



**SIMONE MANCINI**

**REDES NEURAIAS ARTIFICIAIS APLICADAS NO  
ESTUDO DAS PRESSÕES EM SILOS ESBELTOS  
CILÍNDRICOS METÁLICOS: UMA ABORDAGEM  
SOBRE CONFIABILIDADE ESTRUTURAL**

**LAVRAS – MG**

**2022**

**SIMONE MANCINI**

**REDES NEURAIIS ARTIFICIAIS APLICADAS NO  
ESTUDO DAS PRESSÕES EM SILOS ESBELTOS  
CILÍNDRICOS METÁLICOS: UMA ABORDAGEM  
SOBRE CONFIABILIDADE ESTRUTURAL**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, área de concentração em Construções, Ambiência e Tratamento de Resíduos para a obtenção do título de Mestre.

Prof. *DSc* Tadayuki Yanagi Junior  
Orientador

Prof. *DSc*. Francisco Carlos Gomes  
Prof. *DSc*. Wilian Soares Lacerda  
Coorientadores

**LAVRAS - MG**

**2022**

Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca  
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).

Mancini, Simone.

Redes Neurais Artificiais aplicadas no estudo das pressões em  
silos esbeltos cilíndricos metálicos: : uma abordagem sobre  
confiabilidade estrutural / Simone Mancini. - 2022.

80 p. : il.

Orientador(a): Tadayuki Yanagi Junior.

Coorientador(a): Francisco Carlos Gomes, Wilian Soares  
Lacerda.

Dissertação (mestrado acadêmico) - Universidade Federal de  
Lavras, 2022.

Bibliografia.

1. Silos Esbeltos. 2. Redes Neurais Artificiais. 3.  
Confiabilidade estrutural. I. Yanagi Junior, Tadayuki