G, Bristow J, et al. Predictive models for concrete properties using machine learning and deep learning approaches : A review. *J Build Eng.* 2023;63: 105444. doi:10.1016/j.jobe.2022.105444
  36. Haenlein M, Kaplan A. A brief history of artificial intelligence: On the past, present, and future of artificial intelligence. *Calif Manage Rev.* 2019;61: 5–14. doi:10.1177/0008125619864925
  37. Faria ÉF. PREDIÇÃO DA EXOTERMIA DA REAÇÃO DE HIDRATAÇÃO DO CONCRETO ATRAVÉS DE MODELO TERMOQUÍMICO E MODELO DE DADOS. UNIVERSIDADE FEDERAL DO RIO DE JANEIRO. 2004.
  38. Taffese WZ, Sistonen E. Machine learning for durability and service-life assessment of reinforced concrete structures: Recent advances and future directions. *Autom Constr.* 2017;77: 1–14. doi:10.1016/j.autcon.2017.01.016
  39. Ababneh A, Alhassan M, Abu-haifa M. Predicting the contribution of recycled aggregate concrete to the shear capacity of beams without transverse reinforcement using artificial neural networks. *Case Stud Constr Mater.* 2020;13: e00414. doi:10.1016/j.cscm.2020.e00414
  40. Teymori A, Tapeh G. Artificial Intelligence , Machine Learning , and Deep Learning in Structural Engineering : A Scientometrics Review of Trends and Best Practices. *Archives of Computational Methods in Engineering.* Springer Netherlands; 2023. doi:10.1007/s11831-022-09793-w
  41. Hwang H, Baek J, Kim J, Kim C. Prediction of bond performance of tension lap splices using artificial neural networks. *Eng Struct.* 2019;198: 109535. doi:10.1016/j.engstruct.2019.109535
  42. Hwang HJ, Baek JW, Kim JY, Kim CS. Prediction of bond performance of tension lap splices using artificial neural networks. *Eng Struct.* 2019;198: 109535. doi:10.1016/j.engstruct.2019.109535
  43. ACI 209.2R-08. Guide for modeling and calculating shrinkage and creep in hardened concrete. 2008 p. 44.

44. Bazant ZP, Baweja S. Creep and shrinkage prediction model for analysis and design of concrete structures: Model 83. Am Concr Institute, ACI Spec Publ. 2000;SP-194: 1–83.
45. Bal L, Buyle-bodin F. Artificial neural network for predicting drying shrinkage of concrete. Constr Build Mater. 2013;38: 248–254. doi:10.1016/j.conbuildmat.2012.08.043
46. Congro M, Monteiro VM de A, Brandão ALT, Santos BF do., Roehl D, Silva F de A. Prediction of the residual flexural strength of fiber reinforced concrete using artificial neural networks. Constr Build Mater. 2021;303. doi:10.1016/j.conbuildmat.2021.124502
47. Bažant ZP. Professor Zdeněk P. Bažant, Ph.D., S.E. 2019 [cited 15 May 2022]. Available: <http://www.civil.northwestern.edu/people/bazant/downloads.html>
48. NBR 11768-1. Aditivos para concreto de cimento Portland. 2019 pp. 2–5.
49. Parente AP, Pereira M V, Teixeira MC, Brand ALT. Artificial intelligence modeling of ultrasonic fatigue test to predict the temperature increase. 2022;163. doi:10.1016/j.ijfatigue.2022.106999
50. Wang H, Zhao K, Zhang Y, Zhang X. Prediction of Compressive Strength of Concrete Using the Spearman and PCA-Based BP Neural Network. Wirel Commun Mob Comput. 2022;2022. doi:10.1155/2022/7248561
51. Hilloulin B, Tran VQ. Using machine learning techniques for predicting autogenous shrinkage of concrete incorporating superabsorbent polymers and supplementary cementitious materials. J Build Eng. 2022;49: 104086. doi:10.1016/j.jobe.2022.104086

## ANEXO I – Estrutura da Rede Neural em Python no Jupyter Notebook

### Importação das bibliotecas

Bibliotecas específicas para aprendizado de máquinas

```
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import shap

import category_encoders as ce
from category_encoders.one_hot import OrdinalEncoder

import optuna
import sklearn

from sklearn import preprocessing
from sklearn.preprocessing import minmax_scale
from sklearn.preprocessing import scale
from sklearn.preprocessing import StandardScaler
from sklearn.pipeline import make_pipeline
from sklearn.model_selection import train_test_split
from sklearn.metrics import r2_score
from sklearn.metrics import mean_absolute_error
from sklearn.metrics import mean_squared_error

from tensorflow import keras
from keras.wrappers.scikit_learn import KerasRegressor
from keras.callbacks import EarlyStopping, ReduceLROnPlateau

import plotly

import seaborn as sns

import tensorflow as tf

import keras
from keras.models import Sequential
from keras.layers import Dense, Dropout
from keras.utils import to_categorical
```

### Funções Auxiliares

Correlaçao

```
def correlacao(df):
    plt.subplots(figsize=(22, 12))
    sns.heatmap(df.corr(method='spearman'), annot=True, cmap = 'YlGnBu', line
```

```
widths=.5)
plt.yticks(va="center")
plt.title('Spearman')
plt.show()
```

## Cria\_X\_Y

```
def cria_X_Y(data,saida):
    ent = data.columns.to_list()
    for element in saida:
        if element in ent:
            ent.remove(element)
    Y = data.drop(ent,axis=1)
    X = data.drop(saida,axis=1)
    return X,Y
```

## Separação

```
def separacao2(X,Y,ts_teste):
    X_train, X_test, Y_train, Y_test = sklearn.model_selection.train_test_split(X,
Y, test_size = ts_teste)
    return X_train, X_test,Y_train, Y_test
```

## Normaliza

```
def normaliza2(xtrain, xtest, ytrain, ytest):
    preprocessParams = preprocessing.StandardScaler().fit(xtrain)

    X_train_norm = preprocessParams.transform(xtrain)
    X_test_norm = preprocessParams.transform(xtest)

    preprocessParams = preprocessing.StandardScaler().fit(ytrain)
    Y_train_norm = preprocessParams.transform(ytrain)
    Y_test_norm = preprocessParams.transform(ytest)
    return X_train_norm, X_test_norm,Y_train_norm,Y_test_norm
```

## Create\_model

```
def create_model_reg():
    model = keras.models.Sequential()

    model.add(keras.layers.Dense(study.best_params['mlp_hidden_size'], \
                                input_shape = (X_train.shape[1],), activation=study.best_params['mlp_activation']))
```

```

    model.add(keras.layers.Dense(Y_train.shape[1], activation=study.best_params['mlp_activation_end']))
    model.compile(loss='mean_squared_error', optimizer=study.best_params['mlp_optimizer'],
                  metrics=['mean_squared_error'])
    return model

```

## Desempenho da Rede

```

def analise_desempenho(Y_train, Y_train_pred, Y_val, Y_val_pred, Y_test, Y_test_pred, tipo, multi, mod):

    MAEtrain = sklearn.metrics.mean_absolute_error(Y_train, Y_train_pred) # retirado
    r2train = sklearn.metrics.r2_score(Y_train, Y_train_pred) # retirado
    MSEtrain = sklearn.metrics.mean_squared_error(Y_train, Y_train_pred)
    RMSEtrain = np.sqrt(MSEtrain)
    nn = len(Y_train)
    pp = X_train.shape[1]
    r2trainad = 1 - (1 - r2train) * (nn - 1) / (nn - pp - 1)

    MAEval = sklearn.metrics.mean_absolute_error(Y_val, Y_val_pred)
    r2val = sklearn.metrics.r2_score(Y_val, Y_val_pred)
    MSEval = sklearn.metrics.mean_squared_error(Y_val, Y_val_pred)
    RMSEval = np.sqrt(MSEval)
    nn = len(Y_val)
    pp = X_val.shape[1]
    r2valad = 1 - (1 - r2val) * (nn - 1) / (nn - pp - 1)

    MAEtest = sklearn.metrics.mean_absolute_error(Y_test, Y_test_pred)
    r2test = sklearn.metrics.r2_score(Y_test, Y_test_pred)
    MSEtest = sklearn.metrics.mean_squared_error(Y_test, Y_test_pred)
    RMSEtest = np.sqrt(MSEtest)
    nn = len(Y_test)
    pp = X_test.shape[1]
    r2testad = 1 - (1 - r2test) * (nn - 1) / (nn - pp - 1)

    saida = pd.DataFrame({'MAE': [MAEtrain, MAEval, MAEtest], 'R2': [r2train, r2val, r2test],
                          'R2_adj': [r2trainad, r2valad, r2testad],
                          'MSE': [MSEtrain, MSEval, MSEtest],
                          'RMSE': [RMSEtrain, RMSEval, RMSEtest]}, index=['Train', 'Validation', 'Test'])

    return saida

```

R2

```
def R2(y_true, y_pred):
    from keras import backend as K
    SS_res = K.sum(K.square( y_true-y_pred ))
    SS_tot = K.sum(K.square( y_true - K.mean(y_true) ) )
    return ( 1 - SS_res/(SS_tot + K.epsilon()) )
```

### Plot\_history

```
def plot_history(history):
    hist = pd.DataFrame(history.history)
    hist['epoch'] = history.epoch

    plt.figure()
    plt.xlabel('Epoch')
    plt.ylabel('Mean Abs Error [MPG]')
    plt.plot(hist['epoch'], hist['mae'],
             label='Train Error')
    plt.plot(hist['epoch'], hist['val_mae'],
             label = 'Val Error')

    plt.legend()

    plt.figure()
    plt.xlabel('Epoch')
    plt.ylabel('Mean Square Error [$MPG^2$]')
    plt.plot(hist['epoch'], hist['mse'],
             label='Train Error')
    plt.plot(hist['epoch'], hist['val_mse'],
             label = 'Val Error')

    plt.legend()
    plt.show()
```

### Evaluation

```
def metrics(y_pred, y_true, n_features):
    mse = mean_squared_error(y_true, y_pred)
    mae = mean_absolute_error(y_true, y_pred)
    rmse = np.sqrt(mse)
    r2 = r2_score(y_true, y_pred)
    adj_r2 = 1 - (1 - r2) * (len(y_true) - 1) / (len(y_true) - n_features - 1)

    y_true_mape = np.where(y_true == 0, 1e+20, y_true)
    mape = np.mean(np.abs((y_true - y_pred) / y_true_mape)) * 100

    return mse, mae, rmse, mape, r2, adj_r2
```

## Upload e Tratamento da Base de Dados Nacionais

```
df = pd.read_excel('Data_base.xlsx')
df.head()
```

Remoção de variáveis claramente desnecessárias

```
df.columns
```

```
df_1 = df.drop(columns = ['ID','File (data reference)',  

'manufacturer','Ref','Author (laboratory)','agg_description','classification agg',  

'specified agg_fine','City','concrete plant','constructions','Year','timescale  

(log/linear/table)','type (total/auto/drying)','fck (Mpa)','fctm,k (Mpa)','fc28  

(Mpa)','fct0 (Mpa)','E28 (Mpa)','Geometry (mm)','r (mm)','b (mm)','h  

(mm)','V/S (mm)','H0 (%)','t dry (days)','Tcur (°C)','T (°C)','Heat (°C)','RH_test  

(%)','Note'])]
```

```
df_1.columns
```

Renomear para melhores práticas de programação:

```
renomear = { 'shrinkage (%)':'shrinkage_(%)',}
df_1 = df_1.rename(columns = renomear)
```

```
df_1.dtypes
```

```
df_1.info()
```

Identificação e eliminação de dados Nulos

```
df_1.isna().any()
```

```
df_1.isna().sum()
```

```
df_1[df_1['shrinkage_(%)'].isnull()]
```

```
df_1[df_1['Region'].isnull()]
```

```
df_1['Region'].fillna('Desconhecida', inplace = True)
```

```
df_1[df_1['Region'].isnull()]
```

```
df_1
```

```
df_2 = df_1.dropna().reset_index(drop=True)
```

```
df_2.isna().sum()
```

```
df_2
```

Plotando e analisando melhor os dados

```
colunas = ['Region', 'w/c', 'a/c', 'mortar (%)', 'aggregate (artificial/natural)', 'agg (kg/m3)', 'c (kg/m3)', 'multifunctional', 'mid ranger', 'super', 'compensator', 'microfiber', 'macrofiber P P', 'macrofiber steel', 'cemente', 'dt (days)', 'shrinkage (%)']

colunas_numericas = ['w/c', 'a/c', 'mortar (%)', 'aggregate (artificial/natural)', 'agg (kg/m3)', 'c (kg/m3)', 'multifunctional', 'mid ranger', 'super', 'compensator', 'microfiber', 'macrofiber P P', 'macrofiber steel', 'dt (days)']

bar_labels = colunas_numericas
```

Retração por tipo de cimento:

```
todas_regioes = df_2.groupby('cemente')

for região, grupo in todas_regioes:
    plt.hist(grupo['shrinkage (%)'], alpha=0.5, label=região)
    plt.legend()
    plt.show()
    plt.rcParams['figure.figsize'] = [3.2, 2.2]
```

Relação direta entre os dados de entrada e retração:

```
df_2.columns
```

```
novos_nomes = {
    'Region':'Região',
    'w/c':'a/c',
    'a/c':'a/c',
    'multifunctional':'Polifuncional',
    'compensator':'compensador',
    'cemente':'Cimento',
    'dt (days)':'dt (dias)',
    'shrinkage (%)':'Retração (%)'}
```

```

def plotscatter(coluna1, coluna2, dado):
    sns.scatterplot(x=coluna1, y=coluna2, data=dado)

# Create a dictionary mapping column names to new labels
count = {coluna: idx for idx, coluna in enumerate(colunas, start=1)}

for i in colunas:
    plotscatter('shrinkage_(%)', i, df_2)
    plt.ylabel(novos_nomes.get(i, i)) # Use the new label for y-axis
    plt.xlabel("Retração (%)")
    plt.tight_layout()
    plt.savefig(f'plot_{count.get(i, i)}.jpg') # Use the new label for filename
    plt.show()
    print("\n"*2)

```

Gráficos com e sem adição de compensador no dia 1, 2, 7, 14, 28 e 56:

```

dias = [1, 2, 7, 14, 28, 56]
cement_colormap = plt.cm.get_cmap('tab10')

for day in dias:
    filtered_df = df_2[df_2['dt (days)'] == day]

    no_compensator_df = filtered_df[filtered_df['compensator'] == 0]
    with_compensator_df = filtered_df[filtered_df['compensator'] != 0]

    fig, ax = plt.subplots(figsize=(2.8, 1.8))

    cement_types = filtered_df['cemente'].unique()

    ax.scatter(no_compensator_df['shrinkage_(%)'], no_compensator_df['w/c'], c=np.array([cement_colormap(0)]), label='Sem compensador')
    ax.scatter(with_compensator_df['shrinkage_(%)'], with_compensator_df['w/c'], c=np.array([cement_colormap(1)]), label='Com compensador')

    ax.set_xlabel('Retração (%)')
    ax.set_ylabel('a/c')
    ax.set_title(f'Dia: {day}')

    ax.legend()
    plt.show()

```

Compilando todos os dados ao longo do tempo com e sem compensador:

```

cement_colormap = plt.cm.get_cmap('tab10')

no_compensator_df = df_2[df_2['compensator'] == 0]
with_compensator_df = df_2[df_2['compensator'] != 0]

```

```

fig, ax = plt.subplots(figsize=(10, 6))

ax.plot(no_compensator_df['dt (days)'], no_compensator_df['shrinkage_(%)']*10000, 'o', c=cement_colormap(0), label='Sem Compensador')
ax.plot(with_compensator_df['dt (days)'], with_compensator_df['shrinkage_(%)']*10000, 'o', c=cement_colormap(1), label='Com Compensador')

mean_no_compensator = no_compensator_df.groupby('dt (days)')['shrinkage_(%)'].mean()*10000
mean_with_compensator = with_compensator_df.groupby('dt (days)')['shrinkage_(%)'].mean()*10000

fixed_std = 0.008*10000

ax.fill_between(mean_no_compensator.index, mean_no_compensator - fixed_std, mean_no_compensator + fixed_std, color='blue', alpha=0.3)
ax.fill_between(mean_with_compensator.index, mean_with_compensator - fixed_std, mean_with_compensator + fixed_std, color='orange', alpha=0.3)

ax.axhline(y=0, color='black', linestyle='--')
ax.axvline(x=7, color='black', linestyle='--')

ax.set_xlabel('dt (dias)')
ax.set_ylabel('Retração ( $\mu\text{m}/\text{m}$ )')

ax.legend()
plt.show()

```

Conversão das colunas ‘Region’ e ‘Cemente’ em dados categóricos

```

import category_encoders as ce
from category_encoders.one_hot import OneHotEncoder

```

```
df_3 = df_2.drop(columns = ['agg (kg/m3)'])
```

```
df_3.head()
```

```
df_3['Region'].unique()
```

```
df_3['cemente'].unique()
```

```

ohe = OneHotEncoder()
ohe.fit_transform(df_3[['Region', 'cemente']])

```

```

import pandas as pd
from sklearn.preprocessing import OneHotEncoder

```

```

ohe = OneHotEncoder(handle_unknown='ignore')
feature_array = ohe.fit_transform(df_3[["Region", "cemente"]])

column_names = ohe.get_feature_names_out(input_features=["Region",
"cemente"])

one_hot_df = pd.DataFrame(feature_array.toarray(), columns=column_names)

df_4 = df_3.drop(columns=['cemente', 'Region'])
df_5 = df_4.join(one_hot_df)

df_5

```

```

feature_array = ohe.fit_transform(df_3[["Region", "cemente"]])

column_names = ohe.get_feature_names_out(input_features=["Region", "ceme
nte"])

one_hot_df = pd.DataFrame(feature_array.toarray(), columns=column_names)

df_4 = df_3.drop(columns=['cemente', 'Region'])

df_5 = df_4.join(one_hot_df)

last_column = df_5.pop('shrinkage_(%)')
df_5.insert(len(df_5.columns), 'shrinkage_(%)', last_column)

df_5

```

## Rede Neural com Keras Dados Nacionais

```

dados = df_5[['w/c', 'c (kg/m3)', 'multifunctional', 'mid ranger', 'compensator',
'dt (days)', 'cemente_CP II E', 'cemente_CP II E 40', 'cemente_CP II E 40
RS', 'cemente_CP II F 32 RS',
'cemente_CP II F 40', 'cemente_CP II Z 32', 'cemente_CP III 40 RS',
'cemente_CP V ARI', 'cemente_CP V ARI RS', 'shrinkage_(%)']]

dados.loc[0:3,:]

```

```

def normalize(x, y):
    scaler_x = preprocessing.StandardScaler().fit(x)
    scaler_y = preprocessing.StandardScaler().fit(y)
    x_norm = scaler_x.transform(x)
    y_norm = scaler_y.transform(y)
    params = {'scaler_x': scaler_x, 'scaler_y': scaler_y}
    return x_norm, y_norm, params

```

```
X,Y = cria_X_Y(dados,['shrinkage_(%)'])
```

```
X_norm, Y_norm, params = normalize(X, Y)
X_train, X_test, Y_train, Y_test = separacao2(X_norm, Y_norm, 0.3)

model_keras_diogo = keras.models.Sequential()
model_keras_diogo.add(Dense(2000, input_dim=X_train.shape[1],
activation='relu'))
model_keras_diogo.add(Dense(500, activation='relu'))
model_keras_diogo.add(Dense(2000, activation='relu'))
model_keras_diogo.add(Dense(Y_train.shape[1], activation='linear'))
model_keras_diogo.compile(loss='mean_squared_error', optimizer='adam',
metrics=['mean_squared_error'])
```

```
class ProgressCallback(keras.callbacks.Callback):

    def __init__(self, validation_data):
        self.X_val, self.y_val = validation_data

    def on_epoch_end(self, epoch, logs={}):
        y_pred = self.model.predict(self.X_val, verbose=0)
        r2 = round(r2_score(self.y_val, y_pred)*100, 2)

        if epoch % 20 == 0:
            print("Epoch {} - loss: {:.3f} - mean_squared_error: {:.3f} - val_loss: {:.3f} - val_mean_squared_error: {:.3f} - R2: {:.1f}"
                  .format(epoch, logs["loss"], logs["mean_squared_error"],
                          logs["val_loss"], logs["val_mean_squared_error"], r2))
```

```
progress_callback = ProgressCallback(validation_data=(X_test, Y_test))
early_stop = EarlyStopping(monitor='val_loss', patience=50,
                           restore_best_weights = True)
reduce_lr = ReduceLROnPlateau(monitor='val_loss', factor=0.8, patience=10,
                             n_lr=1e-10)

history = model_keras_diogo.fit(X_train, Y_train, epochs=1000, batch_size=3,
                                 validation_split = 0.3, verbose=0,
                                 callbacks=[progress_callback, early_stop, reduce_lr])
```

```
plt.plot(history.history['loss'], label='Training Loss (MSE)')
plt.plot(history.history['val_loss'], label='Validation Loss (MSE)')
plt.title('Model Loss')
plt.ylabel('Loss')
plt.xlabel('Epoch')
plt.legend()
plt.show()
```

```
y_pred_train = model_keras_diogo.predict(X_train, verbose = 0)
mse, mae, rmse, mape, r2, adj_r2 = metrics(y_pred_train, Y_train,
df_5.shape[1])
print("## Train ##")
print(f'Mean Squared Error (MSE): {mse:.2e}')
```

```

print(fMean Absolute Error (MAE):           {mae:.2e}'')
print(fRoot Mean Squared Error (RMSE):     {rmse:.2e}'')
print(fMean Absolute Percentage Error (MAPE): {mape:.2f} %')
print(fR-squared (R2):                     {r2*100:.1f} %')
print(fAdjusted R-squared (R2 adj):       {adj_r2*100:.1f} %')

fig, ax = plt.subplots()
ax.scatter(Y_train, y_pred_train, edgecolors=(0, 0, 0))
ax.plot([Y_train.ravel().min(), Y_train.ravel().max()], [Y_train.ravel().min(), Y_train.ravel().max()], 'k--', lw=4)
ax.set_xlabel('Calculado')
ax.set_ylabel('Predito')
plt.title(fKeras Regressor\nMSE={mse:.4f}, R2={r2*100:.1f} %')
plt.show()

```

```

y_pred_test = model_keras_diogo.predict(X_test, verbose = 0)
mse, mae, rmse, mape, r2, adj_r2 = metrics(y_pred_test, Y_test, df_5.shape[1])
print("## Test ##")
print(fMean Squared Error (MSE):           {mse:.2e}'')
print(fMean Absolute Error (MAE):           {mae:.2e}'')
print(fRoot Mean Squared Error (RMSE):     {rmse:.2e}'')
print(fMean Absolute Percentage Error (MAPE): {mape:.2f} %')
print(fR-squared (R2):                     {r2*100:.1f} %')
print(fAdjusted R-squared (R2 adj):       {adj_r2*100:.1f} %')

fig, ax = plt.subplots()
ax.scatter(Y_test, y_pred_test, edgecolors=(0, 0, 0))
ax.plot([Y_train.ravel().min(), Y_train.ravel().max()], [Y_train.ravel().min(), Y_train.ravel().max()], 'k--', lw=4)
ax.set_xlabel('Calculado')
ax.set_ylabel('Predito')
plt.title(fRandom Forest Regressor\nMSE={mse:.4f}, R2={r2*100:.1f} %')
plt.show()

```

```

errors = Y_test - y_pred_test
errors = np.round(errors, 1)
unique_elements, counts = np.unique(errors, return_counts=True)

fig, ax = plt.subplots(figsize=(15, 5))
ax.bar(unique_elements, counts, edgecolor='black', width=0.1)
ax.axvline(x=0, color='red')
ax.set_title("Erro da retração (%)")
ax.set_xlabel("Retração (%)")
ax.set_ylabel("Frequência")
plt.show()

```

```

feature_names=['w/c', 'c (kg/m3)', 'multifunctional', 'mid ranger', 'compensator',
               'dt (days)', 'cemente_CP II E', 'cemente_CP II E 40', 'cemente_CP II E 40
RS', 'cemente_CP II F 32 RS',

```

```
'cemente_CP II F 40', 'cemente_CP II Z 32', 'cemente_CP III 40 RS',
'cemente_CP V ARI', 'cemente_CP V ARI RS']
```

```
translations = {
    "dt (days)": "dt (dias)",
    "compensator": "compensador",
    "multifuncional": "polifuncional",
    "w/c": "a/c",
    "c (kg/m³)": "c (kg/m³)",
    "cemente_CP II E 40": "cimento CP II E 40",
    "mid ranger": "mid ranger",
    "cemente_CP II E 40 RS": "cimento CP II E 40 R",
    "cemente_CP V ARI RS": "cimento CP V ARI RS",
    "cemente_CP II Z 32": "cimento CP II Z 32",
    "cemente_CP II F 40": "cimento CP II F 40",
    "cemente_CP II F 32 RS": "cimento CP II F 32 RS",
    "cemente_CP II E": "cimento CP II E",
    "cemente_CP III 40 RS": "cimento CP III 40 RS",
    "cemente_CP V ARI": "cimento CP V ARI",
}
```

```
translated_feature_names = [translations.get(name, name) for name in
feature_names]
```

```
background_data = X_train[np.random.choice(X_train.shape[0], 100,
replace=False)]
explainer = shap.Explainer(model_keras_diogo, background_data)
shap_values = explainer(X_test)
shap.summary_plot(shap_values, X_test,
feature_names=translated_feature_names)
```

```
shap.summary_plot(shap_values, X_test, feature_names=translated_feature_names, plot_type='bar')
```

## Upload e Tratamento da Base de Dados Internacionais

```
original_data_USA = pd.read_excel('dataframe_agregado.xlsx')
```

```
pd.set_option('display.max_columns', None)
```

```
original_data_USA
```

```
original_data_USA.columns
```

Remoção de colunas desnecessárias

```
data_USA = original_data_USA.drop(columns = ['ID', 'File', 'Author', 'Ref',
'Shape', 'Unknown', 'Chem', 'Uncertain', 'Chem', 'Note',
'Unnamed: 52', 'Unnamed: 53'])
```

```
data_USA.columns
```

```
data_USA
```

```
list_non_numeric_columns = ['Region', 'Region', 'timescale', 'type', 'cem', 'cem_prov', 'agg', 'agg_description', 'agg_course', 'Geometry']

for column in list_non_numeric_columns:
    data_USA[column] = data_USA[column].str.replace(' ', '_')
```

```
word_counts_dict = {}
```

```
for col in list_non_numeric_columns:
    word_counts = data_USA[col].str.split(r'\s|-|/', expand=True).stack().value_counts()
    word_counts_dict[col] = word_counts

pd.set_option('display.max_rows', None)
pd.set_option('display.max_columns', None)

for col in word_counts_dict:
    print("#"*50)
    print(f'Contagem de palavras para a coluna {col}：“')
    print("#"*50)
    print(word_counts_dict[col])
    print("\n"*2)

pd.reset_option('display.max_rows')
pd.reset_option('display.max_columns')
```

```
missing_values_count = data_USA.isna().sum()
missing_values_count_inf = (data_USA == -np.inf).sum() + (data_USA == np.inf).sum()

print("#"*30)
print("Number of missing values per column:")
print("#"*30)
print(missing_values_count)
print("\n"*2)

pct_missing = (missing_values_count / len(data_USA)) * 100
pct_missing = round(pct_missing, 1)

print("#"*30)
```

```

print("Percentage of missing values in each column:")
print("#"*30)
print(pct_missing)
print("\n"*2)

print("#"*50)
print("\n"*2)

print("#"*30)
print("Number of inf values per column:")
print("#"*30)
print(missing_values_count_inf)
print("\n"*2)

pct_missing_inf = (missing_values_count_inf / len(data_USA)) * 100
pct_missing_inf = round(pct_missing_inf, 1)

print("#"*30)
print("Percentage of inf values in each column:")
print("#"*30)
print(pct_missing_inf)
print("\n"*2)

```

```

missing_values_total = data_USA.isna().sum() + (data_USA == -np.inf).sum()
+ (data_USA == np.inf).sum()

pct_missing_total = (missing_values_total / len(data_USA)) * 100
pct_missing_total = round(pct_missing_total, 1)

print("#"*30)
print("Percentage of missing values in each column:")
print("#"*30)
print(pct_missing)
print("\n"*2)

data_USA.columns

```

```

data_USA_2 = data_USA
data_USA_2.columns

```

```

threshold = 25
drop_columns = pct_missing_total[pct_missing > threshold].index
data_USA_2.drop(drop_columns, axis=1, inplace=True)
data_USA_2

```

```

data_USA_2.columns

```

Remover as linhas com -inf. inf, NaN e None:

```
data_USA_2
```

```
data_USA_3 = data_USA_2.replace([-np.inf, np.inf], np.nan)
data_USA_3.dropna(inplace=True)
data_USA_3 = data_USA_3.reset_index(drop=True)
data_USA_3
```

Remoção de colunas duplicadas

```
duplicated_rows = data_USA_3[data_USA_3.duplicated()]
duplicated_rows
```

```
data_USA_3.drop_duplicates(inplace=True)
data_USA_3
```

Verificação:

```
duplicated_rows = data_USA_3[data_USA_3.duplicated()]
duplicated_rows
```

Conversão de colunas em dados categóricos

```
data_USA_3.head(1)
```

```
data_USA_3.dtypes
```

```
data_USA_3
```

```
data_USA_4 = data_USA_3.reset_index(drop=True)
data_USA_4
```

```
data_USA_4.columns
```

```
list_numeric_columns = ['dt', 'shrinkage strain', 'Year', 'w/c', 'a/c', 'c', 'SiO2',
'FlyAsh', 'Slag', 'Filler/c', 'VA(kg)', 'VA(l)',
'Accel (kg)', 'Accel (l)', 'WR (kg)', 'WR (l)', 'Re (kg)', 'Re (l)',
'Super (kg)', 'Super (l)', 'AEA (kg)', 'AEA (l)', 'Else', 'fc28',
'r', 'h', 'V/S', 'H0', 't dry', 'T', 'RH_test']
```

```
rows_to_drop = []
```

```
for col in list_numeric_columns:
    col_copy = data_USA_4[col].copy()
    for idx, val in enumerate(col_copy):
```

```

try:
    float_val = float(val)
    col_copy[idx] = float_val
except ValueError:
    rows_to_drop.append(idx)
data_USA_4[col] = col_copy

```

```

data_USA_4 = data_USA_4.drop(rows_to_drop)
data_USA_4[list_numeric_columns] = data_USA_4[list_numeric_columns].astype(float)
data_USA_4.dtypes

```

```
data_USA_4
```

```
list_non_numeric_columns = ['Region','type','cem','Geometry']
```

```

data_USA_4[list_non_numeric_columns] = data_USA_4[list_non_numeric_columns].astype('category')

```

```
data_USA_4.dtypes
```

```
data_USA_4
```

Palavras aparecem nas colunas categóricas:

```

data_USA_4['Region'] = data_USA_4['Region'].str.replace(' ', '_')
data_USA_4['type'] = data_USA_4['type'].str.replace(' ', '_')
data_USA_4['cem'] = data_USA_4['cem'].str.replace(' ', '_')
data_USA_4['Geometry'] = data_USA_4['Geometry'].str.replace(' ', '_')

```

```
data_USA_4
```

```
word_counts_dict = {}
```

```

for col in list_non_numeric_columns:
    word_counts = data_USA_4[col].str.split(r'\s|-|/', expand=True).stack().value
    word_counts()
    word_counts_dict[col] = word_counts

```

```

pd.set_option('display.max_rows', None)
pd.set_option('display.max_columns', None)

```

```

for col in word_counts_dict:
    print("#"*30)

```

```

print(f'Word counts for column '{col}':')
print("#"*30)
print(word_counts_dict[col])
print("\n"*2)

pd.reset_option('display.max_rows')

```

Seleção de dados na base de dados

Remover dados anteriores ao ano de 2000:

```

data_USA_4 = data_USA_4[data_USA_4['Year'] >= 2000]
data_USA_4 = data_USA_4.reset_index(drop=True)
data_USA_4

```

Filtrando os ensaios feito em prismas:

```

data_USA_5 = data_USA_4[data_USA_4['Geometry'].str.startswith("P")]
data_USA_5

```

```

word_counts_dict = {}

for col in list_non_numeric_columns:
    word_counts = data_USA_5[col].str.split(r'\s|-|/', expand=True).stack().value
    _counts()
    word_counts_dict[col] = word_counts

pd.set_option('display.max_rows', None)
pd.set_option('display.max_columns', None)

for col in word_counts_dict:
    print("#"*30)
    print(f'Word counts for column '{col}':')
    print("#"*30)
    print(word_counts_dict[col])
    print("\n"*2)

pd.reset_option('display.max_rows')
pd.reset_option('display.max_columns')

```

Colocar a retração (shrinkage) em porcentagem:

```

data_USA_5.columns

```

```

data_USA_5.loc[:, 'shrinkage_(%)'] = data_USA_5['shrinkage strain'] / 10000
data_USA_5.drop('shrinkage strain', axis=1, inplace=True)

```

```
data_USA_5
```

Salvando para excel:

```
data_USA_5.to_excel('dados_internacionais_filtragem.xlsx', index=False)
```

```
data_USA_5['shrinkage_(%)'].describe()
```

```
pd.set_option('display.max_rows', None)
print(data_USA_5['shrinkage_(%)'].round(2).value_counts())
```

```
pd.set_option('display.max_columns', None)
```

```
data_USA_6 = data_USA_5.drop(['Geometry','type'], axis=1)
data_USA_6
```

```
list_non_numeric_columns = ['Region','cem']
```

```
word_counts_dict = {}

for col in list_non_numeric_columns:
    word_counts = data_USA_6[col].str.split(r'\s|-|/', expand=True).stack().value_counts()
    word_counts_dict[col] = word_counts

pd.set_option('display.max_rows', None)
pd.set_option('display.max_columns', None)

for col in word_counts_dict:
    print("#"*30)
    print(f'Word counts for column {col}::')
    print("#"*30)
    print(word_counts_dict[col])
    print("\n"*2)

pd.reset_option('display.max_rows')
pd.reset_option('display.max_columns')
```

```
value_counts = data_USA_6['Region'].value_counts()
```

```
regions_to_change = value_counts[value_counts < 500].index
```

```
regions_to_change
```

```
replacement_dict = {region: 'Other' for region in regions_to_change}
```

```
data_USA_6['Region'] = data_USA_6['Region'].replace(replacement_dict)
```

```
word_counts_dict = {}
```

```
for col in list_non_numeric_columns:
```

```
    word_counts = data_USA_6[col].str.split(r'\s|-|/', expand=True).stack().value
    _counts()
    word_counts_dict[col] = word_counts
```

```
pd.set_option('display.max_rows', None)
```

```
pd.set_option('display.max_columns', None)
```

```
for col in word_counts_dict:
```

```
    print("#"*30)
```

```
    print(f'Word counts for column {col}:'")
```

```
    print("#"*30)
```

```
    print(word_counts_dict[col])
```

```
    print("\n"*2)
```

```
pd.reset_option('display.max_rows')
```

```
pd.reset_option('display.max_columns')
```

```
region_dummies = pd.get_dummies(data_USA_6['Region'], prefix='Region')
cem_dummies = pd.get_dummies(data_USA_6['cem'], prefix='cem')
```

```
data_USA_7 = pd.concat([data_USA_6, region_dummies, cem_dummies], axis=1)
```

```
data_USA_7 = data_USA_7.drop(['Region', 'cem'], axis=1)
```

```
pd.set_option('display.max_columns', None)
```

```
data_USA_7 = data_USA_7.reset_index(drop=True)
```

```
data_USA_7
```

```
data_USA_7.describe()
```

Retirando duplicidade em valores que estão (kg) e (l):

```
data_USA_7.columns
```

```
data_USA_8 = data_USA_7.drop(columns = ['Year', 'Accel (l)', 'Re (l)', 'VA(l)', 'WR (l)', 'Super (l)', 'AEA (l)', 'Else', 'r', 'h', 'V/S', 'H0', 'T', 'RH_test', 'Region_Ch'])
```

```
ina', 'Region_Israel', 'Region_JAP',
'Region_Other', 'Region_UK',])
```

```
data_USA_8.describe()
```

Retirando colunas sem informações:

```
data_USA_9 = data_USA_8.drop(columns = ['Accel (kg)', 'VA(kg)', 'WR (kg)',
'Filler/c'])
```

```
data_USA_9.describe()
```

### Rede Neural com Keras Dados Internacionais

```
X,Y = cria_X_Y(data_USA_9,['shrinkage_(%)'])
X_norm, Y_norm, params = normalize(X, Y)
X_train, X_test, Y_train, Y_test = separacao2(X_norm, Y_norm, 0.5)
```

```
model = keras.models.Sequential()
model.add(Dense(1000, input_dim=X_train.shape[1], activation='relu'))
model.add(Dense(500, activation='relu'))
model.add(Dense(1000, activation='relu'))
model.add(Dense(Y_train.shape[1], activation='linear'))
model.compile(loss='mean_squared_error', optimizer='adam', metrics=['mean_squared_error'])
```

```
class ProgressCallback(keras.callbacks.Callback):
```

```
def __init__(self, validation_data):
    self.X_val, self.y_val = validation_data

def on_epoch_end(self, epoch, logs={}):
    y_pred = self.model.predict(self.X_val, verbose=0)
    r2 = round(r2_score(self.y_val, y_pred)*100, 2)

    if epoch % 20 == 0:
        print("Epoch {} - loss: {:.3f} - mean_squared_error: {:.3f} - val_loss: {:.3f} - val_mean_squared_error: {:.3f} - R2: {:.1f}"
              .format(epoch, logs["loss"], logs["mean_squared_error"], logs["val_loss"], logs["val_mean_squared_error"], r2))
```

```
progress_callback = ProgressCallback(validation_data=(X_test, Y_test))
early_stop = EarlyStopping(monitor='val_loss', patience=50, restore_best_weights=True)
reduce_lr = ReduceLROnPlateau(monitor='val_loss', factor=0.8, patience=10, n
```

```
_lr=1e-10)

history = model.fit(X_train, Y_train, epochs=1000, batch_size=3,
                     validation_split=0.3, verbose=0,
                     callbacks=[progress_callback, early_stop, reduce_lr])
```

```
plt.plot(history.history['loss'], label='Training Loss (MSE)')
plt.plot(history.history['val_loss'], label='Validation Loss (MSE)')
plt.title('Model Loss')
plt.ylabel('Loss')
plt.xlabel('Epoch')
plt.legend()
plt.show()
```

```
y_pred_train = model.predict(X_train, verbose=0)
mse, mae, rmse, mape, r2, adj_r2 = metrics(y_pred_train, Y_train, data_USA_8
    .shape[1])
print("## Train ##")
print(f'Mean Squared Error (MSE): {mse:.2e}')
print(f'Mean Absolute Error (MAE): {mae:.2e}')
print(f'Root Mean Squared Error (RMSE): {rmse:.2e}')
print(f'Mean Absolute Percentage Error (MAPE): {mape:.2f} %')
print(f'R-squared (R2): {r2*100:.1f} %')
print(f'Adjusted R-squared (R2 adj): {adj_r2*100:.1f} %')

fig, ax = plt.subplots()
ax.scatter(Y_train, y_pred_train, edgecolors=(0, 0, 0))
ax.plot([Y_train.ravel().min(), Y_train.ravel().max()], [Y_train.ravel().min(), Y
    _train.ravel().max()], 'k--', lw=4)
ax.set_xlabel('Calculado')
ax.set_ylabel('Predito')
plt.title(f'Keras Regressor\nMSE={mse:.4f}, R2={r2*100:.1f} %')
plt.show()
```

```
y_pred_test = model.predict(X_test, verbose=0)
mse, mae, rmse, mape, r2, adj_r2 = metrics(y_pred_test, Y_test, data_USA_8.s
    ape[1])
print("## Test ##")
print(f'Mean Squared Error (MSE): {mse:.2e}')
print(f'Mean Absolute Error (MAE): {mae:.2e}')
print(f'Root Mean Squared Error (RMSE): {rmse:.2e}')
print(f'Mean Absolute Percentage Error (MAPE): {mape:.2f} %')
print(f'R-squared (R2): {r2*100:.1f} %')
print(f'Adjusted R-squared (R2 adj): {adj_r2*100:.1f} %')

fig, ax = plt.subplots()
ax.scatter(Y_test, y_pred_test, edgecolors=(0, 0, 0))
ax.plot([Y_train.ravel().min(), Y_train.ravel().max()], [Y_train.ravel().min(), Y
```

```
_train.ravel().max(), 'k--', lw=4)
ax.set_xlabel('Calculado')
ax.set_ylabel('Pretido')
plt.title(f'Random Forest Regressor\nMSE={mse:.4f}, R2={r2*100:.1f}%')
plt.show()
```

```
errors = Y_test - y_pred_test
errors = np.round(errors, 1)
unique_elements, counts = np.unique(errors, return_counts=True)

fig, ax = plt.subplots(figsize=(8, 4))
ax.bar(unique_elements, counts, edgecolor='black', width=0.1)
ax.axvline(x=0, color='red')
ax.set_title("Erro da retração (%)")
ax.set_xlabel("Retração (%)")
ax.set_ylabel("Frequência")
plt.show()
```

```
feature_names = ['dt', 'w/c', 'a/c', 'c', 'SiO2', 'FlyAsh', 'Slag',
    'Re (kg)', 'Super (kg)', 'AEA (kg)', 'fc28',
    't dry', 'cem_R', 'cem_RS', 'cem_SL']

background_data = X_train[np.random.choice(X_train.shape[0], 100, replace=False)]
explainer = shap.Explainer(model, background_data)
shap_values = explainer(X_test)
shap.summary_plot(shap_values, X_test, feature_names=feature_names)
```

## **ANEXO II – Tabela do Banco de Dados Nacionais**

c	agg	aggregate	mortar	Year	City	Region	Author (laboratory)
(kg/m3)	(kg/m3)	(artificial/natural)	(%)	a/c	w/c	Ref	
340	1786	0,50	0,53	5,25	0,55	1244/2021	2022 Curitiba Sul Bianco Concreto
340	1786	0,50	0,53	5,25	0,55	1244/2021	2022 Curitiba Sul Bianco Concreto
340	1786	0,50	0,53	5,25	0,55	1244/2021	2022 Curitiba Sul Bianco Concreto
340	1786	0,50	0,53	5,25	0,55	1244/2021	2022 Curitiba Sul Bianco Concreto
340	1786	0,50	0,53	5,25	0,55	1244/2021	2022 Curitiba Sul Bianco Concreto
340	1786	0,50	0,53	5,25	0,55	1244/2021	2022 Curitiba Sul Bianco Concreto
340	1786	0,50	0,53	5,25	0,55	1244/2021	2022 Curitiba Sul Bianco Concreto
340	1786	0,50	0,53	5,25	0,55	1243/2021	2022 Curitiba Sul Bianco Concreto
340	1786	0,50	0,53	5,25	0,55	1243/2021	2022 Curitiba Sul Bianco Concreto
340	1786	0,50	0,53	5,25	0,55	1243/2021	2022 Curitiba Sul Bianco Concreto
340	1786	0,50	0,53	5,25	0,55	1243/2021	2022 Curitiba Sul Bianco Concreto
340	1786	0,50	0,53	5,25	0,55	1243/2021	2022 Curitiba Sul Bianco Concreto
340	1786	0,50	0,53	5,25	0,55	1243/2021	2022 Curitiba Sul Bianco Concreto
340	1786	0,50	0,53	5,25	0,55	1243/2021	2022 Curitiba Sul Bianco Concreto
340	1786	0,50	0,53	5,25	0,55	1243/2021	2022 Curitiba Sul Bianco Concreto
340	1786	0,50	0,53	5,25	0,55	1243/2021	2022 Curitiba Sul Bianco Concreto
340	1786	0,50	0,53	5,25	0,55	1243/2021	2022 Curitiba Sul Bianco Concreto
350	2021	0,3	0,53	5,77	0,54	7914.444475	2021 Santa Barbara D'oeste Sudeste Qualitec
350	2021	0,3	0,53	5,77	0,54	7914.444475	2021 Santa Barbara D'oeste Sudeste Qualitec
350	2021	0,3	0,53	5,77	0,54	7914.444475	2021 Santa Barbara D'oeste Sudeste Qualitec
350	2021	0,3	0,53	5,77	0,54	7914.444475	2021 Santa Barbara D'oeste Sudeste Qualitec
350	2021	0,3	0,53	5,77	0,54	7914.444475	2021 Santa Barbara D'oeste Sudeste Qualitec



mortar (%)	a/c	w/c	Ref	Year	City	Region	Author (laboratory)	shrinkage (%)	dt (days)	$f_{ctm,k}$ (MPa)	$f_{ck}$ (MPa)	agg_description
0,53	5,77	0,54	7914.444475	2021	Santa Barbara D'oeste	Sudeste	Qualitec	0	0	30	artificial/natural	
0,53	5,77	0,54	7914.444475	2021	Santa Barbara D'oeste	Sudeste	Qualitec	0,009	1	30	artificial/natural	
0,53	5,77	0,54	7914.444475_A	2021	Santa Barbara D'oeste	Sudeste	Qualitec	0,003	2	30	artificial/natural	
0,53	5,77	0,54	7914.444475_A	2021	Santa Barbara D'oeste	Sudeste	Qualitec	0,001	7	30	artificial/natural	
0,53	5,77	0,54	7914.444475_A	2021	Santa Barbara D'oeste	Sudeste	Qualitec	-0,015	14	30	artificial/natural	
0,53	5,77	0,54	7914.444475_A	2021	Santa Barbara D'oeste	Sudeste	Qualitec	-0,037	28	30	artificial/natural	
0,53	5,77	0,54	7914.444475_A	2021	Santa Barbara D'oeste	Sudeste	Qualitec	-0,049	56	30	artificial/natural	
0,53	5,77	0,54	7914.444475_A	2021	Santa Barbara D'oeste	Sudeste	Qualitec	0	0	30	artificial/natural	
0,53	5,77	0,54	7914.444475_A	2021	Santa Barbara D'oeste	Sudeste	Qualitec	0,016	1	30	artificial/natural	
0,53	6,05	0,55	7914.458415	2022	Piracicaba	Sudeste	Qualitec	0,014	2	30	artificial/natural	
0,53	6,05	0,55	7914.458415	2022	Piracicaba	Sudeste	Qualitec	0,011	7	30	artificial/natural	
0,53	6,05	0,55	7914.458415	2022	Piracicaba	Sudeste	Qualitec	-0,003	14	30	artificial/natural	
0,53	6,05	0,55	7914.458415	2022	Piracicaba	Sudeste	Qualitec	-0,022	28	30	artificial/natural	
0,53	6,05	0,55	7914.458415	2022	Piracicaba	Sudeste	Qualitec	-0,033	56	30	artificial/natural	
0,53	6,05	0,55	7914.458415	2022	Piracicaba	Sudeste	Qualitec	0	0,625	4,2	30	artificial/natural
0,53	6,05	0,55	7914.458415	2022	Piracicaba	Sudeste	Qualitec	0,01	1	4,2	30	artificial/natural
0,53	6,05	0,55	7914.458415_A	2022	Piracicaba	Sudeste	Qualitec	0,016	2	4,2	30	artificial/natural
0,53	6,05	0,55	7914.458415_A	2022	Piracicaba	Sudeste	Qualitec	0,019	7	4,2	30	artificial/natural
0,53	6,05	0,55	7914.458415_A	2022	Piracicaba	Sudeste	Qualitec	-0,007	14	4,2	30	artificial/natural



Region	Author (laboratory)	shrinkage (%)	dt (days)	$f_{cm,k}$ (Mpa)	$f_{ck}$ (Mpa)	agg_description	specified agg_fine	classification	agg	manufacturer
Sudeste	Qualitec	-0,013	28	4,2	30	artificial/natural	cava		basalto	
Sudeste	Qualitec	-0,024	56	4,2	30	artificial/natural	cava		basalto	
Sudeste	Qualitec	0	0,58	4,2	30	artificial/natural	cava		basalto	
Sudeste	Qualitec	-0,013	1	4,2	30	artificial/natural	cava		basalto	
Nordeste	Qualitec	-0,015	2	4,2	30	artificial/natural	cava		basalto	
Nordeste	Qualitec	-0,019	7	4,2	30	artificial/natural	cava		basalto	
Nordeste	Qualitec	-0,023	14	4,2	30	artificial/natural	cava		basalto	
Nordeste	Qualitec	-0,027	28	4,2	30	artificial/natural	cava		basalto	
Nordeste	Qualitec	-0,039	56	4,2	30	artificial/natural	cava		basalto	
Nordeste	Qualitec	0	0,708			artificial/natural	cava		basalto	
Nordeste	Qualitec	0,005	1			artificial/natural	cava		basalto	
Nordeste	Qualitec	0,011	2			artificial/natural	cava		basalto	
Nordeste	Qualitec	0,014	7			artificial/natural	cava		basalto	
Nordeste	Qualitec	-0,005	14			artificial/natural	cava		basalto	
Nordeste	Qualitec	-0,014	28			artificial/natural	cava		basalto	
Nordeste	Qualitec	-0,023	56			artificial/natural	cava		basalto	
Nordeste	Qualitec	0	0,708			artificial/natural	cava		basalto	
Nordeste	Qualitec	-0,007	1			artificial/natural	cava		basalto	
Sudeste	Qualitec	-0,011	2			artificial/natural	cava		basalto	

	super ranger	mid ranger	multifunctional	c (kg/m3) (artificial/natural)	agg (kg/m3) (artificial/natural)	aggregate mortar (%)	a/c	w/c	Ref	Year	City
0	0,5	0,6	337	2038	0,25	0,53	6,05	0,55	7914.458415_A	2022	Piracicaba
0	0,5	0,6	337	2038	0,25	0,53	6,05	0,55	7914.458415_A	2022	Piracicaba
0	0,5	0,6	337	2038	0,25	0,53	6,05	0,55	7914.458415_A	2022	Piracicaba
0	0,5	0,6	337	2038	0,25	0,53	6,05	0,55	7914.458415_A	2022	Piracicaba
0	0	0,72	380	1810	0	0,51	4,76	0,49	7914.440109	2021	Teresina
0	0	0,72	380	1810	0	0,51	4,76	0,49	7914.440109	2021	Teresina
0	0	0,72	380	1810	0	0,51	4,76	0,49	7914.440109	2021	Teresina
0	0	0,72	380	1810	0	0,51	4,76	0,49	7914.440109	2021	Teresina
0	0	0,72	380	1810	0	0,51	4,76	0,49	7914.440109	2021	Teresina
0	0	0,72	380	1810	0	0,51	4,76	0,49	7914.440109	2021	Teresina
0	0	0,72	380	1810	0	0,51	4,76	0,49	7914.440109	2021	Teresina
0	0	0,72	380	1810	0	0,51	4,76	0,49	7914.440109	2021	Teresina
0	0	0,72	380	1810	0	0,51	4,76	0,49	7914.440109	2021	Teresina
0	0	0,72	380	1810	0	0,51	4,76	0,49	7914.440109	2021	Teresina
0	0	0,72	380	1810	0	0,51	4,76	0,49	7914.440109	2021	Teresina
0	0	0,72	380	1810	0	0,51	4,76	0,49	7914.440109	2021	Teresina
0	0	0,72	380	1810	0	0,51	4,76	0,49	7914.440109	2021	Teresina
0	0	0,72	380	1810	0	0,51	4,76	0,49	7914.440109	2021	Teresina
0	0	0,72	380	1810	0	0,51	4,76	0,49	7914.440109	2021	Teresina
0	0	0,72	380	1810	0	0,51	4,76	0,49	7914.440109	2021	Teresina
0	0	0,72	380	1810	0	0,51	4,76	0,49	7914.440109	2021	Teresina
0	0	0,72	380	1810	0	0,51	4,76	0,49	7914.440109	2021	Teresina
0	0	0,72	380	1810	0	0,51	4,76	0,49	7914.440109	2021	Teresina
0	0	0,65	336	1810	0,41	0,57	5,39	0,55	7914.442155_A	2022	Santo Andre

$f_{ctm,k}$ (Mpa)	$f_{ck}$ (Mpa)	agg_description	specified agg_fine	classification agg	manufacturer	cemento steel	macrofiber PP	macrofiber PP	microfiber PP	compensator
		artificial/natural	cava	basalto	CP V ARI RS	0,00	5,50	0,6	0	
		artificial/natural	cava	basalto	CP V ARI RS	0,00	5,50	0,6	0	
		artificial/natural	cava	basalto	CP V ARI RS	0,00	5,50	0,6	0	
		artificial/natural	cava	basalto	CP V ARI RS	0,00	5,50	0,6	0	
4,5	35	0		Mizu	CP V ARI RS	0,00	0,00	0	0	
4,5	35	0		Mizu	CP V ARI RS	0,00	0,00	0	0	
4,5	35	0		Mizu	CP V ARI RS	0,00	0,00	0	0	
4,5	35	0		Mizu	CP V ARI RS	0,00	0,00	0	0	
4,5	35	0		Mizu	CP V ARI RS	0,00	0,00	0	0	
4,5	35	0		Mizu	CP V ARI RS	0,00	0,00	0	0	
4,5	35	0		Mizu	CP V ARI RS	0,00	0,00	0	0	
4,5	35	0		Mizu	CP V ARI RS	0,00	0,00	0	0	
4,5	35	0		Mizu	CP V ARI RS	0,00	0,00	0	0	
4,5	35	0		Mizu	CP V ARI RS	0,00	0,00	0	0	
4,5	35	0		Mizu	CP V ARI RS	0,00	0,00	0	0	
4,2	30	artificial/natural	Tupi	CP II E 40	0,00	0,00	0,6	0		

	agg (kg/m3)	aggregate (artificial/natural)	mortar (%)	a/c	w/c	Ref	Year	City	Region	Author (laboratory)	shrinkage (%)	dt (days)
1810	0,41	0,57	5,39	0,55	7914.442155_A	2022	Santo Andre	Sudeste	Qualitec	-0,018	7	
1810	0,41	0,57	5,39	0,55	7914.442155_A	2022	Santo Andre	Sudeste	Qualitec	-0,026	14	
1810	0,41	0,57	5,39	0,55	7914.442155_A	2022	Santo Andre	Sudeste	Qualitec	-0,034	28	
1810	0,41	0,57	5,39	0,55	7914.442155_A	2022	Santo Andre	Sudeste	Qualitec	-0,043	56	
1810	0,41	0,57	5,39	0,55	7914.442155_A	2022	Santo Andre	Sudeste	Qualitec	0	0,708	
1810	0,41	0,57	5,39	0,55	7914.442155_A	2022	Santo Andre	Sudeste	Qualitec	-0,005	1	
1810	0,41	0,57	5,39	0,55	7914.442155	2022	Santo Andre	Sudeste	Qualitec	-0,01	2	
1810	0,41	0,57	5,39	0,55	7914.442155	2022	Santo Andre	Sudeste	Qualitec	-0,017	7	
1810	0,41	0,57	5,39	0,55	7914.442155	2022	Santo Andre	Sudeste	Qualitec	-0,026	14	
1810	0,41	0,57	5,39	0,55	7914.442155	2022	Santo Andre	Sudeste	Qualitec	-0,037	28	
1810	0,41	0,57	5,39	0,55	7914.442155	2022	Santo Andre	Sudeste	Qualitec	-0,045	56	
1810	0,41	0,57	5,39	0,55	7914.442155	2022	Santo Andre	Sudeste	Qualitec	0	0,75	
1810	0,41	0,57	5,39	0,55	7914.442155	2022	Santo Andre	Sudeste	Qualitec	0,003	1	
1712	0	0,56	5,04	0,56	7914.459571_A	2022	Belem	Norte	Qualitec	0,007	2	
1712	0	0,56	5,04	0,56	7914.459571_A	2022	Belem	Norte	Qualitec	0,012	7	
1712	0	0,56	5,04	0,56	7914.459571_A	2022	Belem	Norte	Qualitec	-0,009	14	
1712	0	0,56	5,04	0,56	7914.459571_A	2022	Belem	Norte	Qualitec	-0,02	28	
1712	0	0,56	5,04	0,56	7914.459571_A	2022	Belem	Norte	Qualitec	-0,032	56	
1712	0	0,56	5,04	0,56	7914.459571_A	2022	Belem	Norte	Qualitec	0	0,625	

classification agg	manufacturer	cemente	macrofiber steel	macrofiber PP	macrofiber	microfiber	compensator	super ranger	mid ranger	multifunctional	c (kg/m3)
Tupi	CP II E 40	0,00	0,00	0,6	0	0	0	0	0,65	336	
Tupi	CP II E 40	0,00	0,00	0,6	0	0	0	0	0,65	336	
Tupi	CP II E 40	0,00	0,00	0,6	0	0	0	0	0,65	336	
Tupi	CP II E 40	0,00	0,00	0,6	0	0	0	0	0,65	336	
Tupi	CP II E 40	0,00	0,00	0,6	0	0	0	0	0,65	336	
Tupi	CP II E 40	0,00	0,00	0,6	0	0	0	0	0,65	336	
Tupi	CP II E 40	0,00	0,00	0,6	0	0	0	0	0,65	336	
Tupi	CP II E 40	0,00	0,00	0,6	10	0	0	0	0,65	336	
Tupi	CP II E 40	0,00	0,00	0,6	10	0	0	0	0,65	336	
Tupi	CP II E 40	0,00	0,00	0,6	10	0	0	0	0,65	336	
Tupi	CP II E 40	0,00	0,00	0,6	10	0	0	0	0,65	336	
Tupi	CP II E 40	0,00	0,00	0,6	10	0	0	0	0,65	336	
Tupi	CP II E 40	0,00	0,00	0,6	10	0	0	0	0,65	336	
Votorantim	CP II E	0,00	0,00	0,6	10	0	0	0	0,65	336	
Votorantim	CP II E	0,00	0,00	0,6	10	0	0	0	0,65	336	
Votorantim	CP II E	0,00	0,00	0,6	12	0,2	0	0	0,82	340	
Votorantim	CP II E	0,00	0,00	0,6	12	0,2	0	0	0,82	340	
Votorantim	CP II E	0,00	0,00	0,6	12	0,2	0	0	0,82	340	
Votorantim	CP II E	0,00	0,00	0,6	12	0,2	0	0	0,82	340	

w/c	Ref	Year	City	Region	Author (laboratory)	shrinkage (%)	dt (days)	$f_{ctm,k}$ (Mpa)	$f_{ck}$ (Mpa)	agg_description	specified agg_fine
0,56	7914.459571	A	2022	Belem	Norte Qualitec	-0,005	1	4,2	30	artificial/natural	
0,56	7914.459571	2022	Belem	Norte	Qualitec	-0,009	2	4,2	30	artificial/natural	
0,56	7914.459571	2022	Belem	Norte	Qualitec	-0,014	7	4,2	30	artificial/natural	
0,56	7914.459571	2022	Belem	Norte	Qualitec	-0,02	14	4,2	30	artificial/natural	
0,56	7914.459571	2022	Belem	Norte	Qualitec	-0,031	28	4,2	30	artificial/natural	
0,56	7914.459571	2022	Belem	Norte	Qualitec	-0,041	56	4,2	30	artificial/natural	
0,56	7914.459571	2022	Belem	Norte	Qualitec	0	0,625	4,2	30	artificial/natural	
0,56	7914.459571	2022	Belem	Norte	Qualitec	0,005	1	4,2	30	artificial/natural	
0,5	2021	Cabedelo	Nordeste	Qualitec	0,012	2	4,2	30	artificial/natural		
0,5	2021	Cabedelo	Nordeste	Qualitec	0,007	7	4,2	30	artificial/natural		
0,5	2021	Cabedelo	Nordeste	Qualitec	-0,005	14	4,2	30	artificial/natural		
0,5	2021	Cabedelo	Nordeste	Qualitec	-0,016	28	4,2	30	artificial/natural		
0,5	2021	Cabedelo	Nordeste	Qualitec	-0,023	56	4,2	30	artificial/natural		
0,5	2021	Cabedelo	Nordeste	Qualitec	0	0,75		0	rio		
0,5	2021	Cabedelo	Nordeste	Qualitec	0,003	1		0	rio		
0,5	2021	Cabedelo	Nordeste	Qualitec	0,008	2		0	rio		
0,5	2021	Cabedelo	Nordeste	Qualitec	0,012	7		0	rio		
0,5	2021	Cabedelo	Nordeste	Qualitec	-0,003	14		0	rio		
0,5	2021	Cabedelo	Nordeste	Qualitec	-0,012	28		0	rio		



Region	Author (laboratory)	shrinkage (%)	dt	$f_{ctm,k}$	$f_{ck}$	agg_description	specified agg_fine	classification agg	manufacturer	cement
Nordeste	Qualitec	-0,021	56		0		rio		Votorantim	CP II E
Nordeste	Qualitec	0	0,708		0		rio		Votorantim	CP II E
Nordeste	Qualitec	-0,005	1		0		rio		Votorantim	CP II E
Norte	Qualitec	-0,01	2		0		rio		Votorantim	CP II E
Norte	Qualitec	-0,014	7		0		rio		Votorantim	CP II E
Norte	Qualitec	-0,02	14		0		rio		Votorantim	CP II E
Norte	Qualitec	-0,028	28		0		rio		Votorantim	CP II E
Norte	Qualitec	-0,043	56		0		rio		Votorantim	CP II E
Norte	Qualitec	0	0	4,2	30		0		Mizu	CP V ARI RS
Norte	Qualitec	0,007	1	4,2	30		0		Mizu	CP V ARI RS
Norte	Qualitec	0,012	2	4,2	30		0		Mizu	CP V ARI RS
Norte	Qualitec	0,017	7	4,2	30		0		Mizu	CP V ARI RS
Norte	Qualitec	-0,005	14	4,2	30		0		Mizu	CP V ARI RS
Norte	Qualitec	-0,024	28	4,2	30		0		Mizu	CP V ARI RS
Norte	Qualitec	-0,038	56	4,2	30		0		Mizu	CP V ARI RS
Norte	Qualitec	0	0	4,2	30		0		Mizu	CP V ARI RS
Norte	Qualitec	-0,007	1	4,2	30		0		Mizu	CP V ARI RS
Norte	Qualitec	-0,009	2	4,2	30		0		Mizu	CP V ARI RS
Norte	Qualitec	-0,013	7	4,2	30		0		Mizu	CP V ARI RS

super ranger	mid multifunctional	c (kg/m3) (artificial/natural)	agg (kg/m3) (artificial/natural)	aggregate (%)	mortar a/c	w/c	Ref	Year	City
0,5	0	0,62	370	1810	0	0,5	4,89	0,5	2021
0,5	0	0,62	370	1810	0	0,5	4,89	0,5	2021
0,5	0	0,62	370	1810	0	0,5	4,89	0,5	Cabedelo
0,35	0	0,9	360	1779	0	0,517	4,94	0,53	2021
0,35	0	0,9	360	1779	0	0,517	4,94	0,53	Manaus
0,35	0	0,9	360	1779	0	0,517	4,94	0,53	Manaus
0,35	0	0,9	360	1779	0	0,517	4,94	0,53	Manaus
0,35	0	0,9	360	1779	0	0,517	4,94	0,53	Manaus
0,35	0	0,9	360	1779	0	0,517	4,94	0,53	Manaus
0,35	0	0,9	360	1779	0	0,517	4,94	0,53	Manaus
0,35	0	0,9	360	1779	0	0,517	4,94	0,53	Manaus
0,35	0	0,9	360	1779	0	0,517	4,94	0,53	Manaus
0,35	0	0,9	360	1779	0	0,517	4,94	0,53	Manaus
0,35	0	0,9	360	1779	0	0,517	4,94	0,53	Manaus
0,35	0	0,9	360	1779	0	0,517	4,94	0,53	Manaus
0,35	0	0,9	360	1779	0	0,517	4,94	0,53	Manaus
0,35	0	0,9	360	1779	0	0,517	4,94	0,53	Manaus
0,35	0	0,9	360	1779	0	0,517	4,94	0,53	Manaus
0,35	0	0,9	360	1779	0	0,517	4,94	0,53	Manaus
0,35	0	0,9	360	1779	0	0,517	4,94	0,53	Manaus
0,4	0	0,9	360	1779	0	0,517	4,94	0,53	2021
0,4	0	0,9	360	1779	0	0,517	4,94	0,53	Manaus



	agg (kg/m3)	aggregate (artificial/natural)	mortar (%)	a/c	w/c	Ref	Year	City	Region	Author (laboratory)	shrinkage (%)	dt (days)
1779	0	0,517	4,94	0,53	7914.430520	2021	Manaus	Norte	Qualitec	-0,02	14	
1779	0	0,517	4,94	0,53	7914.430520	2021	Manaus	Norte	Qualitec	-0,032	28	
1779	0	0,517	4,94	0,53	7914.430520	2021	Manaus	Norte	Qualitec	-0,044	56	
1779	0	0,517	4,94	0,53	7914.430520	2021	Manaus	Norte	Qualitec	0	0,5	
1779	0	0,517	4,94	0,53	7914.430520	2021	Manaus	Norte	Qualitec	0,012	1	
1779	0	0,517	4,94	0,53	7914.430520	2021	Manaus	Norte	Qualitec	0,016	2	
1779	0	0,517	4,94	0,53	7914.430520_A	2021	Manaus	Norte	Qualitec	0,02	7	
1779	0	0,517	4,94	0,53	7914.430520_A	2021	Manaus	Norte	Qualitec	-0,003	14	
1779	0	0,517	4,94	0,53	7914.430520_A	2021	Manaus	Norte	Qualitec	-0,015	28	
1779	0	0,517	4,94	0,53	7914.430520_A	2021	Manaus	Norte	Qualitec	-0,027	56	
1779	0	0,517	4,94	0,53	7914.430520_A	2021	Manaus	Norte	Qualitec	0	0,5	
1779	0	0,517	4,94	0,53	7914.430520_A	2021	Manaus	Norte	Qualitec	-0,007	1	
1779	0	0,517	4,94	0,53	7914.430520_A	2021	Manaus	Norte	Qualitec	-0,011	2	
1739	0	0,532	4,58	0,52	7914.430401	2021	Manaus	Norte	Qualitec	-0,017	7	
1739	0	0,532	4,58	0,52	7914.430401	2021	Manaus	Norte	Qualitec	-0,022	14	
1739	0	0,532	4,58	0,52	7914.430401	2021	Manaus	Norte	Qualitec	-0,034	28	
1739	0	0,532	4,58	0,52	7914.430401	2021	Manaus	Norte	Qualitec	-0,049	56	
1739	0	0,532	4,58	0,52	7914.430401	2021	Manaus	Norte	Qualitec	0	0,625	
1739	0	0,532	4,58	0,52	7914.430401	2021	Manaus	Norte	Qualitec	0,009	1	



w/c	Ref	Year	City	Region	Author (laboratory)	shrinkage (%)	dt (days)	$f_{ctm,k}$ (Mpa)	$f_{ck}$ (Mpa)	agg_description	specified agg_fine
0,52	7914.430401	2021	Manaus	Norte	Qualitec	0,014	2	4,2	30	0	rio
0,52	7914.430401_A	2021	Manaus	Norte	Qualitec	0,016	7	4,2	30	0	rio
0,52	7914.430401_A	2021	Manaus	Norte	Qualitec	-0,005	14	4,2	30	0	rio
0,52	7914.430401_A	2021	Manaus	Norte	Qualitec	-0,016	28	4,2	30	0	rio
0,52	7914.430401_A	2021	Manaus	Norte	Qualitec	-0,029	56	4,2	30	0	rio
0,52	7914.430401_A	2021	Manaus	Norte	Qualitec	0	0,625	4,2	30	0	rio
0,52	7914.430401_A	2021	Manaus	Norte	Qualitec	-0,005	1	4,2	30	0	rio
0,51	7914.439717_1	2021	Recife	Nordeste	Qualitec	-0,01	2	4,2	30	0	rio
0,51	7914.439717_1	2021	Recife	Nordeste	Qualitec	-0,018	7	4,2	30	0	rio
0,51	7914.439717_1	2021	Recife	Nordeste	Qualitec	-0,025	14	4,2	30	0	rio
0,51	7914.439717_1	2021	Recife	Nordeste	Qualitec	-0,032	28	4,2	30	0	rio
0,51	7914.439717_1	2021	Recife	Nordeste	Qualitec	-0,042	56	4,2	30	0	rio
0,51	7914.439717_1	2021	Recife	Nordeste	Qualitec	0	0,5	4,2	30	0	rio
0,51	7914.439717_1	2021	Recife	Nordeste	Qualitec	-0,009	1	4,2	30	0	rio
0,51	7914.447132	2021	Recife	Nordeste	Qualitec	-0,014	2	4,2	30	0	rio
0,51	7914.447132	2021	Recife	Nordeste	Qualitec	-0,018	7	4,2	30	0	rio
0,51	7914.447132	2021	Recife	Nordeste	Qualitec	-0,024	14	4,2	30	0	rio
0,51	7914.447132	2021	Recife	Nordeste	Qualitec	-0,033	28	4,2	30	0	rio



Region	Author (laboratory)	shrinkage (%)	dt (days)	f <sub>ctm,k</sub> (Mpa)	f <sub>ck</sub> (Mpa)	agg_description	specified agg_fine	classification agg	manufacturer	cement
Nordeste	Qualitec	-0,045	56	4,2	30	0	rio	Poty	CP II F 32 RS	
Nordeste	Qualitec	0	0,5	4,2	30	0	rio	Poty	CP II F 32 RS	
Nordeste	Qualitec	0,008	1	4,2	30	0	rio	Poty	CP II F 32 RS	
Centro-oeste	Qualitec	0,012	2	4,2	30	0	rio	Poty	CP II F 32 RS	
Centro-oeste	Qualitec	0,015	7	4,2	30	0	rio	Poty	CP II F 32 RS	
Centro-oeste	Qualitec	-0,005	14	4,2	30	0	rio	Poty	CP II F 32 RS	
Centro-oeste	Qualitec	-0,017	28	4,2	30	0	rio	Poty	CP II F 32 RS	
Centro-oeste	Qualitec	-0,031	56	4,2	30	0	rio	Poty	CP II F 32 RS	
Centro-oeste	Qualitec	0	0,708			0	rio	Nacional	CP II F 40	
Centro-oeste	Qualitec	0,001	1			0	rio	Nacional	CP II F 40	
Centro-oeste	Qualitec	0,003	2			0	rio	Nacional	CP II F 40	
Centro-oeste	Qualitec	0,007	7			0	rio	Nacional	CP II F 40	
Centro-oeste	Qualitec	-0,015	14			0	rio	Nacional	CP II F 40	
Centro-oeste	Qualitec	-0,023	28			0	rio	Nacional	CP II F 40	
Centro-oeste	Qualitec	-0,031	56			0	rio	Nacional	CP II F 40	
Centro-oeste	Qualitec	0	0,708			0	rio	Nacional	CP II F 40	
Centro-oeste	Qualitec	-0,006	1			0	rio	Nacional	CP II F 40	
Nordeste	Qualitec	-0,012	2			0	rio	Nacional	CP II F 40	
Nordeste	Qualitec	-0,016	7			0	rio	Nacional	CP II F 40	

	super ranger	mid ranger	multifunctional	c (kg/m3) (artificial/natural)	agg (kg/m3) (artificial/natural)	aggregate (%)	mortar a/c	w/c	Ref	Year	City
0	0	0,85	412	1667	0	0,49	4,05	0,51	7914.447132	2021	Recife
0	0	0,85	412	1667	0	0,49	4,05	0,51	7914.447132	2021	Recife
0	0	0,85	412	1667	0	0,49	4,05	0,51	7914.447132	2021	Recife
0,43	0	0,7	380	1698	0,1	0,52	4,47	0,47	7914.424545	2021	Rondonopolis
0,43	0	0,7	380	1698	0,1	0,52	4,47	0,47	7914.424545	2021	Rondonopolis
0,43	0	0,7	380	1698	0,1	0,52	4,47	0,47	7914.424545	2021	Rondonopolis
0,43	0	0,7	380	1698	0,1	0,52	4,47	0,47	7914.424545	2021	Rondonopolis
0,43	0	0,7	380	1698	0,1	0,52	4,47	0,47	7914.424545	2021	Rondonopolis
0,43	0	0,7	380	1698	0,1	0,52	4,47	0,47	7914.424545	2021	Rondonopolis
0,43	0	0,7	380	1698	0,1	0,52	4,47	0,47	7914.424545	2021	Rondonopolis
0,43	0	0,7	380	1698	0,1	0,52	4,47	0,47	7914.424545	2021	Rondonopolis
0,43	0	0,7	380	1698	0,1	0,52	4,47	0,47	7914.424545	2021	Rondonopolis
0,43	0	0,7	380	1698	0,1	0,52	4,47	0,47	7914.424545	2021	Rondonopolis
0,43	0	0,7	380	1698	0,1	0,52	4,47	0,47	7914.424545	2021	Rondonopolis
0,43	0	0,7	380	1698	0,1	0,52	4,47	0,47	7914.424545	2021	Rondonopolis
0,43	0	0,7	380	1698	0,1	0,52	4,47	0,47	7914.424545	2021	Rondonopolis
0,43	0	0,7	380	1698	0,1	0,52	4,47	0,47	7914.424545	2021	Rondonopolis
0,43	0	0,7	380	1698	0,1	0,52	4,47	0,47	7914.424545	2021	Rondonopolis
0,43	0	0,7	380	1698	0,1	0,52	4,47	0,47	7914.424545	2021	Rondonopolis
0	0	0,35	311	1832	0,1	0,52	5,89	0,62	7914.417208	2021	Feira de Santana
0	0	0,35	311	1832	0,1	0,52	5,89	0,62	7914.417208	2021	Feira de Santana

$f_{ctm,k}$ (Mpa)	$f_{ck}$ (Mpa)	agg_description	specified agg_fine	classification agg	manufacturer	cement	macrofiber steel	macrofiber PP	macrofiber microfiber	compensator
0	0	rio	rio	Nacional	CP II F 40	0,00	0,00	0	0	0
0	0	rio	rio	Nacional	CP II F 40	0,00	0,00	0	0	0
0	0	rio	rio	Nacional	CP II F 40	0,00	0,00	0	0	0
artificial/natural	artificial/natural	rio	rio	Intercement	CP II F 40	0,00	6,00	0,6	0	0
artificial/natural	artificial/natural	rio	rio	Intercement	CP II F 40	0,00	6,00	0,6	0	0
artificial/natural	artificial/natural	rio	rio	Intercement	CP II F 40	0,00	6,00	0,6	0	0
artificial/natural	artificial/natural	rio	rio	Intercement	CP II F 40	0,00	6,00	0,6	0	0
artificial/natural	artificial/natural	rio	rio	Intercement	CP II F 40	0,00	6,00	0,6	0	0
artificial/natural	artificial/natural	rio	rio	Intercement	CP II F 40	0,00	6,00	0,6	0	0
artificial/natural	artificial/natural	rio	rio	Intercement	CP II F 40	0,00	6,00	0,6	0	0
artificial/natural	artificial/natural	rio	rio	Intercement	CP II F 40	0,00	6,00	0,6	0	0
artificial/natural	artificial/natural	rio	rio	Intercement	CP II F 40	0,00	6,00	0,6	0	0
artificial/natural	artificial/natural	rio	rio	Intercement	CP II F 40	0,00	6,00	0,6	0	0
artificial/natural	artificial/natural	rio	rio	Intercement	CP II F 40	0,00	6,00	0,6	0	0
artificial/natural	artificial/natural	rio	rio	Intercement	CP II F 40	0,00	6,00	0,6	0	0
artificial/natural	artificial/natural	rio	rio	Intercement	CP II F 40	0,00	6,00	0,6	0	0
4,2	30	artificial/natural	rio	Intercement	CP II F 40	0,00	0,00	0	10	10
4,2	30	artificial/natural	rio	Intercement	CP II F 40	0,00	0,00	0	10	10

	agg (kg/m3)	aggregate (artificial/natural)	mortar (%)	a/c	w/c	Ref	Year	City	Region	Author (laboratory)	shrinkage (%)	dt (days)
1832	0,1	0,52	5,89	0,62	7914.417208	2021	Feira de Santana	Nordeste	Qualitec	-0,026	14	
1832	0,1	0,52	5,89	0,62	7914.417208	2021	Feira de Santana	Nordeste	Qualitec	-0,035	28	
1832	0,1	0,52	5,89	0,62	7914.417208	2021	Feira de Santana	Nordeste	Qualitec	-0,043	56	
1832	0,1	0,52	5,89	0,62	7914.417208	2021	Feira de Santana	Nordeste	Qualitec	0	0,58	
1832	0,1	0,52	5,89	0,62	7914.417208	2021	Feira de Santana	Nordeste	Qualitec	-0,002	1	
1832	0,1	0,52	5,89	0,62	7914.417208_A	2021	Feira de Santana	Nordeste	Qualitec	-0,007	2	
1832	0,1	0,52	5,89	0,62	7914.417208_A	2021	Feira de Santana	Nordeste	Qualitec	-0,01	7	
1832	0,1	0,52	5,89	0,62	7914.417208_A	2021	Feira de Santana	Nordeste	Qualitec	-0,02	14	
1832	0,1	0,52	5,89	0,62	7914.417208_A	2021	Feira de Santana	Nordeste	Qualitec	-0,046	28	
1832	0,1	0,52	5,89	0,62	7914.417208_A	2021	Feira de Santana	Nordeste	Qualitec	-0,058	56	
1832	0,1	0,52	5,89	0,62	7914.417208_A	2021	Feira de Santana	Nordeste	Qualitec	0	0,625	
1832	0,1	0,52	5,89	0,62	7914.417208_A	2021	Feira de Santana	Nordeste	Qualitec	0,005	1	
1931	0,52	0,49	5,75	0,55	7914.457891_A	2021	Ribeirão Preto	Sudeste	Qualitec	0,008	2	
1931	0,52	0,49	5,75	0,55	7914.457891_A	2021	Ribeirão Preto	Sudeste	Qualitec	0,012	7	
1931	0,52	0,49	5,75	0,55	7914.457891_A	2021	Ribeirão Preto	Sudeste	Qualitec	0,002	14	
1931	0,52	0,49	5,75	0,55	7914.457891_A	2021	Ribeirão Preto	Sudeste	Qualitec	-0,011	28	
1931	0,52	0,49	5,75	0,55	7914.457891_A	2021	Ribeirão Preto	Sudeste	Qualitec	-0,028	56	
1931	0,52	0,49	5,75	0,55	7914.457891_A	2021	Ribeirão Preto	Sudeste	Qualitec	0	0	
1931	0,52	0,49	5,75	0,55	7914.457891_A	2021	Ribeirão Preto	Sudeste	Qualitec	0,003	1	



w/c	Ref	Year	City	Region	Author (laboratory)	shrinkage (%)	dt (days)	$f_{ctm,k}$ (Mpa)	$f_{ck}$ (Mpa)	agg_description	specified agg_fine
0,55	7914.457891_B	2021	Ribeirão Preto	Sudeste	Qualitec	0,004	2	4,2	30	artificial/natural	rio
0,55	7914.457891_B	2021	Ribeirão Preto	Sudeste	Qualitec	0,006	7	4,2	30	artificial/natural	rio
0,55	7914.457891_B	2021	Ribeirão Preto	Sudeste	Qualitec	-0,004	14	4,2	30	artificial/natural	rio
0,55	7914.457891_B	2021	Ribeirão Preto	Sudeste	Qualitec	-0,009	28	4,2	30	artificial/natural	rio
0,55	7914.457891_B	2021	Ribeirão Preto	Sudeste	Qualitec	-0,02	56	4,2	30	artificial/natural	rio
0,55	7914.457891_B	2021	Ribeirão Preto	Sudeste	Qualitec	0	0	4,2	30	artificial/natural	rio
0,55	7914.457891_B	2021	Ribeirão Preto	Sudeste	Qualitec	-0,001	1	4,2	30	artificial/natural	rio
0,55	7914.457891	2021	Ribeirão Preto	Sudeste	Qualitec	-0,003	2	4,2	30	artificial/natural	rio
0,55	7914.457891	2021	Ribeirão Preto	Sudeste	Qualitec	-0,005	7	4,2	30	artificial/natural	rio
0,55	7914.457891	2021	Ribeirão Preto	Sudeste	Qualitec	-0,014	14	4,2	30	artificial/natural	rio
0,55	7914.457891	2021	Ribeirão Preto	Sudeste	Qualitec	-0,027	28	4,2	30	artificial/natural	rio
0,55	7914.457891	2021	Ribeirão Preto	Sudeste	Qualitec	-0,041	56	4,2	30	artificial/natural	rio
0,55	7914.457891	2021	Ribeirão Preto	Sudeste	Qualitec	0	0,708	4,2	30	artificial/natural	rio
0,55	7914.457891	2021	Ribeirão Preto	Sudeste	Qualitec	-0,008	1	4,2	30	artificial/natural	rio
0,55	7914.457613	2021	Ribeirão Preto	Sudeste	Qualitec	-0,013	2	4,2	30	artificial/natural	rio
0,55	7914.457613	2021	Ribeirão Preto	Sudeste	Qualitec	-0,018	7	4,2	30	artificial/natural	rio
0,55	7914.457613	2021	Ribeirão Preto	Sudeste	Qualitec	-0,022	14	4,2	30	artificial/natural	rio
0,55	7914.457613	2021	Ribeirão Preto	Sudeste	Qualitec	-0,029	28	4,2	30	artificial/natural	rio
0,55	7914.457613	2021	Ribeirão Preto	Sudeste	Qualitec	-0,041	56	4,2	30	artificial/natural	rio

macrofiber steel	macrofiber PP	macrofiber microfiber	compensator	super ranger	mid multifunctional	c	agg (kg/m3) (artificial/natural)	mortar (%)	a/c
0,00	4,00	0,6	15	0,7	0	0,35	336	1931	0,49
0,00	4,00	0,6	15	0,7	0	0,35	336	1931	0,49
0,00	4,00	0,6	15	0,7	0	0,35	336	1931	0,49
0,00	4,00	0,6	15	0,7	0	0,35	336	1931	0,49
0,00	4,00	0,6	15	0,7	0	0,35	336	1931	0,49
0,00	4,00	0,6	15	0,7	0	0,35	336	1931	0,49
0,00	4,00	0,6	15	0,7	0	0,35	336	1931	0,49
0,00	4,00	0,6	15	0,7	0	0,35	336	1931	0,49
0,00	4,00	0,6	10	0,7	0	0,35	336	1931	0,49
0,00	4,00	0,6	10	0,7	0	0,35	336	1931	0,49
0,00	4,00	0,6	10	0,7	0	0,35	336	1931	0,49
0,00	4,00	0,6	10	0,7	0	0,35	336	1931	0,49
0,00	4,00	0,6	10	0,7	0	0,35	336	1931	0,49
0,00	4,00	0,6	10	0,7	0	0,35	336	1931	0,49
0,00	4,00	0,6	10	0,7	0	0,35	336	1931	0,49
0,00	4,00	0,6	10	0,7	0	0,35	336	1931	0,49
0,00	4,00	0,6	10	0,7	0	0,35	336	1931	0,49
0,00	4,00	0,6	10	0,7	0	0,35	336	1931	0,49
0,00	4,00	0,6	10	0,7	0	0,35	336	1931	0,49
0,00	0,00	0,6	10	0	0	0,65	336	1931	0,52
0,00	0,00	0,6	10	0	0	0,65	336	1931	0,52
0,00	0,00	0,6	10	0	0	0,65	336	1931	0,52
0,00	0,00	0,6	10	0	0	0,65	336	1931	0,52
0,00	0,00	0,6	10	0	0	0,65	336	1931	0,52

Region	Author (laboratory)	shrinkage (%)	dt (days)	$f_{ctm,k}$ (Mpa)	$f_{ck}$ (Mpa)	agg_description	specified agg_fine	classification agg	manufacturer	cement
Sudeste	Qualitec	0	0,67	4,2	30	artificial/natural	rio		CSN	CP II E 40 RS
Sudeste	Qualitec	0,003	1	4,2	30	artificial/natural	rio		CSN	CP II E 40 RS
Sudeste	Qualitec	0,008	2	4,2	30	artificial/natural	rio		CSN	CP II E 40 RS
Sudeste	Qualitec	0,015	7	4,2	30	artificial/natural	rio		CSN	CP II E 40 RS
Sudeste	Qualitec	-0,004	14	4,2	30	artificial/natural	rio		CSN	CP II E 40 RS
Sudeste	Qualitec	-0,011	28	4,2	30	artificial/natural	rio		CSN	CP II E 40 RS
Sudeste	Qualitec	-0,025	56	4,2	30	artificial/natural	rio		CSN	CP II E 40 RS
Sudeste	Qualitec	0	0,708	4,2	30	artificial/natural	rio		CSN	CP II E 40 RS
Sudeste	Qualitec	0,004	1	4,2	30	artificial/natural	rio		CSN	CP II E 40 RS
Sudeste	Qualitec	0,008	2	4,2	30	artificial/natural	rio		CSN	CP II E 40 RS
Sudeste	Qualitec	0,011	7	4,2	30	artificial/natural	rio		CSN	CP II E 40 RS
Sudeste	Qualitec	-0,005	14	4,2	30	artificial/natural	rio		CSN	CP II E 40 RS
Sudeste	Qualitec	-0,014	28	4,2	30	artificial/natural	rio		CSN	CP II E 40 RS
Sudeste	Qualitec	-0,033	56	4,2	30	artificial/natural	rio		CSN	CP II E 40 RS
Sudeste	Qualitec	0	0,708	4,2	30	artificial/natural	rio		CSN	CP II E 40 RS
Sudeste	Qualitec	0,005	1	4,2	30	artificial/natural	rio		CSN	CP II E 40 RS
Sudeste	Qualitec	0,01	2	4,2	30	artificial/natural	rio		CSN	CP II E 40 RS
Sudeste	Qualitec	0,013	7	4,2	30	artificial/natural	rio		CSN	CP II E 40 RS
Sudeste	Qualitec	-0,005	14	4,2	30	artificial/natural	rio		CSN	CP II E 40 RS

super ranger	mid ranger	multifunctional	c (kg/m3) (artificial/natural)	agg (kg/m3) (artificial/natural)	aggregate (%)	mortar a/c	w/c	Ref	Year	City	
0	0	0,65	336	1931	0,52	0,49	5,75	0,55	7914.457613	2021	Ribeirão Preto
0	0	0,65	336	1931	0,52	0,49	5,75	0,55	7914.457613	2021	Ribeirão Preto
0	0	0,65	336	1931	0,52	0,49	5,75	0,55	7914.457613_A	2021	Ribeirão Preto
0	0	0,65	336	1931	0,52	0,49	5,75	0,55	7914.457613_A	2021	Ribeirão Preto
0	0	0,65	336	1931	0,52	0,49	5,75	0,55	7914.457613_A	2021	Ribeirão Preto
0	0	0,65	336	1931	0,52	0,49	5,75	0,55	7914.457613_A	2021	Ribeirão Preto
0	0	0,65	336	1931	0,52	0,49	5,75	0,55	7914.457613_A	2021	Ribeirão Preto
0	0	0,65	336	1931	0,52	0,49	5,75	0,55	7914.457613_A	2021	Ribeirão Preto
0	0	0,65	336	1931	0,52	0,49	5,75	0,55	7914.457613_B	2021	Ribeirão Preto
0	0	0,65	336	1931	0,52	0,49	5,75	0,55	7914.457613_B	2021	Ribeirão Preto
0	0	0,65	336	1931	0,52	0,49	5,75	0,55	7914.457613_B	2021	Ribeirão Preto
0	0	0,65	336	1931	0,52	0,49	5,75	0,55	7914.457613_B	2021	Ribeirão Preto
0	0	0,65	336	1931	0,52	0,49	5,75	0,55	7914.457613_B	2021	Ribeirão Preto
0,82	0	0,875	380	1805	0,138	0,526	4,75	0,51	7914.446869	2022	Rio de Janeiro
0,82	0	0,875	380	1805	0,138	0,526	4,75	0,51	7914.446869	2022	Rio de Janeiro
0,82	0	0,875	380	1805	0,138	0,526	4,75	0,51	7914.446869	2022	Rio de Janeiro

f <sub>cm,k</sub> (MPa)	f <sub>ck</sub> (MPa)	agg_description	specified agg_fine	classification	manufacturer	cemente	macrofiber steel	macrofiber PP	microfiber PP	compensator
4,2	30	artificial/natural	rio		CSN	CP II E 40 RS	0,00	0,00	0,6	10
4,2	30	artificial/natural	rio		CSN	CP II E 40 RS	0,00	0,00	0,6	10
4,2	30	artificial/natural	rio		CSN	CP II E 40 RS	0,00	0,00	0,6	0
4,2	30	artificial/natural	rio		CSN	CP II E 40 RS	0,00	0,00	0,6	0
4,2	30	artificial/natural	rio		CSN	CP II E 40 RS	0,00	0,00	0,6	0
4,2	30	artificial/natural	rio		CSN	CP II E 40 RS	0,00	0,00	0,6	0
4,2	30	artificial/natural	rio		CSN	CP II E 40 RS	0,00	0,00	0,6	0
4,2	30	artificial/natural	rio		CSN	CP II E 40 RS	0,00	0,00	0,6	0
4,2	30	artificial/natural	rio		CSN	CP II E 40 RS	0,00	0,00	0,6	0
4,2	30	artificial/natural	rio		CSN	CP II E 40 RS	0,00	0,00	0,6	0
4,2	30	artificial/natural	rio		CSN	CP II E 40 RS	0,00	0,00	0,6	0
4,2	30	artificial/natural	rio		CSN	CP II E 40 RS	0,00	0,00	0,6	0
4,2	30	artificial/natural	rio		CSN	CP II E 40 RS	0,00	0,00	0,6	0
4,2	30	artificial/natural	rio		CSN	CP II E 40 RS	0,00	0,00	0,6	0
4,2	30	artificial/natural	rio		CSN	CP II E 40 RS	0,00	0,00	0,6	0
4,2	30	artificial/natural	rio		CSN	CP II E 40 RS	0,00	0,00	0,6	0
4,2	30	artificial/natural	rio		CSN	CP II E 40 RS	0,00	0,00	0,6	0
4,2	30	artificial/natural	rio		CSN	CP II E 40 RS	0,00	0,00	0,6	0
4,2	30	artificial/natural	rio		CSN	CP II E 40 RS	0,00	0,00	0,6	0
4,2	30	artificial/natural	rio		CSN	CP II E 40 RS	0,00	0,00	0,6	0
4,2	30	artificial/natural	rio		CSN	CP II E 40 RS	0,00	0,00	0,6	0
4,5	35	artificial/natural	cava	Gnaisse	LafargeHolcim	CP V ARI RS	0,00	5,50	0,6	0
4,5	35	artificial/natural	cava	Gnaisse	LafargeHolcim	CP V ARI RS	0,00	5,50	0,6	0
4,5	35	artificial/natural	cava	Gnaisse	LafargeHolcim	CP V ARI RS	0,00	5,50	0,6	0

agg (kg/m3)	aggregate (artificial/natural)	mortar (%)	a/c	w/c	Ref	Year	City	Region	Author (laboratory)	shrinkage (%)	dt (days)
1805	0,138	0,526	4,75	0,51	7914.446869	2022	Rio de Janeiro	Sudeste	Qualitec	-0,016	28
1805	0,138	0,526	4,75	0,51	7914.446869	2022	Rio de Janeiro	Sudeste	Qualitec	-0,028	56
1805	0,138	0,526	4,75	0,51	7914.446869	2022	Rio de Janeiro	Sudeste	Qualitec	0	0,708
1805	0,138	0,526	4,75	0,51	7914.446869	2022	Rio de Janeiro	Sudeste	Qualitec	-0,006	1
1805	0,138	0,526	4,75	0,51	7914.446869_A	2022	Rio de Janeiro	Sudeste	Qualitec	-0,012	2
1805	0,138	0,526	4,75	0,51	7914.446869_A	2022	Rio de Janeiro	Sudeste	Qualitec	-0,017	7
1805	0,138	0,526	4,75	0,51	7914.446869_A	2022	Rio de Janeiro	Sudeste	Qualitec	-0,021	14
1805	0,138	0,526	4,75	0,51	7914.446869_A	2022	Rio de Janeiro	Sudeste	Qualitec	-0,034	28
1805	0,138	0,526	4,75	0,51	7914.446869_A	2022	Rio de Janeiro	Sudeste	Qualitec	-0,046	56
1805	0,138	0,526	4,75	0,51	7914.446869_A	2022	Rio de Janeiro	Sudeste	Qualitec	0	0,67
1805	0,138	0,526	4,75	0,51	7914.446869_A	2022	Rio de Janeiro	Sudeste	Qualitec	0,005	1
1750	0,45	0,51	4,61	0,49	7914.443614	2021	Macae	Sudeste	Qualitec	0,012	2
1750	0,45	0,51	4,61	0,49	7914.443614	2021	Macae	Sudeste	Qualitec	0,016	7
1750	0,45	0,51	4,61	0,49	7914.443614	2021	Macae	Sudeste	Qualitec	-0,001	14
1750	0,45	0,51	4,61	0,49	7914.443614	2021	Macae	Sudeste	Qualitec	-0,008	28
1750	0,45	0,51	4,61	0,49	7914.443614	2021	Macae	Sudeste	Qualitec	-0,022	56
1750	0,45	0,51	4,61	0,49	7914.443614	2021	Macae	Sudeste	Qualitec	0	0,67
1750	0,45	0,51	4,61	0,49	7914.443614	2021	Macae	Sudeste	Qualitec	-0,009	1
1750	0,45	0,51	4,61	0,49	7914.443614_A	2021	Macae	Sudeste	Qualitec	-0,012	2



w/c	Ref	Year	City	Region	Author (laboratory)	shrinkage (%)	dt (days)	$f_{ctm,k}$ (Mpa)	$f_{ck}$ (Mpa)	agg_description	specified agg_fine
0,49	7914.443614_A	2021	Macae	Sudeste	Qualitec	-0,016	7	4,5	35	artificial/natural	cava
0,49	7914.443614_A	2021	Macae	Sudeste	Qualitec	-0,021	14	4,5	35	artificial/natural	cava
0,49	7914.443614_A	2021	Macae	Sudeste	Qualitec	-0,036	28	4,5	35	artificial/natural	cava
0,49	7914.443614_A	2021	Macae	Sudeste	Qualitec	-0,049	56	4,5	35	artificial/natural	cava
0,49	7914.443614_A	2021	Macae	Sudeste	Qualitec	0	0,67	4,5	35	artificial/natural	cava
0,49	7914.443614_A	2021	Macae	Sudeste	Qualitec	0,007	1	4,5	35	artificial/natural	cava
0,49	7914.4439717_1	2021	Rio de Janeiro	Sudeste	Qualitec	0,008	2	4,5	35	artificial/natural	cava
0,49	7914.439717_1	2021	Rio de Janeiro	Sudeste	Qualitec	0,011	7	4,5	35	artificial/natural	cava
0,49	7914.439717_1	2021	Rio de Janeiro	Sudeste	Qualitec	-0,004	14	4,5	35	artificial/natural	cava
0,49	7914.439717_1	2021	Rio de Janeiro	Sudeste	Qualitec	-0,017	28	4,5	35	artificial/natural	cava
0,49	7914.439717_1	2021	Rio de Janeiro	Sudeste	Qualitec	-0,028	56	4,5	35	artificial/natural	cava
0,49	7914.439717_1	2021	Rio de Janeiro	Sudeste	Qualitec	0	0,58	4,5	35	artificial/natural	rio
0,49	7914.439717_1	2021	Rio de Janeiro	Sudeste	Qualitec	0,004	1	4,5	35	artificial/natural	rio
0,49	7914.439717_A1	2021	Rio de Janeiro	Sudeste	Qualitec	-0,007	2	4,5	35	artificial/natural	rio
0,49	7914.439717_A1	2021	Rio de Janeiro	Sudeste	Qualitec	-0,01	7	4,5	35	artificial/natural	rio
0,49	7914.439717_A1	2021	Rio de Janeiro	Sudeste	Qualitec	-0,018	14	4,5	35	artificial/natural	rio
0,49	7914.439717_A1	2021	Rio de Janeiro	Sudeste	Qualitec	-0,028	28	4,5	35	artificial/natural	rio
0,49	7914.439717_A1	2021	Rio de Janeiro	Sudeste	Qualitec	-0,037	56	4,5	35	artificial/natural	rio
0,49	7914.439717_A1	2021	Rio de Janeiro	Sudeste	Qualitec	0	0,58	4,5	35	artificial/natural	rio



Region	Author (laboratory)	shrinkage (%)	dt (days)	$f_{ctm,k}$ (Mpa)	$f_{ck}$ (Mpa)	agg_description	specified agg_fine	classification agg	manufacturer	cement
Sudeste	Qualitec	-0,006	1	4,5	35	artificial/natural	rio		Nassau	CP III 40 RS
Sudeste	Qualitec	-0,012	2	4,5	35	artificial/natural	rio		Nassau	CP III 40 RS
Sudeste	Qualitec	-0,016	7	4,5	35	artificial/natural	rio		Nassau	CP III 40 RS
Sudeste	Qualitec	-0,024	14	4,5	35	artificial/natural	rio		Nassau	CP III 40 RS
Sudeste	Qualitec	-0,037	28	4,5	35	artificial/natural	rio		Nassau	CP III 40 RS
Sudeste	Qualitec	-0,049	56	4,5	35	artificial/natural	rio		Nassau	CP III 40 RS
Sudeste	Qualitec	0	0,75	4,5	35	artificial/natural	cava	Gnaisse	LafargeHolcim	CP V ARI RS
Sudeste	Qualitec	0,004	1	4,5	35	artificial/natural	cava	Gnaisse	LafargeHolcim	CP V ARI RS
Sudeste	Qualitec	0,007	2	4,5	35	artificial/natural	cava	Gnaisse	LafargeHolcim	CP V ARI RS
Sudeste	Qualitec	0,01	7	4,5	35	artificial/natural	cava	Gnaisse	LafargeHolcim	CP V ARI RS
Sudeste	Qualitec	-0,005	14	4,5	35	artificial/natural	cava	Gnaisse	LafargeHolcim	CP V ARI RS
Sudeste	Qualitec	-0,014	28	4,5	35	artificial/natural	cava	Gnaisse	LafargeHolcim	CP V ARI RS
Sudeste	Qualitec	-0,025	56	4,5	35	artificial/natural	cava	Gnaisse	LafargeHolcim	CP V ARI RS
Sudeste	Qualitec	0	0,75	4,5	35	artificial/natural	cava	Gnaisse	LafargeHolcim	CP V ARI RS
Sudeste	Qualitec	-0,004	1	4,5	35	artificial/natural	cava	Gnaisse	LafargeHolcim	CP V ARI RS
Sudeste	Qualitec	-0,009	2	4,5	35	artificial/natural	cava	Gnaisse	LafargeHolcim	CP V ARI RS
Sudeste	Qualitec	-0,012	7	4,5	35	artificial/natural	cava	Gnaisse	LafargeHolcim	CP V ARI RS
Sudeste	Qualitec	-0,018	14	4,5	35	artificial/natural	cava	Gnaisse	LafargeHolcim	CP V ARI RS
Sudeste	Qualitec	-0,028	28	4,5	35	artificial/natural	cava	Gnaisse	LafargeHolcim	CP V ARI RS





	agg (kg/m3)	aggregate (artificial/natural)	mortar (%)	a/c	w/c	Ref	Year	City	Region	Author (laboratory)	shrinkage (%)	dt (days)
1714	0,3	0,54	4,39	0,47	7914.455585	2022	São Gonçalo	Sudeste	Qualitec	-0,04	56	
1714	0,3	0,54	4,39	0,47	7914.455585	2022	São Gonçalo	Sudeste	Qualitec	0	0	
1714	0,3	0,54	4,39	0,47	7914.455585	2022	São Gonçalo	Sudeste	Qualitec	0,009	1	
1714	0,3	0,54	4,39	0,47	7914.455585_A	2022	São Gonçalo	Sudeste	Qualitec	0,016	2	
1714	0,3	0,54	4,39	0,47	7914.455585_A	2022	São Gonçalo	Sudeste	Qualitec	0,031	7	
1714	0,3	0,54	4,39	0,47	7914.455585_A	2022	São Gonçalo	Sudeste	Qualitec	0,03	14	
1714	0,3	0,54	4,39	0,47	7914.455585_A	2022	São Gonçalo	Sudeste	Qualitec	0,001	28	
1714	0,3	0,54	4,39	0,47	7914.455585_A	2022	São Gonçalo	Sudeste	Qualitec	-0,025	56	
1714	0,3	0,54	4,39	0,47	7914.455585_A	2022	São Gonçalo	Sudeste	Qualitec	0	0	
1714	0,3	0,54	4,39	0,47	7914.455585_A	2022	São Gonçalo	Sudeste	Qualitec	-0,01	1	
1714	0,3	0,54	4,39	0,47	7914.455585_A	2022	São Gonçalo	Sudeste	Qualitec	-0,014	2	
1747	0,2	0,5	4,72	0,5	7914.455846_A	2022	São Gonçalo	Sudeste	Qualitec	-0,018	7	
1747	0,2	0,5	4,72	0,5	7914.455846_A	2022	São Gonçalo	Sudeste	Qualitec	-0,031	14	
1747	0,2	0,5	4,72	0,5	7914.455846_A	2022	São Gonçalo	Sudeste	Qualitec	-0,039	28	
1747	0,2	0,5	4,72	0,5	7914.455846_A	2022	São Gonçalo	Sudeste	Qualitec	-0,056	56	
1747	0,2	0,5	4,72	0,5	7914.455846_A	2022	São Gonçalo	Sudeste	Qualitec	0	0,708	
1747	0,2	0,5	4,72	0,5	7914.455846_A	2022	São Gonçalo	Sudeste	Qualitec	0,008	1	
1747	0,2	0,5	4,72	0,5	7914.455846_A	2022	São Gonçalo	Sudeste	Qualitec	-0,005	2	
1747	0,2	0,5	4,72	0,5	7914.455846	2022	São Gonçalo	Sudeste	Qualitec	-0,01	7	



w/c	Ref	Year	City	Region	Author (laboratory)	shrinkage (%)	dt (days)	$f_{ctm,k}$ (Mpa)	$f_{ck}$ (Mpa)	agg_description	specified agg_fine
0,5	7914.455846	2022	São Gonçalo	Sudeste	Qualitec	-0,017	14	4,5	35	artificial/natural	cava
0,5	7914.455846	2022	São Gonçalo	Sudeste	Qualitec	-0,023	28	4,5	35	artificial/natural	cava
0,5	7914.455846	2022	São Gonçalo	Sudeste	Qualitec	-0,029	56	4,5	35	artificial/natural	cava
0,5	7914.455846	2022	São Gonçalo	Sudeste	Qualitec	0	0,708	4,5	35	artificial/natural	cava
0,5	7914.455846	2022	São Gonçalo	Sudeste	Qualitec	-0,009	1	4,5	35	artificial/natural	cava
0,54	7914.456438_A	2022	Cajamar	Sudeste	Qualitec	-0,014	2	4,5	35	artificial/natural	cava
0,54	7914.456438_A	2022	Cajamar	Sudeste	Qualitec	-0,021	7	4,5	35	artificial/natural	cava
0,54	7914.456438_A	2022	Cajamar	Sudeste	Qualitec	-0,027	14	4,5	35	artificial/natural	cava
0,54	7914.456438_A	2022	Cajamar	Sudeste	Qualitec	-0,032	28	4,5	35	artificial/natural	cava
0,54	7914.456438_A	2022	Cajamar	Sudeste	Qualitec	-0,044	56	4,5	35	artificial/natural	cava
0,54	7914.456438_A	2022	Cajamar	Sudeste	Qualitec	0	0,75	4,5	35	artificial/natural	cava
0,54	7914.456438_A	2022	Cajamar	Sudeste	Qualitec	0,003	1	4,5	35	artificial/natural	cava
0,54	7914.456438_B	2022	Cajamar	Sudeste	Qualitec	-0,005	2	4,5	35	artificial/natural	cava
0,54	7914.456438_B	2022	Cajamar	Sudeste	Qualitec	-0,009	7	4,5	35	artificial/natural	cava
0,54	7914.456438_B	2022	Cajamar	Sudeste	Qualitec	-0,015	14	4,5	35	artificial/natural	cava
0,54	7914.456438_B	2022	Cajamar	Sudeste	Qualitec	-0,02	28	4,5	35	artificial/natural	cava
0,54	7914.456438_B	2022	Cajamar	Sudeste	Qualitec	-0,031	56	4,5	35	artificial/natural	cava
0,54	7914.456438_B	2022	Cajamar	Sudeste	Qualitec	0	0,708	4,5	35	artificial/natural	cava
0,54	7914.456438_B	2022	Cajamar	Sudeste	Qualitec	-0,009	1	4,5	35	artificial/natural	cava



Region	Author (laboratory)	shrinkage (%)	dt (days)	$f_{ctm,k}$ (Mpa)	$f_{ck}$ (Mpa)	agg_description	specified agg_fine	classification agg	manufacturer	cement
Sudeste	Qualitec	-0,012	2	4,5	35	artificial/natural	cava	Gnaisse	LafargeHolcim	CP V ARI RS
Sudeste	Qualitec	-0,015	7	4,5	35	artificial/natural	cava	Gnaisse	LafargeHolcim	CP V ARI RS
Sudeste	Qualitec	-0,018	14	4,5	35	artificial/natural	cava	Gnaisse	LafargeHolcim	CP V ARI RS
Sudeste	Qualitec	-0,025	28	4,5	35	artificial/natural	cava	Gnaisse	LafargeHolcim	CP V ARI RS
Sudeste	Qualitec	-0,039	56	4,5	35	artificial/natural	cava	Gnaisse	LafargeHolcim	CP V ARI RS
Sudeste	Qualitec	0	0,67			artificial/natural			Votorantim	CP II F 40
Sudeste	Qualitec	0,006	1			artificial/natural			Votorantim	CP II F 40
Sudeste	Qualitec	0,009	2			artificial/natural			Votorantim	CP II F 40
Sudeste	Qualitec	0,012	7			artificial/natural			Votorantim	CP II F 40
Sudeste	Qualitec	-0,003	14			artificial/natural			Votorantim	CP II F 40
Sudeste	Qualitec	-0,014	28			artificial/natural			Votorantim	CP II F 40
Sudeste	Qualitec	-0,031	56			artificial/natural			Votorantim	CP II F 40
Sudeste	Qualitec	0	0,67			artificial/natural			Votorantim	CP II F 40
Sudeste	Qualitec	0,006	1			artificial/natural			Votorantim	CP II F 40
Sudeste	Qualitec	0,01	2			artificial/natural			Votorantim	CP II F 40
Sudeste	Qualitec	0,014	7			artificial/natural			Votorantim	CP II F 40
Sudeste	Qualitec	-0,001	14			artificial/natural			Votorantim	CP II F 40
Sudeste	Qualitec	-0,007	28			artificial/natural			Votorantim	CP II F 40
Sudeste	Qualitec	-0,028	56			artificial/natural			Votorantim	CP II F 40

	super ranger	mid ranger	multifunctional	c	agg	aggregate	mortar	a/c	w/c	Ref	Year	City
				(kg/m3)	(kg/m3)	(artificial/natural)	(%)					
0	0,5	0,3	341	1890	0,3	0,5	5,54	0,54	7914.456438	2022	Cajamar	
0	0,5	0,3	341	1890	0,3	0,5	5,54	0,54	7914.456438	2022	Cajamar	
0	0,5	0,3	341	1890	0,3	0,5	5,54	0,54	7914.456438	2022	Cajamar	
0	0,5	0,3	341	1890	0,3	0,5	5,54	0,54	7914.456438	2022	Cajamar	
0	0,5	0,3	341	1890	0,3	0,5	5,54	0,54	7914.456438	2022	Cajamar	
0	0,5	0,3	341	1890	0,3	0,5	5,54	0,54	7914.456438	2022	Cajamar	
0	0,5	0,3	341	1890	0,3	0,5	5,54	0,54	7914.456438	2022	Cajamar	
0	0,5	0,3	341	1890	0,3	0,5	5,54	0,54	7914.456438	2022	Cajamar	
0,8	0	0,4	339	1923	0,3	0,436	5,67	0,6	7914.456807	2022	Morumbi	
0,8	0	0,4	339	1923	0,3	0,436	5,67	0,6	7914.456807	2022	Morumbi	
0,8	0	0,4	339	1923	0,3	0,436	5,67	0,6	7914.456807	2022	Morumbi	
0,8	0	0,4	339	1923	0,3	0,436	5,67	0,6	7914.456807	2022	Morumbi	
0,8	0	0,4	339	1923	0,3	0,436	5,67	0,6	7914.456807	2022	Morumbi	
0,8	0	0,4	339	1923	0,3	0,436	5,67	0,6	7914.456807	2022	Morumbi	
0,8	0	0,4	339	1923	0,3	0,436	5,67	0,6	7914.456807	2022	Morumbi	
0,8	0	0,4	339	1923	0,3	0,436	5,67	0,6	7914.456807	2022	Morumbi	
0,8	0	0,4	339	1923	0,3	0,436	5,67	0,6	7914.456807	2022	Morumbi	
0,8	0	0,4	339	1923	0,3	0,436	5,67	0,6	7914.456807	2022	Morumbi	
0,8	0	0,4	339	1923	0,3	0,436	5,67	0,6	7914.456807_A	2022	Morumbi	
0,8	0	0,4	339	1923	0,3	0,436	5,67	0,6	7914.456807_A	2022	Morumbi	
0,8	0	0,4	339	1923	0,3	0,436	5,67	0,6	7914.456807_A	2022	Morumbi	
0,8	0	0,4	339	1923	0,3	0,436	5,67	0,6	7914.456807_A	2022	Morumbi	

f <sub>cm,k</sub> (MPa)	f <sub>ck</sub> (MPa)	agg_description	specified agg_fine	classification agg	manufacturer	cemente	macrofiber steel	macrofiber PP	microfiber	compensator
artificial/natural		Votorantim	CP II F 40	25,00	0,00	0,6			0	0
artificial/natural		Votorantim	CP II F 40	25,00	0,00	0,6			0	0
artificial/natural		Votorantim	CP II F 40	25,00	0,00	0,6			0	0
artificial/natural		Votorantim	CP II F 40	25,00	0,00	0,6			0	0
artificial/natural		Votorantim	CP II F 40	25,00	0,00	0,6			0	0
artificial/natural		Votorantim	CP II F 40	25,00	0,00	0,6			0	0
artificial/natural		Votorantim	CP II F 40	25,00	0,00	0,6			0	0
artificial/natural		Votorantim	CP II E 40	0,00	0,00	0,6			25	
artificial/natural		Votorantim	CP II E 40	0,00	0,00	0,6			25	
artificial/natural		Votorantim	CP II E 40	0,00	0,00	0,6			25	
artificial/natural		Votorantim	CP II E 40	0,00	0,00	0,6			25	
artificial/natural		Votorantim	CP II E 40	0,00	0,00	0,6			25	
artificial/natural		Votorantim	CP II E 40	0,00	0,00	0,6			25	
artificial/natural		Votorantim	CP II E 40	0,00	0,00	0,6			25	
artificial/natural		Votorantim	CP II E 40	0,00	0,00	0,6			25	
artificial/natural		Votorantim	CP II E 40	0,00	0,00	0,6			25	
artificial/natural		Votorantim	CP II E 40	0,00	0,00	0,6			25	
artificial/natural		Votorantim	CP II E 40	0,00	0,00	0,6			0	0
artificial/natural		Votorantim	CP II E 40	0,00	0,00	0,6			0	0
artificial/natural		Votorantim	CP II E 40	0,00	0,00	0,6			0	0
artificial/natural		Votorantim	CP II E 40	0,00	0,00	0,6			0	0
artificial/natural		Votorantim	CP II E 40	0,00	0,00	0,6			0	0

	agg (kg/m3)	aggregate (artificial/natural)	mortar (%)	a/c	w/c	Ref	Year	City	Region	Author (laboratory)	shrinkage (%)	dt (days)
1923	0,3	0,436	5,67	0,6	7914.456807_A	2022	Morumbi	Sudeste	Qualitec	0	0,67	
1923	0,3	0,436	5,67	0,6	7914.456807_A	2022	Morumbi	Sudeste	Qualitec	-0,006	1	
1781	0	0,51	4,57	0,49	2021/0710	2021		Concretus		-0,009	2	
1781	0	0,51	4,57	0,49	2021/0710	2021		Concretus		-0,015	7	
1781	0	0,51	4,57	0,49	2021/0710	2021		Concretus		-0,019	14	
1781	0	0,51	4,57	0,49	2021/0710	2021		Concretus		-0,026	28	
1781	0	0,51	4,57	0,49	2021/0710	2021		Concretus		-0,041	56	
1781	0	0,51	4,57	0,49	2021/0710	2021		Concretus		0	0,708	
1781	0	0,51	4,57	0,49	2021/0710	2021		Concretus		0,009	1	
1781	0	0,51	4,57	0,49	2021/0710	2021		Concretus		0,015	2	
1781	0	0,51	4,57	0,49	2021/0710	2021		Concretus		0,021	7	
1781	0	0,51	4,57	0,49	2021/0709	2021		Concretus		0,004	14	
1781	0	0,51	4,57	0,49	2021/0709	2021		Concretus		-0,004	28	
1781	0	0,51	4,57	0,49	2021/0709	2021		Concretus		-0,014	56	
1781	0	0,51	4,57	0,49	2021/0709	2021		Concretus		0	0,75	
1781	0	0,51	4,57	0,49	2021/0709	2021		Concretus		-0,005	1	
1781	0	0,51	4,57	0,49	2021/0709	2021		Concretus		-0,009	2	
1781	0	0,51	4,57	0,49	2021/0709	2021		Concretus		-0,017	7	
1781	0	0,51	4,57	0,49	2021/0709	2021		Concretus		-0,024	14	



w/c	Ref	Year	City	Region	Author (laboratory)	shrinkage (%)	dt (days)	$f_{ctm,k}$ (Mpa)	$f_{ck}$ (Mpa)	agg_description	specified agg_fine
0,49	2021/0709	2021			Concretus	-0,036	28			artificial/natural	
0,49	2021/0716	2021			Concretus	-0,043	56			artificial/natural	
0,49	2021/0716	2021			Concretus	0	1			0	
0,49	2021/0716	2021			Concretus	0,015	2			0	
0,49	2021/0716	2021			Concretus	0,02	4			0	
0,49	2021/0716	2021			Concretus	0,023	7			0	
0,49	2021/0716	2021			Concretus	0,018	11			0	
0,49	2021/0716	2021			Concretus	0,008	14			0	
0,49	2021/0716	2021			Concretus	0,004	21			0	
0,49	2021/0716	2021			Concretus	-0,002	28			0	
0,47	2021/0715	2021			Concretus	-0,008	56			0	
0,47	2021/0715	2021			Concretus	0	1			0	
0,47	2021/0715	2021			Concretus	0,013	2			0	
0,47	2021/0715	2021			Concretus	0,016	4			0	
0,47	2021/0715	2021			Concretus	0,018	7			0	
0,47	2021/0715	2021			Concretus	0,014	11			0	
0,47	2021/0715	2021			Concretus	0,004	14			0	
0,47	2021/0715	2021			Concretus	-0,001	21			0	
0,47	2021/0715	2021			Concretus	-0,006	28			0	



Region	Author (laboratory)	shrinkage (%)	dt (days)	$f_{ctm,k}$ (Mpa)	$f_{ck}$ (Mpa)	agg_description	specified agg_fine	classification agg	manufacturer	cement
Concretus		-0,013	56				0		Votorantim	CP II Z 32
Concretus		0	1				0		Votorantim	CP II Z 32
Concretus		0,009	2				0		Votorantim	CP II Z 32
Concretus		0,013	4				0		Votorantim	CP II Z 32
Concretus		0,014	7				0		Votorantim	CP II Z 32
Concretus		0,004	11				0		Votorantim	CP II Z 32
Concretus		-0,002	14				0		Votorantim	CP II Z 32
Concretus		-0,006	21				0		Votorantim	CP II Z 32
Concretus		-0,01	28				0		Votorantim	CP II Z 32
Sudeste	Qualitec	-0,023	56				0		Votorantim	CP II Z 32
Sudeste	Qualitec	0	1				0		Votorantim	CP II Z 32
Sudeste	Qualitec	0,006	2				0		Votorantim	CP II Z 32
Sudeste	Qualitec	0,007	4				0		Votorantim	CP II Z 32
Sudeste	Qualitec	0,008	7				0		Votorantim	CP II Z 32
Sudeste	Qualitec	-0,002	11				0		Votorantim	CP II Z 32
Sudeste	Qualitec	-0,008	14				0		Votorantim	CP II Z 32
Sudeste	Qualitec	-0,013	21				0		Votorantim	CP II Z 32
Sudeste	Qualitec	-0,015	28				0		Votorantim	CP II Z 32
Sudeste	Qualitec	-0,022	56				0		Votorantim	CP II Z 32



$f_{ctm,k}$ (Mpa)	$f_{ck}$ (Mpa)	agg_description	specified agg_fine	classification agg	manufacturer	cement	macrofiber steel	macrofiber PP	macrofiber PP	microfiber	compensator
0	0	Votorantim	CP II Z 32	0,00	5,65	0	5,65	0	0	15	15
0	0	Votorantim	CP II Z 32	0,00	5,65	0	5,65	0	0	15	15
0	0	Votorantim	CP II Z 32	0,00	5,65	0	5,65	0	0	15	15
0	0	Votorantim	CP II Z 32	0,00	5,65	0	5,65	0	0	15	15
0	0	Votorantim	CP II Z 32	0,00	5,65	0	5,65	0	0	15	15
0	0	Votorantim	CP II Z 32	0,00	5,65	0	5,65	0	0	15	15
0	0	Votorantim	CP II Z 32	0,00	5,65	0	5,65	0	0	15	15
0	0	LafargeHolcim	CP V ARI RS	25,00	0,00	0,00	0,00	0,00	0,6	12,5	12,5
4,2	30	artificial/natural	LafargeHolcim	CP V ARI RS	25,00	0,00	0,00	0,00	0,6	12,5	12,5
4,2	30	artificial/natural	LafargeHolcim	CP V ARI RS	25,00	0,00	0,00	0,00	0,6	12,5	12,5
4,2	30	artificial/natural	LafargeHolcim	CP V ARI RS	25,00	0,00	0,00	0,00	0,6	12,5	12,5
4,2	30	artificial/natural	LafargeHolcim	CP V ARI RS	25,00	0,00	0,00	0,00	0,6	12,5	12,5
4,2	30	artificial/natural	LafargeHolcim	CP V ARI RS	25,00	0,00	0,00	0,00	0,6	12,5	12,5
4,2	30	artificial/natural	LafargeHolcim	CP V ARI RS	25,00	0,00	0,00	0,00	0,6	12,5	12,5
4,2	30	artificial/natural	LafargeHolcim	CP V ARI RS	25,00	0,00	0,00	0,00	0,6	12,5	12,5
4,2	30	artificial/natural	LafargeHolcim	CP V ARI RS	25,00	0,00	0,00	0,00	0,6	10	10
4,2	30	artificial/natural	LafargeHolcim	CP V ARI RS	25,00	0,00	0,00	0,00	0,6	10	10
4,2	30	artificial/natural	LafargeHolcim	CP V ARI RS	25,00	0,00	0,00	0,00	0,6	10	10

	agg (kg/m3)	aggregate (artificial/natural)	mortar (%)	a/c	w/c	Ref	Year	City	Region	Author (laboratory)	shrinkage (%)	dt (days)
1760	0,3	0,49	5,24	0,55	7914.424526	2021	Paulinia	Sudeste	Qualitec	0	1	
1760	0,3	0,49	5,24	0,55	7914.424526	2021	Paulinia	Sudeste	Qualitec	0,018	2	
1760	0,3	0,49	5,24	0,55	7914.424526	2021	Paulinia	Sudeste	Qualitec	0,023	4	
1760	0,3	0,49	5,24	0,55	7914.424526	2021	Paulinia	Sudeste	Qualitec	0,026	7	
1760	0,3	0,49	5,24	0,55	7914.424526-3	2021	Paulinia	Sudeste	Qualitec	0,02	11	
1760	0,3	0,49	5,24	0,55	7914.424526-3	2021	Paulinia	Sudeste	Qualitec	0,015	14	
1760	0,3	0,49	5,24	0,55	7914.424526-3	2021	Paulinia	Sudeste	Qualitec	0,01	21	
1760	0,3	0,49	5,24	0,55	7914.424526-3	2021	Paulinia	Sudeste	Qualitec	0,004	28	
1760	0,3	0,49	5,24	0,55	7914.424526-3	2021	Paulinia	Sudeste	Qualitec	-0,002	56	
1760	0,3	0,49	5,24	0,55	7914.424526-3	2021	Paulinia	Sudeste	Qualitec	0	0,625	
1760	0,3	0,49	5,24	0,55	7914.424526-3	2021	Paulinia	Sudeste	Qualitec	0,014	1	
1914	0,4	0,5	5,63	0,54	7914.460592_B	2022	Cajamar	Sudeste	Qualitec	0,015	2	
1914	0,4	0,5	5,63	0,54	7914.460592_B	2022	Cajamar	Sudeste	Qualitec	0,015	7	
1914	0,4	0,5	5,63	0,54	7914.460592_B	2022	Cajamar	Sudeste	Qualitec	0,006	14	
1914	0,4	0,5	5,63	0,54	7914.460592_B	2022	Cajamar	Sudeste	Qualitec	-0,017	28	
1914	0,4	0,5	5,63	0,54	7914.460592_B	2022	Cajamar	Sudeste	Qualitec	-0,028	56	
1914	0,4	0,5	5,63	0,54	7914.460592_B	2022	Cajamar	Sudeste	Qualitec	0	0,625	
1914	0,4	0,5	5,63	0,54	7914.460592_B	2022	Cajamar	Sudeste	Qualitec	0,006	1	
1914	0,4	0,5	5,63	0,54	7914.460592	2022	Cajamar	Sudeste	Qualitec	0,008	2	



w/c	Ref	Year	City	Region	Author (laboratory)	shrinkage (%)	dt (days)	$f_{ctm,k}$ (Mpa)	$f_{ck}$ (Mpa)	agg_description	specified agg_fine
0,54	7914.460592	2022	Cajamar	Sudeste	Qualitec	0,012	7	4,2	30	artificial/natural	
0,54	7914.460592	2022	Cajamar	Sudeste	Qualitec	0,008	14	4,2	30	artificial/natural	
0,54	7914.460592	2022	Cajamar	Sudeste	Qualitec	-0,022	28	4,2	30	artificial/natural	
0,54	7914.460592	2022	Cajamar	Sudeste	Qualitec	-0,031	56	4,2	30	artificial/natural	
0,54	7914.460592	2022	Cajamar	Sudeste	Qualitec	0	0,625	4,2	30	artificial/natural	
0,54	7914.460592	2022	Cajamar	Sudeste	Qualitec	-0,012	1	4,2	30	artificial/natural	
0,54	7914.460592_A	2022	Cajamar	Sudeste	Qualitec	-0,015	2	4,2	30	artificial/natural	
0,54	7914.460592_A	2022	Cajamar	Sudeste	Qualitec	-0,018	7	4,2	30	artificial/natural	
0,54	7914.460592_A	2022	Cajamar	Sudeste	Qualitec	-0,025	14	4,2	30	artificial/natural	
0,54	7914.460592_A	2022	Cajamar	Sudeste	Qualitec	-0,03	28	4,2	30	artificial/natural	
0,54	7914.460592_A	2022	Cajamar	Sudeste	Qualitec	-0,047	56	4,2	30	artificial/natural	
0,54	7914.460592_A	2022	Cajamar	Sudeste	Qualitec	0	0,67			artificial/natural	
0,54	7914.460592_A	2022	Cajamar	Sudeste	Qualitec	0,006	1			artificial/natural	
0,51	7914.459921	2022	Cajamar	Sudeste	Qualitec	0,01	2			artificial/natural	
0,51	7914.459921	2022	Cajamar	Sudeste	Qualitec	0,015	7			artificial/natural	
0,51	7914.459921	2022	Cajamar	Sudeste	Qualitec	-0,003	14			artificial/natural	
0,51	7914.459921	2022	Cajamar	Sudeste	Qualitec	-0,015	28			artificial/natural	
0,51	7914.459921	2022	Cajamar	Sudeste	Qualitec	-0,027	56			artificial/natural	
0,51	7914.459921	2022	Cajamar	Sudeste	Qualitec	0	0,67			artificial/natural	



Region	Author (laboratory)	shrinkage (%)	dt (days)	$f_{ck}$ (Mpa)	agg_description	specified agg_fine	classification agg	manufacturer	cement
Sudeste	Qualitec	-0,006	1		artificial/natural		CP II E 40 RS		
Sudeste	Qualitec	-0,011	2		artificial/natural		CP II E 40 RS		
Sudeste	Qualitec	-0,015	7		artificial/natural		CP II E 40 RS		
Sudeste	Qualitec	-0,02	14		artificial/natural		CP II E 40 RS		
Sudeste	Qualitec	-0,032	28		artificial/natural		CP II E 40 RS		
Sudeste	Qualitec	-0,04	56		artificial/natural		CP II E 40 RS		
Sudeste	Qualitec	0	0,67		artificial/natural		CP II E 40 RS		
Sudeste	Qualitec	0,006	1		artificial/natural		CP II E 40 RS		
Sudeste	Qualitec	0,009	2		artificial/natural		CP II E 40 RS		
Sudeste	Qualitec	0,013	7		artificial/natural		CP II E 40 RS		
Sudeste	Qualitec	-0,002	14		artificial/natural		CP II E 40 RS		
Sudeste	Qualitec	-0,011	28		artificial/natural		CP II E 40 RS		
Sudeste	Qualitec	-0,022	56		artificial/natural		CP II E 40 RS		
Sudeste	Qualitec	0	0,67		artificial/natural		CP V ARI RS		
Sudeste	Qualitec	-0,006	1		artificial/natural		Intercement	CP V ARI RS	
Sudeste	Qualitec	-0,011	2		artificial/natural		Intercement	CP V ARI RS	
Sudeste	Qualitec	-0,016	7		artificial/natural		Intercement	CP V ARI RS	
Sudeste	Qualitec	-0,02	14		artificial/natural		Intercement	CP V ARI RS	
Sudeste	Qualitec	-0,029	28		artificial/natural		Intercement	CP V ARI RS	

super ranger	mid ranger	multifunctional	c (kg/m3) (artificial/natural)	agg (kg/m3) (artificial/natural)	aggregate (%)	mortar a/c	w/c	Ref	Year	City
0	0	0,47	370	1770	0,15	0,586	4,78	0,51	7914.459921	2022
0	0	0,47	370	1770	0,15	0,586	4,78	0,51	7914.459921_A	2022
0	0	0,47	370	1770	0,15	0,586	4,78	0,51	7914.459921_A	2022
0	0	0,47	370	1770	0,15	0,586	4,78	0,51	7914.459921_A	2022
0	0	0,47	370	1770	0,15	0,586	4,78	0,51	7914.459921_A	2022
0	0	0,47	370	1770	0,15	0,586	4,78	0,51	7914.459921_A	2022
0	0	0,47	370	1770	0,15	0,586	4,78	0,51	7914.459921_A	2022
0	0	0,47	370	1770	0,15	0,586	4,78	0,51	7914.459921_A	2022
0	0	0,47	370	1770	0,15	0,586	4,78	0,51	7914.459921_A	2022
0	0	0,47	370	1770	0,15	0,586	4,78	0,51	7914.459921_A	2022
0	0	0,47	370	1770	0,15	0,586	4,78	0,51	7914.459921_A	2022
0,5	0	0,6	370	1780	0,5	0,587	4,81	0,5	7914.437641	2021
0,5	0	0,6	370	1780	0,5	0,587	4,81	0,5	7914.437641	2021
0,5	0	0,6	370	1780	0,5	0,587	4,81	0,5	7914.437641	2021
0,5	0	0,6	370	1780	0,5	0,587	4,81	0,5	7914.437641	2021
0,5	0	0,6	370	1780	0,5	0,587	4,81	0,5	7914.437641	2021
0,5	0	0,6	370	1780	0,5	0,587	4,81	0,5	7914.437641	2021
0,5	0	0,6	370	1780	0,5	0,587	4,81	0,5	7914.437641	2021
0,63	0	0,35	336	1811	0,42	0,56	5,39	0,55	7914.499801	2022
0,63	0	0,35	336	1811	0,42	0,56	5,39	0,55	7914.499801	2022
0,63	0	0,35	336	1811	0,42	0,56	5,39	0,55	7914.499801	2022
0,63	0	0,35	336	1811	0,42	0,56	5,39	0,55	7914.499801	2022

$f_{ctm,k}$ (Mpa)	$f_{ck}$ (Mpa)	agg_description	specified agg_fine	classification agg	manufacturer	cement	macrofiber steel	macrofiber PP	macrofiber	microfiber	compensator
		artificial/natural			Intercement	CP V ARI RS	0,00	6,00	0,6		0
		artificial/natural			Intercement	CP V ARI RS	0,00	6,00	0,6		10
		artificial/natural			Intercement	CP V ARI RS	0,00	6,00	0,6		10
		artificial/natural			Intercement	CP V ARI RS	0,00	6,00	0,6		10
		artificial/natural			Intercement	CP V ARI RS	0,00	6,00	0,6		10
		artificial/natural			Intercement	CP V ARI RS	0,00	6,00	0,6		10
		artificial/natural			Intercement	CP V ARI RS	0,00	6,00	0,6		10
		artificial/natural			Intercement	CP V ARI RS	0,00	6,00	0,6		10
		artificial/natural			Intercement	CP V ARI RS	0,00	6,00	0,6		10
		artificial/natural			Tupi	CP II E 40	0,00	0,00	0,6		10
4,5	35	artificial/natural			Tupi	CP II E 40	0,00	0,00	0,6		12,5
4,5	35	artificial/natural			Tupi	CP II E 40	0,00	0,00	0,6		12,5
4,5	35	artificial/natural			Tupi	CP II E 40	0,00	0,00	0,6		12,5
4,5	35	artificial/natural			Tupi	CP II E 40	0,00	0,00	0,6		12,5
4,5	35	artificial/natural			Tupi	CP II E 40	0,00	0,00	0,6		12,5
4,5	35	artificial/natural			Tupi	CP II E 40	0,00	0,00	0,6		12,5
4,5	35	artificial/natural			Tupi	CP II E 40	0,00	0,00	0,6		12,5
4,5	35	artificial/natural			Tupi	CP II E 40	0,00	0,00	0,6		12,5
4,5	35	artificial/natural			Tupi	CP II E 40	0,00	0,00	0,6		12,5
		artificial/natural			Tupi	CP II E 40	0,00	0,00	0,6		15
		artificial/natural			Tupi	CP II E 40	0,00	5,50	0,6		15
		artificial/natural			Tupi	CP II E 40	0,00	5,50	0,6		15
		artificial/natural			Tupi	CP II E 40	0,00	5,50	0,6		15

	agg (kg/m3)	aggregate (artificial/natural)	mortar (%)	a/c	w/c	Ref	Year	City	Region	Author (laboratory)	shrinkage (%)	dt (days)
1811	0,42	0,56	5,39	0,55	7914.499801	2022	São Paulo	Sudeste	Qualitec	-0,041	56	
1811	0,42	0,56	5,39	0,55	7914.499801	2022	São Paulo	Sudeste	Qualitec	0	0,625	
1811	0,42	0,56	5,39	0,55	7914.499801	2022	São Paulo	Sudeste	Qualitec	0,005	1	
1811	0,42	0,56	5,39	0,55	7914.499801_A	2022	São Paulo	Sudeste	Qualitec	0,008	2	
1811	0,42	0,56	5,39	0,55	7914.499801_A	2022	São Paulo	Sudeste	Qualitec	0,01	7	
1811	0,42	0,56	5,39	0,55	7914.499801_A	2022	São Paulo	Sudeste	Qualitec	-0,005	14	
1811	0,42	0,56	5,39	0,55	7914.499801_A	2022	São Paulo	Sudeste	Qualitec	-0,012	28	
1811	0,42	0,56	5,39	0,55	7914.499801_A	2022	São Paulo	Sudeste	Qualitec	-0,023	56	
1811	0,42	0,56	5,39	0,55	7914.499801_A	2022	São Paulo	Sudeste	Qualitec	0	0,67	
1811	0,42	0,56	5,39	0,55	7914.499801_A	2022	São Paulo	Sudeste	Qualitec	0,011	1	
1769	0,8	0,52	4,74	0,51	7914.468195	2022	Betim	Sudeste	Qualitec	0,015	2	
1769	0,8	0,52	4,74	0,51	7914.468195	2022	Betim	Sudeste	Qualitec	0,019	7	
1769	0,8	0,52	4,74	0,51	7914.468195	2022	Betim	Sudeste	Qualitec	-0,007	14	
1769	0,8	0,52	4,74	0,51	7914.468195	2022	Betim	Sudeste	Qualitec	-0,021	28	
1769	0,8	0,52	4,74	0,51	7914.468195	2022	Betim	Sudeste	Qualitec	-0,032	56	
1769	0,8	0,52	4,74	0,51	7914.468195	2022	Betim	Sudeste	Qualitec	0	0,75	
1769	0,8	0,52	4,74	0,51	7914.468195	2022	Betim	Sudeste	Qualitec	0,004	1	
1769	0,8	0,52	4,74	0,51	7914.468195_A	2022	Betim	Sudeste	Qualitec	0,01	2	
1769	0,8	0,52	4,74	0,51	7914.468195_A	2022	Betim	Sudeste	Qualitec	0,015	7	



w/c	Ref	Year	City	Region	Author (laboratory)	shrinkage (%)	dt (days)	$f_{ctm,k}$ (Mpa)	$f_{ck}$ (Mpa)	agg_description	specified agg_fine
0,51	7914.468195_A	2022	Betim	Sudeste	Qualitec	-0,001	14			artificial/natural	
0,51	7914.468195_A	2022	Betim	Sudeste	Qualitec	-0,013	28			artificial/natural	
0,51	7914.468195_A	2022	Betim	Sudeste	Qualitec	-0,03	56			artificial/natural	
0,51	7914.468195_A	2022	Betim	Sudeste	Qualitec	0	0,75			artificial/natural	
0,51	7914.468195_A	2022	Betim	Sudeste	Qualitec	-0,004	1			artificial/natural	
0,51	7914.468195_A	2022	Betim	Sudeste	Qualitec	-0,009	2			artificial/natural	
0,51	7914.468195_A	2022	Betim	Sudeste	Qualitec	-0,013	7			artificial/natural	
0,51	7914.468195_A	2022	Betim	Sudeste	Qualitec	-0,019	14			artificial/natural	
0,51	7914.468195_A	2022	Betim	Sudeste	Qualitec	-0,03	28			artificial/natural	
0,51	7914.468195_A	2022	Betim	Sudeste	Qualitec	-0,043	56			artificial/natural	
0,51	7914.468195_A	2022	Betim	Sudeste	Qualitec	0	0,67			artificial/natural	
0,51	7914.468195_A	2022	Betim	Sudeste	Qualitec	-0,005	1			artificial/natural	
0,54	7914.502517	2022	Palmas	Norte	Qualitec	-0,008	2			artificial/natural	
0,54	7914.502517	2022	Palmas	Norte	Qualitec	-0,012	7			artificial/natural	
0,54	7914.502517	2022	Palmas	Norte	Qualitec	-0,02	14			artificial/natural	
0,54	7914.502517	2022	Palmas	Norte	Qualitec	-0,028	28			artificial/natural	
0,54	7914.502517	2022	Palmas	Norte	Qualitec	-0,04	54			artificial/natural	
0,54	7914.502517	2022	Palmas	Norte	Qualitec	0	0,625			artificial/natural	
0,54	7914.502517	2022	Palmas	Norte	Qualitec	0,002	1			artificial/natural	



Region	Author (laboratory)	shrinkage (%)	dt (days)	$f_{ctm,k}$ (Mpa)	$f_{ck}$ (Mpa)	agg_description	specified agg_fine	classification agg	manufacturer	cemento
Norte	Qualitec	0,006	2			artificial/natural			CP V ARI RS	
Norte	Qualitec	0,008	7			artificial/natural			CP V ARI RS	
Norte	Qualitec	-0,006	14			artificial/natural			CP V ARI RS	
Norte	Qualitec	-0,015	28			artificial/natural			CP V ARI RS	
Norte	Qualitec	-0,028	56			artificial/natural			CP V ARI RS	
Norte	Qualitec	0	0,625			artificial/natural			CP V ARI RS	
Norte	Qualitec	0,004	1			artificial/natural			CP V ARI RS	
Centro-oeste	Qualitec	0,007	2			artificial/natural			CP V ARI RS	
Centro-oeste	Qualitec	0,011	7			artificial/natural			CP V ARI RS	
Centro-oeste	Qualitec	-0,003	14			artificial/natural			CP V ARI RS	
Centro-oeste	Qualitec	-0,011	28			artificial/natural			CP V ARI RS	
Centro-oeste	Qualitec	-0,023	56			artificial/natural			CP V ARI RS	
Centro-oeste	Qualitec	0	0,792			natural			CP II E 40	
Centro-oeste	Qualitec	-0,003	1			natural			CP II E 40	
Centro-oeste	Qualitec	-0,008	2			natural			CP II E 40	
Centro-oeste	Qualitec		7			natural			CP II E 40	
Centro-oeste	Qualitec		14			natural			CP II E 40	
Centro-oeste	Qualitec		28			natural			CP II E 40	
Centro-oeste	Qualitec		56			natural			CP II E 40	





	agg (kg/m3)	aggregate (artificial/natural)	mortar (%)	a/c	w/c	Ref	Year	City	Region	Author (laboratory)	shrinkage (%)	dt (days)
1793	0,6	0,54	4,98	0,54	7914.500150	2022	Ceilândia	Centro-oeste	Qualitec	0	0,75	
1793	0,6	0,54	4,98	0,54	7914.500150	2022	Ceilândia	Centro-oeste	Qualitec	0,003	1	
1792	0,41	0,557	5,03	0,52	7914.500440_A	2022	São Paulo	Sudeste	Qualitec	0,009	2	
1792	0,41	0,557	5,03	0,52	7914.500440_A	2022	São Paulo	Sudeste	Qualitec	7		
1792	0,41	0,557	5,03	0,52	7914.500440_A	2022	São Paulo	Sudeste	Qualitec	14		
1792	0,41	0,557	5,03	0,52	7914.500440_A	2022	São Paulo	Sudeste	Qualitec	28		
1792	0,41	0,557	5,03	0,52	7914.500440_A	2022	São Paulo	Sudeste	Qualitec	56		
1792	0,41	0,557	5,03	0,52	7914.500440_A	2022	São Paulo	Sudeste	Qualitec	0	0,75	
1792	0,41	0,557	5,03	0,52	7914.500440_A	2022	São Paulo	Sudeste	Qualitec	-0,005	1	
1792	0,41	0,557	5,03	0,52	7914.500440_A	2022	São Paulo	Sudeste	Qualitec	-0,011	2	
1792	0,41	0,557	5,03	0,52	7914.500440	2022	São Paulo	Sudeste	Qualitec	-0,016	7	
1792	0,41	0,557	5,03	0,52	7914.500440	2022	São Paulo	Sudeste	Qualitec	-0,026	14	
1792	0,41	0,557	5,03	0,52	7914.500440	2022	São Paulo	Sudeste	Qualitec	-0,035	28	
1792	0,41	0,557	5,03	0,52	7914.500440	2022	São Paulo	Sudeste	Qualitec	-0,045	56	
1792	0,41	0,557	5,03	0,52	7914.500440	2022	São Paulo	Sudeste	Qualitec	0	0,75	
1792	0,41	0,557	5,03	0,52	7914.500440	2022	São Paulo	Sudeste	Qualitec	0,003	1	
1745	0,2	0,52	4,72	0,52	7914.509071	2022	São Gonçalo	Sudeste	Qualitec	0,006	2	
1745	0,2	0,52	4,72	0,52	7914.509071	2022	São Gonçalo	Sudeste	Qualitec	0,009	7	
1745	0,2	0,52	4,72	0,52	7914.509071	2022	São Gonçalo	Sudeste	Qualitec	-0,003	14	

classification agg	manufacturer	cement	macrofiber steel	macrofiber PP	microfiber	compensator	super ranger	mid functional	c (kg/m3)
Ciplan	CP V ARI	0,00	5,63	0,6	12	0	0,8	0,2	360
Ciplan	CP V ARI	0,00	5,63	0,6	12	0	0,8	0,2	360
Tupi	CP II E 40 RS	0,00	0,00	0,6	15	0	0	0,75	356
Tupi	CP II E 40 RS	0,00	0,00	0,6	15	0	0	0,75	356
Tupi	CP II E 40 RS	0,00	0,00	0,6	15	0	0	0,75	356
Tupi	CP II E 40 RS	0,00	0,00	0,6	15	0	0	0,75	356
Tupi	CP II E 40 RS	0,00	0,00	0,6	15	0	0	0,75	356
Tupi	CP II E 40 RS	0,00	0,00	0,6	15	0	0	0,75	356
Tupi	CP II E 40 RS	0,00	0,00	0,6	15	0	0	0,75	356
Tupi	CP II E 40 RS	0,00	0,00	0,6	15	0	0	0,75	356
Tupi	CP II E 40 RS	0,00	0,00	0,6	15	0	0	0,75	356
Tupi	CP II E 40 RS	0,00	0,00	0,6	15	0	0	0,75	356
Nacional	CP III 40 RS	0,00	0,00	0,6	0	0	0	0,75	370
Nacional	CP III 40 RS	0,00	0,00	0,6	0	0	0	0,75	370
Nacional	CP III 40 RS	0,00	0,00	0,6	0	0	0	0,75	370

w/c	Ref	Year	City	Region	Author (laboratory)	shrinkage (%)	dt (days)	$f_{ctm,k}$ (Mpa)	$f_{ck}$ (Mpa)	agg_description	specified agg_fine
0,52	7914.509071	2022	São Gonçalo	Sudeste	Qualitec	-0,016	28	4,2	30	artificial/natural	cava
0,52	7914.509071	2022	São Gonçalo	Sudeste	Qualitec	-0,033	56	4,2	30	artificial/natural	cava
0,52	7914.509071	2022	São Gonçalo	Sudeste	Qualitec	0	0,708	4,2	30	artificial/natural	cava
0,52	7914.509071	2022	São Gonçalo	Sudeste	Qualitec	0,006	1	4,2	30	artificial/natural	cava
0,52	7914.509071_A	2022	São Gonçalo	Sudeste	Qualitec	0,011	2	4,2	30	artificial/natural	cava
0,52	7914.509071_A	2022	São Gonçalo	Sudeste	Qualitec	0,016	7	4,2	30	artificial/natural	cava
0,52	7914.509071_A	2022	São Gonçalo	Sudeste	Qualitec	0,001	14	4,2	30	artificial/natural	cava
0,52	7914.509071_A	2022	São Gonçalo	Sudeste	Qualitec	-0,014	28	4,2	30	artificial/natural	cava
0,52	7914.509071_A	2022	São Gonçalo	Sudeste	Qualitec	-0,029	56	4,2	30	artificial/natural	cava
0,52	7914.509071_A	2022	São Gonçalo	Sudeste	Qualitec	0	0,708	4,2	30	artificial/natural	cava
0,52	7914.491458_A	2022	Araraquara	Sudeste	Qualitec	-0,004	1	4,2	30	artificial/natural	cava
0,51	7914.491458_A	2022	Araraquara	Sudeste	Qualitec	-0,009	2	4,2	30	artificial/natural	cava
0,51	7914.491458_A	2022	Araraquara	Sudeste	Qualitec	-0,014	7	4,2	30	artificial/natural	cava
0,51	7914.491458_A	2022	Araraquara	Sudeste	Qualitec	-0,021	14	4,2	30	artificial/natural	cava
0,51	7914.491458_A	2022	Araraquara	Sudeste	Qualitec	-0,029	28	4,2	30	artificial/natural	cava
0,51	7914.491458_A	2022	Araraquara	Sudeste	Qualitec	-0,041	56	4,2	30	artificial/natural	cava
0,51	7914.491458_A	2022	Araraquara	Sudeste	Qualitec	0	0,75	35	35	artificial/natural	rio
0,51	7914.491458_A	2022	Araraquara	Sudeste	Qualitec	-0,005	1	35	35	artificial/natural	rio
0,51	7914.491458	2022	Araraquara	Sudeste	Qualitec	-0,012	2	35	35	artificial/natural	rio

macrofiber steel	macrofiber PP	microfiber	compensator	super ranger	mid multifunctional	c (kg/m3) (artificial/natural)	agg (kg/m3) (artificial/natural)	aggregate	mortar	a/c	
0,00	0,00	0,6	0	0	0,75	370	1745	0,2	0,52	4,72	
0,00	0,00	0,6	0	0	0,75	370	1745	0,2	0,52	4,72	
0,00	0,00	0,6	0	0	0,75	370	1745	0,2	0,52	4,72	
0,00	0,00	0,6	0	0	0,75	370	1745	0,2	0,52	4,72	
0,00	0,00	0,6	15	0	0,75	370	1745	0,2	0,52	4,72	
0,00	0,00	0,6	15	0	0,75	370	1745	0,2	0,52	4,72	
0,00	0,00	0,6	15	0	0,75	370	1745	0,2	0,52	4,72	
0,00	0,00	0,6	15	0	0,75	370	1745	0,2	0,52	4,72	
0,00	0,00	0,6	15	0	0,75	370	1745	0,2	0,52	4,72	
0,00	0,00	0,6	15	0	0,75	370	1745	0,2	0,52	4,72	
0,00	0,00	0,6	15	0	0,75	370	1745	0,2	0,52	4,72	
0,00	0,00	0,6	15	0	0,75	370	1745	0,2	0,52	4,72	
0,00	0,00	0,6	15	0	0,75	370	1745	0,2	0,52	4,72	
0,00	0,00	0,6	15	0	0,75	370	1745	0,2	0,52	4,72	
0,00	0,00	0,6	15	0	0,75	370	1745	0,2	0,52	4,72	
0,00	0,00	0,5	15	0,35	0	0,45	350	1828	0	0,52	5,22
0,00	0,00	0,5	15	0,35	0	0,45	350	1828	0	0,52	5,22
0,00	0,00	0,5	15	0,35	0	0,45	350	1828	0	0,52	5,22
0,00	0,00	0,5	15	0,35	0	0,45	350	1828	0	0,52	5,22
0,00	0,00	0,5	15	0,35	0	0,45	350	1828	0	0,52	5,22
0,00	0,00	0,5	15	0,35	0	0,45	350	1828	0	0,52	5,22
0,00	0,00	0,5	15	0,35	0	0,45	350	1828	0	0,52	5,22
0,00	0,00	0,5	15	0,35	0	0,45	350	1828	0	0,52	5,22
0,00	0,00	0,5	0	0,35	0	0,45	350	1828	0	0,52	5,22

Region	Author (laboratory)	shrinkage (%)	dt (days)	$f_{ctm,k}$ (Mpa)	$f_{ck}$ (Mpa)	agg_description	specified agg_fine	classification agg	manufacturer	cement
Sudeste	Qualitec	-0,018	7	35	artificial/natural	rio		Nacional	CP III 40 RS	
Sudeste	Qualitec	-0,022	14	35	artificial/natural	rio		Nacional	CP III 40 RS	
Sudeste	Qualitec		28	35	artificial/natural	rio		Nacional	CP III 40 RS	
Sudeste	Qualitec		56	35	artificial/natural	rio		Nacional	CP III 40 RS	
Sudeste	Qualitec	0	0,792	35	artificial/natural	rio		Nacional	CP III 40 RS	
Sudeste	Qualitec	0,005	1	35	artificial/natural	rio		Nacional	CP III 40 RS	
Sudeste	Qualitec	0,011	2	35	artificial/natural	rio		Nacional	CP III 40 RS	
Sudeste	Qualitec	0,015	7	35	artificial/natural	rio		Nacional	CP III 40 RS	
Sudeste	Qualitec	0,003	14	35	artificial/natural	rio		Nacional	CP III 40 RS	
Sudeste	Qualitec		28	35	artificial/natural	rio		Nacional	CP III 40 RS	
Sudeste	Qualitec		56	35	artificial/natural	rio		Nacional	CP III 40 RS	
Sudeste	Qualitec	0	0,67		natural	rio		Votorantim	CP II F 40	
Sudeste	Qualitec	0,004	1		natural	rio		Votorantim	CP II F 40	
Sudeste	Qualitec	0,008	2		natural	rio		Votorantim	CP II F 40	
Sudeste	Qualitec	0,013	7		natural	rio		Votorantim	CP II F 40	
Sudeste	Qualitec	-0,006	14		natural	rio		Votorantim	CP II F 40	
Sudeste	Qualitec	-0,017	28		natural	rio		Votorantim	CP II F 40	
Sudeste	Qualitec	-0,029	56		natural	rio		Votorantim	CP II F 40	
Sudeste	Qualitec	0	0,67		natural	rio		Votorantim	CP II F 40	

	super ranger	mid ranger	multifunctional	c (kg/m3) (artificial/natural)	agg (kg/m3) (artificial/natural)	aggregate (%)	mortar a/c	w/c	Ref	Year	City
0,35	0	0,45	350	1828	0	0,52	5,22	0,51	7914.491458	2022	Araraquara
0,35	0	0,45	350	1828	0	0,52	5,22	0,51	7914.491458	2022	Araraquara
0,35	0	0,45	350	1828	0	0,52	5,22	0,51	7914.491458	2022	Araraquara
0,35	0	0,45	350	1828	0	0,52	5,22	0,51	7914.491458	2022	Araraquara
0,35	0	0,45	350	1828	0	0,52	5,22	0,51	7914.491458	2022	Araraquara
0,35	0	0,45	350	1828	0	0,52	5,22	0,51	7914.491458	2022	Araraquara
0,63	0	0,7	336	1810	0,4	0,557	5,39	0,55	7914.500936	2022	São Paulo
0,63	0	0,7	336	1810	0,4	0,557	5,39	0,55	7914.500936	2022	São Paulo
0,63	0	0,7	336	1810	0,4	0,557	5,39	0,55	7914.500936	2022	São Paulo
0,63	0	0,7	336	1810	0,4	0,557	5,39	0,55	7914.500936	2022	São Paulo
0,63	0	0,7	336	1810	0,4	0,557	5,39	0,55	7914.500936	2022	São Paulo
0,63	0	0,7	336	1810	0,4	0,557	5,39	0,55	7914.500936	2022	São Paulo
0,63	0	0,7	336	1810	0,4	0,557	5,39	0,55	7914.500936	2022	São Paulo
0,63	0	0,7	336	1810	0,4	0,557	5,39	0,55	7914.500936	2022	São Paulo
0,63	0	0,7	336	1810	0,4	0,557	5,39	0,55	7914.500936	2022	São Paulo
0	0	0,7	336	1810	0,4	0,557	5,39	0,55	7914.497048_B	2022	São Paulo
0	0	0,7	336	1810	0,4	0,557	5,39	0,55	7914.497048_B	2022	São Paulo
0	0	0,7	336	1810	0,4	0,557	5,39	0,55	7914.497048_B	2022	São Paulo
0	0	0,7	336	1810	0,4	0,557	5,39	0,55	7914.497048_B	2022	São Paulo



	agg (kg/m3)	aggregate (artificial/natural)	mortar (%)	a/c	w/c	Ref	Year	City	Region	Author (laboratory)	shrinkage (%)	dt (days)
1810	0,4	0,557	5,39	0,55	7914.497048_B	2022	São Paulo	Sudeste	Qualitec	-0,004	1	
1811	0,42	0,56	5,39	0,55	7914.497048	2022	São Paulo	Sudeste	Qualitec	-0,008	2	
1811	0,42	0,56	5,39	0,55	7914.497048	2022	São Paulo	Sudeste	Qualitec	-0,015	7	
1811	0,42	0,56	5,39	0,55	7914.497048	2022	São Paulo	Sudeste	Qualitec	-0,023	14	
1811	0,42	0,56	5,39	0,55	7914.497048	2022	São Paulo	Sudeste	Qualitec	-0,031	28	
1811	0,42	0,56	5,39	0,55	7914.497048	2022	São Paulo	Sudeste	Qualitec	-0,043	56	
1811	0,42	0,56	5,39	0,55	7914.497048	2022	São Paulo	Sudeste	Qualitec	0	0,708	
1811	0,42	0,56	5,39	0,55	7914.497048	2022	São Paulo	Sudeste	Qualitec	-0,005	1	
1811	0,42	0,56	5,39	0,55	7914.497048_A	2022	São Paulo	Sudeste	Qualitec	-0,011	2	
1811	0,42	0,56	5,39	0,55	7914.497048_A	2022	São Paulo	Sudeste	Qualitec	-0,016	7	
1811	0,42	0,56	5,39	0,55	7914.497048_A	2022	São Paulo	Sudeste	Qualitec	-0,022	14	
1811	0,42	0,56	5,39	0,55	7914.497048_A	2022	São Paulo	Sudeste	Qualitec	-0,028	28	
1811	0,42	0,56	5,39	0,55	7914.497048_A	2022	São Paulo	Sudeste	Qualitec	0	0,75	
1811	0,42	0,56	5,39	0,55	7914.497048_A	2022	São Paulo	Sudeste	Qualitec	0,005	1	
1810	0,4	0,557	5,39	0,55	7914.500936	2022	São Paulo	Sudeste	Qualitec	0,008	2	
1810	0,4	0,557	5,39	0,55	7914.500936	2022	São Paulo	Sudeste	Qualitec	0,013	7	
1810	0,4	0,557	5,39	0,55	7914.500936	2022	São Paulo	Sudeste	Qualitec	-0,003	14	
1810	0,4	0,557	5,39	0,55	7914.500936	2022	São Paulo	Sudeste	Qualitec	-0,012	28	

classification agg	manufacturer	cement	macrofiber steel	macrofiber PP	microfiber	compensator	super ranger	mid functional	c (kg/m3)
Tupi	CP II E 40	0,00	0,00	0,6	15	0	0	0,7	336
Tupi	CP II E 40	0,00	5,50	0,6	0	0,63	0	0,35	336
Tupi	CP II E 40	0,00	5,50	0,6	0	0,63	0	0,35	336
Tupi	CP II E 40	0,00	5,50	0,6	0	0,63	0	0,35	336
Tupi	CP II E 40	0,00	5,50	0,6	0	0,63	0	0,35	336
Tupi	CP II E 40	0,00	5,50	0,6	0	0,63	0	0,35	336
Tupi	CP II E 40	0,00	5,50	0,6	0	0,63	0	0,35	336
Tupi	CP II E 40	0,00	5,50	0,6	0	0,63	0	0,35	336
Tupi	CP II E 40	0,00	5,50	0,6	0	0,63	0	0,35	336
Tupi	CP II E 40	0,00	5,50	0,6	15	0,63	0	0,35	336
Tupi	CP II E 40	0,00	5,50	0,6	15	0,63	0	0,35	336
Tupi	CP II E 40	0,00	5,50	0,6	15	0,63	0	0,35	336
Tupi	CP II E 40	0,00	5,50	0,6	15	0,63	0	0,35	336
Tupi	CP II E 40	0,00	5,50	0,6	15	0,63	0	0,35	336
Tupi	CP II E 40	0,00	5,50	0,6	15	0,63	0	0,35	336
Tupi	CP II E 40	0,00	5,50	0,6	15	0,63	0	0,35	336
Tupi	CP II E 40	0,00	5,50	0,6	15	0,63	0	0,35	336
Tupi	CP II E 40	0,00	5,50	0,6	15	0,63	0	0,35	336
Tupi	CP II E 40	0,00	5,50	0,6	15	0,63	0	0,35	336
Tupi	CP II E 40	0,00	5,50	0,6	15	0,63	0	0,35	336
Tupi	CP II E 40	0,00	5,50	0,6	15	0,63	0	0,35	336
Tupi	CP II E 40	0,00	0,00	0,6	0	0,63	0	0,7	336
Tupi	CP II E 40	0,00	0,00	0,6	0	0,63	0	0,7	336
Tupi	CP II E 40	0,00	0,00	0,6	0	0,63	0	0,7	336
Tupi	CP II E 40	0,00	0,00	0,6	0	0,63	0	0,7	336

w/c	Ref	Year	City	Region	Author (laboratory)	shrinkage (%)	dt (days)	$f_{ctm,k}$ (Mpa)	$f_{ck}$ (Mpa)	agg_description	specified agg_fine
0,55	7914.500936	2022	São Paulo	Sudeste	Qualitec	-0,034	56			artificial/natural	
0,55	7914.500936	2022	São Paulo	Sudeste	Qualitec	0	0,75			artificial/natural	
0,55	7914.500936	2022	São Paulo	Sudeste	Qualitec	-0,005	1			artificial/natural	
0,55	7914.496624	2022	São Paulo	Sudeste	Qualitec	-0,009	2			artificial/natural	
0,55	7914.496624	2022	São Paulo	Sudeste	Qualitec	-0,016	7			artificial/natural	
0,55	7914.496624	2022	São Paulo	Sudeste	Qualitec	-0,02	14			artificial/natural	
0,55	7914.496624	2022	São Paulo	Sudeste	Qualitec	-0,026	28			artificial/natural	
0,55	7914.496624	2022	São Paulo	Sudeste	Qualitec	-0,041	56			artificial/natural	
0,55	7914.496624	2022	São Paulo	Sudeste	Qualitec	0	0,75			artificial/natural	
0,55	7914.496624	2022	São Paulo	Sudeste	Qualitec	0,004	1			artificial/natural	
0,55	7914.496624_A	2022	São Paulo	Sudeste	Qualitec	0,011	2			artificial/natural	
0,55	7914.496624_A	2022	São Paulo	Sudeste	Qualitec	0,015	7			artificial/natural	
0,55	7914.496624_A	2022	São Paulo	Sudeste	Qualitec	0	14			artificial/natural	
0,55	7914.496624_A	2022	São Paulo	Sudeste	Qualitec	-0,009	28			artificial/natural	
0,55	7914.496624_A	2022	São Paulo	Sudeste	Qualitec	-0,03	56			artificial/natural	
0,55	7914.496624_A	2022	São Paulo	Sudeste	Qualitec	0	0,708			artificial/natural	
0,55	7914.496624_A	2022	São Paulo	Sudeste	Qualitec	-0,005	1			artificial/natural	
0,55	7914.500937	2022	São Paulo	Sudeste	Qualitec	-0,011	2			artificial/natural	
0,55	7914.500937	2022	São Paulo	Sudeste	Qualitec	-0,016	7			artificial/natural	

	macrofiber steel	macrofiber PP	microfiber	compensator	super ranger	mid multifunctional	c (kg/m3)	agg (kg/m3) (artificial/natural)	mortar (%)	a/c
0,00	0,00	0,6	0	0,63	0	0,7	336	1810	0,4	0,557 5,39
0,00	0,00	0,6	0	0,63	0	0,7	336	1810	0,4	0,557 5,39
0,00	0,00	0,6	0	0,63	0	0,7	336	1810	0,4	0,557 5,39
0,00	0,00	0,6	0	0	0	0,35	336	1810	0,42	0,55 5,39
0,00	0,00	0,6	0	0	0	0,35	336	1810	0,42	0,55 5,39
0,00	0,00	0,6	0	0	0	0,35	336	1810	0,42	0,55 5,39
0,00	0,00	0,6	0	0	0	0,35	336	1810	0,42	0,55 5,39
0,00	0,00	0,6	0	0	0	0,35	336	1810	0,42	0,55 5,39
0,00	0,00	0,6	0	0	0	0,35	336	1810	0,42	0,55 5,39
0,00	0,00	0,6	0	0	0	0,35	336	1810	0,42	0,55 5,39
0,00	0,00	0,6	0	0	0	0,35	336	1810	0,42	0,55 5,39
0,00	0,00	0,6	0	0	0	0,35	336	1810	0,42	0,55 5,39
0,00	0,00	0,6	0	0	0	0,35	336	1810	0,42	0,55 5,39
0,00	0,00	0,6	0	0	0	0,35	336	1810	0,42	0,55 5,39
0,00	0,00	0,6	15	0	0	0,35	336	1810	0,42	0,55 5,39
0,00	0,00	0,6	0,6	15	0	0,35	336	1810	0,42	0,55 5,39
0,00	0,00	0,6	0,6	15	0	0,35	336	1810	0,42	0,55 5,39
0,00	0,00	0,6	0,6	15	0	0,35	336	1810	0,42	0,55 5,39
0,00	0,00	0,6	0,6	15	0	0,35	336	1810	0,42	0,55 5,39
0,00	0,00	0,6	0,6	15	0	0,35	336	1810	0,42	0,55 5,39
0,00	0,00	0,6	0,6	15	0	0,35	336	1810	0,42	0,55 5,39
0,00	0,00	0,6	0,6	15	0	0,35	336	1811	0,42	0,56 5,39
0,00	5,50	0,6	15	0,63	0	0,35	336	1811	0,42	0,56 5,39

Region	Author (laboratory)	shrinkage (%)	dt (days)	$f_{ctm,k}$ (Mpa)	$f_{ck}$ (Mpa)	agg_description	specified agg_fine	classification agg	manufacturer	cement
Sudeste	Qualitec		14			artificial/natural			Tupi	CP II E 40
Sudeste	Qualitec		28			artificial/natural			Tupi	CP II E 40
Sudeste	Qualitec		56			artificial/natural			Tupi	CP II E 40
Sudeste	Qualitec	0	0,75			artificial/natural			Tupi	CP II E 40
Sudeste	Qualitec	-0,005	1			artificial/natural			Tupi	CP II E 40
Sudeste	Qualitec	-0,009	2			artificial/natural			Tupi	CP II E 40
Sudeste	Qualitec	-0,016	7			artificial/natural			Tupi	CP II E 40
Sudeste	Qualitec	-0,02	14			artificial/natural			Tupi	CP II E 40
Sudeste	Qualitec	-0,031	28			artificial/natural			Tupi	CP II E 40
Sudeste	Qualitec	-0,044	56			artificial/natural			Tupi	CP II E 40
Sudeste	Qualitec	0	0,75			artificial/natural			Tupi	CP II E 40
Sudeste	Qualitec	0,004	1			artificial/natural			Tupi	CP II E 40
Nordeste	Qualitec	0,01	2			artificial/natural			Tupi	CP II E 40
Nordeste	Qualitec	0,014	7			artificial/natural			Tupi	CP II E 40
Nordeste	Qualitec	-0,001	14			artificial/natural			Tupi	CP II E 40
Nordeste	Qualitec	-0,008	28			artificial/natural			Tupi	CP II E 40
Nordeste	Qualitec	-0,028	56			artificial/natural			Tupi	CP II E 40
Nordeste	Qualitec	0	0,75			artificial/natural			Tupi	CP II E 40
Nordeste	Qualitec	0,005	1			artificial/natural			Tupi	CP II E 40





agg (kg/m3)	aggregate (artificial/natural)	mortar (%)	a/c	w/c	Ref	Year	City	Region	Author (laboratory)	shrinkage (%)	dt (days)
1905	0	0,5	5,60	0,53	7914.496626	2022	Salvador	Nordeste	Qualitec	0,01	2
1905	0	0,5	5,60	0,53	7914.496626	2022	Salvador	Nordeste	Qualitec	0,016	7
1905	0	0,5	5,60	0,53	7914.496626	2022	Salvador	Nordeste	Qualitec		14
1905	0	0,5	5,60	0,53	7914.496626	2022	Salvador	Nordeste	Qualitec		28
1905	0	0,5	5,60	0,53	7914.496626	2022	Salvador	Nordeste	Qualitec		56
1905	0	0,5	5,60	0,53	7914.496626	2022	Salvador	Nordeste	Qualitec	0	0,75
1905	0	0,5	5,60	0,53	7914.496626	2022	Salvador	Nordeste	Qualitec	-0,005	1
1809	0,45	0,53	5,24	0,55	7914.496471_A	2022	Araçari guama	Sudeste	Qualitec	-0,009	2
1809	0,45	0,53	5,24	0,55	7914.496471_A	2022	Araçari guama	Sudeste	Qualitec	-0,016	7
1809	0,45	0,53	5,24	0,55	7914.496471_A	2022	Araçari guama	Sudeste	Qualitec	-0,02	14
1809	0,45	0,53	5,24	0,55	7914.496471_A	2022	Araçari guama	Sudeste	Qualitec		28
1809	0,45	0,53	5,24	0,55	7914.496471_A	2022	Araçari guama	Sudeste	Qualitec		56
1809	0,45	0,53	5,24	0,55	7914.496471_A	2022	Araçari guama	Sudeste	Qualitec	0	0,83
1809	0,45	0,53	5,24	0,55	7914.496471_A	2022	Araçari guama	Sudeste	Qualitec	0,002	1
1809	0,45	0,53	5,24	0,55	7914.496471_A	2022	Araçari guama	Sudeste	Qualitec	0,004	2
1809	0,45	0,53	5,24	0,55	7914.496471	2022	Araçari guama	Sudeste	Qualitec	0,009	7
1809	0,45	0,53	5,24	0,55	7914.496471	2022	Araçari guama	Sudeste	Qualitec	-0,003	14
1809	0,45	0,53	5,24	0,55	7914.496471	2022	Araçari guama	Sudeste	Qualitec	-0,014	28
1809	0,45	0,53	5,24	0,55	7914.496471	2022	Araçari guama	Sudeste	Qualitec	-0,036	56



w/c	Ref	Year	City	Region	Author (laboratory)	shrinkage (%)	dt (days)	$f_{ctm,k}$ (Mpa)	$f_{ck}$ (Mpa)	agg_description	specified agg_fine
0,55	7914.496471	2022	Araçariguama	Sudeste	Qualitec	0	0,792			natural	
0,55	7914.496471	2022	Araçariguama	Sudeste	Qualitec	-0,006	1			natural	
0,55	7914.496473_A	2022	Araçariguama	Sudeste	Qualitec	-0,012	2			natural	
0,55	7914.496473_A	2022	Araçariguama	Sudeste	Qualitec	-0,015	7			natural	
0,55	7914.496473_A	2022	Araçariguama	Sudeste	Qualitec	-0,02	14			natural	
0,55	7914.496473_A	2022	Araçariguama	Sudeste	Qualitec	-0,026	28			natural	
0,55	7914.496473_A	2022	Araçariguama	Sudeste	Qualitec	-0,041	56			natural	
0,55	7914.496473_A	2022	Araçariguama	Sudeste	Qualitec	0	0,792			artificial/natural	rio
0,55	7914.496473_A	2022	Araçariguama	Sudeste	Qualitec	0,003	1			artificial/natural	rio
0,55	7914.496473	2022	Araçariguama	Sudeste	Qualitec	0,008	2			artificial/natural	rio
0,55	7914.496473	2022	Araçariguama	Sudeste	Qualitec	0,014	7			artificial/natural	rio
0,55	7914.496473	2022	Araçariguama	Sudeste	Qualitec	-0,003	14			artificial/natural	rio
0,55	7914.496473	2022	Araçariguama	Sudeste	Qualitec	-0,013	28			artificial/natural	rio
0,55	7914.496473	2022	Araçariguama	Sudeste	Qualitec	-0,032	56			artificial/natural	rio
0,55	7914.496473	2022	Araçariguama	Sudeste	Qualitec	0	0,792			artificial/natural	rio
0,55	7914.496473	2022	Araçariguama	Sudeste	Qualitec	-0,003	1			artificial/natural	rio
0,61	7914.498740_B	2022	Campinas	Sudeste	Qualitec	-0,007	2			artificial/natural	rio
0,61	7914.498740_B	2022	Campinas	Sudeste	Qualitec	-0,012	7			artificial/natural	rio
0,61	7914.498740_B	2022	Campinas	Sudeste	Qualitec	-0,019	14			artificial/natural	rio

	macrofiber steel	macrofiber PP	microfiber	compensator	super ranger	mid multifunctional	c (kg/m3) (artificial/natural)	agg (kg/m3) (artificial/natural)	mortar (%)	a/c
0,00	5,50	0	0	0,5	0	0,4	345	1809	0,45	0,53
0,00	5,50	0	0	0,5	0	0,4	345	1809	0,45	0,53
0,00	5,50	0	12,5	0,5	0	0,4	345	1809	0,45	0,53
0,00	5,50	0	12,5	0,5	0	0,4	345	1809	0,45	0,53
0,00	5,50	0	12,5	0,5	0	0,4	345	1809	0,45	0,53
0,00	5,50	0	12,5	0,5	0	0,4	345	1809	0,45	0,53
0,00	5,50	0	12,5	0,5	0	0,4	345	1809	0,45	0,53
0,00	5,50	0	12,5	0,5	0	0,4	345	1809	0,45	0,53
0,00	5,50	0	12,5	0,5	0	0,4	345	1809	0,45	0,53
0,00	5,50	0	10	0,5	0	0,4	345	1809	0,45	0,53
0,00	5,50	0	10	0,5	0	0,4	345	1809	0,45	0,53
0,00	5,50	0	10	0,5	0	0,4	345	1809	0,45	0,53
0,00	5,50	0	10	0,5	0	0,4	345	1809	0,45	0,53
0,00	5,50	0	10	0,5	0	0,4	345	1809	0,45	0,53
0,00	5,50	0	10	0,5	0	0,4	345	1809	0,45	0,53
0,00	5,50	0	10	0,5	0	0,4	345	1809	0,45	0,53
0,00	0,00	0,3	10	0,9	0	0,1	330	1890	0,3	0,61
0,00	0,00	0,3	10	0,9	0	0,1	330	1890	0,3	0,61
0,00	0,00	0,3	10	0,9	0	0,1	330	1890	0,3	0,61

Region	Author (laboratory)	shrinkage (%)	dt (days)	$f_{ctm,k}$ (Mpa)	$f_{ck}$ (Mpa)	agg_description	specified agg_fine	classification agg	manufacturer	cement
Sudeste	Qualitec	-0,026	28			artificial/natural	rio		Votorantim	CP II E 40
Sudeste	Qualitec	-0,044	56			artificial/natural	rio		Votorantim	CP II E 40
Sudeste	Qualitec	0	0,708			artificial/natural	rio		Votorantim	CP II E 40
Sudeste	Qualitec	0,004	1			artificial/natural	rio		Votorantim	CP II E 40
Sudeste	Qualitec	0,009	2			artificial/natural	rio		Votorantim	CP II E 40
Sudeste	Qualitec	0,012	7			artificial/natural	rio		Votorantim	CP II E 40
Sudeste	Qualitec	-0,005	14			artificial/natural	rio		Votorantim	CP II E 40
Sudeste	Qualitec	-0,013	28			artificial/natural	rio		Votorantim	CP II E 40
Sudeste	Qualitec	-0,031	56			artificial/natural	rio		Votorantim	CP II E 40
Sudeste	Qualitec	0	0,75			artificial/natural	rio		Votorantim	CP II E 40
Sudeste	Qualitec	0,002	1			artificial/natural	rio		Votorantim	CP II E 40
Sudeste	Qualitec	0,005	2			artificial/natural	rio		Votorantim	CP II E 40
Sudeste	Qualitec	0,008	7			artificial/natural	rio		Votorantim	CP II E 40
Sudeste	Qualitec	-0,006	14			artificial/natural	rio		Votorantim	CP II E 40
Sudeste	Qualitec	-0,02	28			artificial/natural	rio		Votorantim	CP II E 40
Sudeste	Qualitec	-0,035	56			artificial/natural	rio		Votorantim	CP II E 40
Sudeste	Qualitec	0	0,83			artificial/natural			LafargeHolcim	CP VARI RS
Sudeste	Qualitec	0,003	1			artificial/natural			LafargeHolcim	CP VARI RS
Sudeste	Qualitec	0,007	2			artificial/natural			LafargeHolcim	CP VARI RS

super ranger	mid ranger	multifunctional	c	agg	aggregate (artificial/natural)	mortar (%)	a/c	w/c	Ref	Year	City
0,9	0	0,1	330	1890	0,3	0,61	5,73	0,61	7914.498740_B	2022	Campinas
0,9	0	0,1	330	1890	0,3	0,61	5,73	0,61	7914.498740_B	2022	Campinas
0,9	0	0,1	330	1890	0,3	0,61	5,73	0,61	7914.498740_B	2022	Campinas
0,9	0	0,1	330	1890	0,3	0,61	5,73	0,61	7914.498740_B	2022	Campinas
0,88	0	0,1	330	1890	0,3	0,61	5,73	0,61	7914.498740_A	2022	Campinas
0,88	0	0,1	330	1890	0,3	0,61	5,73	0,61	7914.498740_A	2022	Campinas
0,88	0	0,1	330	1890	0,3	0,61	5,73	0,61	7914.498740_A	2022	Campinas
0,88	0	0,1	330	1890	0,3	0,61	5,73	0,61	7914.498740_A	2022	Campinas
0,88	0	0,1	330	1890	0,3	0,61	5,73	0,61	7914.498740_A	2022	Campinas
0,88	0	0,1	330	1890	0,3	0,61	5,73	0,61	7914.498740_A	2022	Campinas
0,88	0	0,1	330	1890	0,3	0,61	5,73	0,61	7914.498740_A	2022	Campinas
0,88	0	0,1	330	1890	0,3	0,61	5,73	0,61	7914.498740_A	2022	Campinas
0,88	0	0,1	330	1890	0,3	0,61	5,73	0,61	7914.498740_A	2022	Campinas
0,88	0	0,1	330	1890	0,3	0,61	5,73	0,61	7914.498740_A	2022	Campinas
0,88	0	0,1	330	1890	0,3	0,61	5,73	0,61	7914.498740_A	2022	Campinas
0,88	0	0,1	330	1890	0,3	0,61	5,73	0,61	7914.498740_A	2022	Campinas
0,88	0	0,1	330	1890	0,3	0,61	5,73	0,61	7914.498740_A	2022	Campinas
0,88	0	0,1	330	1890	0,3	0,61	5,73	0,61	7914.498740_A	2022	Campinas
0,88	0	0,1	330	1890	0,3	0,61	5,73	0,61	7914.498740_A	2022	Campinas
1,12	0	0,1	325	1905	0,3	0,61	5,86	0,6	7914.498740_C	2022	Campinas



	agg (kg/m3)	aggregate (artificial/natural)	mortar (%)	a/c	w/c	Ref	Year	City	Region	Author (laboratory)	shrinkage (%)	dt (days)
1905	0,3	0,61	5,86	0,6	7914.498740_C	2022	Campinas	Sudeste	Qualitec	0,011	7	
1905	0,3	0,61	5,86	0,6	7914.498740_C	2022	Campinas	Sudeste	Qualitec	-0,002	14	
1905	0,3	0,61	5,86	0,6	7914.498740_C	2022	Campinas	Sudeste	Qualitec	-0,014	28	
1905	0,3	0,61	5,86	0,6	7914.498740_C	2022	Campinas	Sudeste	Qualitec	-0,037	56	
1905	0,3	0,61	5,86	0,6	7914.498740_C	2022	Campinas	Sudeste	Qualitec	0	0,83	
1905	0,3	0,61	5,86	0,6	7914.498740_C	2022	Campinas	Sudeste	Qualitec	0,001	1	
1905	0,3	0,61	5,86	0,6	7914.498430_B	2022	Campinas	Sudeste	Qualitec	0,003	2	
1905	0,3	0,61	5,86	0,6	7914.498430_B	2022	Campinas	Sudeste	Qualitec	0,006	7	
1905	0,3	0,61	5,86	0,6	7914.498430_B	2022	Campinas	Sudeste	Qualitec	-0,005	14	
1905	0,3	0,61	5,86	0,6	7914.498430_B	2022	Campinas	Sudeste	Qualitec	-0,017	28	
1905	0,3	0,61	5,86	0,6	7914.498430_B	2022	Campinas	Sudeste	Qualitec	-0,039	56	
1905	0,3	0,61	5,86	0,6	7914.498430_B	2022	Campinas	Sudeste	Qualitec	0	0,83	
1905	0,3	0,61	5,86	0,6	7914.498430_B	2022	Campinas	Sudeste	Qualitec	-0,003	1	
1905	0,3	0,61	5,86	0,61	7914.498430_A	2022	Campinas	Sudeste	Qualitec	-0,01	2	
1905	0,3	0,61	5,86	0,61	7914.498430_A	2022	Campinas	Sudeste	Qualitec	-0,015	7	
1905	0,3	0,61	5,86	0,61	7914.498430_A	2022	Campinas	Sudeste	Qualitec	-0,021	14	
1905	0,3	0,61	5,86	0,61	7914.498430_A	2022	Campinas	Sudeste	Qualitec	-0,029	28	
1905	0,3	0,61	5,86	0,61	7914.498430_A	2022	Campinas	Sudeste	Qualitec	-0,044	56	
1905	0,3	0,61	5,86	0,61	7914.498430_A	2022	Campinas	Sudeste	Qualitec	0	0,83	



w/c	Ref	Year	City	Region	Author (laboratory)	shrinkage (%)	dt (days)	$f_{ctm,k}$ (Mpa)	$f_{ck}$ (Mpa)	agg_description	specified agg_fine
0,61	7914.498430	A	2022	Campinas	Sudeste	Qualitec	0,002	1		artificial/natural	
0,61	7914.498430	2022	Campinas	Sudeste	Qualitec	0,005	2			artificial/natural	
0,61	7914.498430	2022	Campinas	Sudeste	Qualitec	0,008	7			artificial/natural	
0,61	7914.498430	2022	Campinas	Sudeste	Qualitec	-0,005	14			artificial/natural	
0,61	7914.498430	2022	Campinas	Sudeste	Qualitec	-0,015	28			artificial/natural	
0,61	7914.498430	2022	Campinas	Sudeste	Qualitec	-0,036	56			artificial/natural	
0,61	7914.498430	2022	Campinas	Sudeste	Qualitec	0	0,83			artificial/natural	
0,61	7914.498430	2022	Campinas	Sudeste	Qualitec	0,002	1			artificial/natural	
0,61	7914.498430	2022	Campinas	Sudeste	Qualitec	0,006	2			artificial/natural	
						0,009	7			artificial/natural	
						-0,002	14			artificial/natural	
						-0,015	28			artificial/natural	
						-0,034	56			artificial/natural	
						0	0,83			artificial/natural	
						-0,004	1			artificial/natural	
						-0,009	2			artificial/natural	
						-0,014	7			artificial/natural	
						-0,019	14			artificial/natural	
						-0,027	28			artificial/natural	



shrinkage (%)	dt (days)	$f_{ctm,k}$ (Mpa)	$f_{ck}$ (Mpa)	agg_description	specified agg_fine	classification agg	manufacturer	cemente
-0,04	56			artificial/natural		LafargeHolcim	CP V ARI RS	
0	0,83			artificial/natural		LafargeHolcim	CP V ARI RS	
0,003	1			artificial/natural		LafargeHolcim	CP V ARI RS	
0,006	2			artificial/natural		LafargeHolcim	CP V ARI RS	
0,011	7			artificial/natural		LafargeHolcim	CP V ARI RS	
-0,001	14			artificial/natural		LafargeHolcim	CP V ARI RS	
-0,01	28			artificial/natural		LafargeHolcim	CP V ARI RS	
-0,032	56			artificial/natural		LafargeHolcim	CP V ARI RS	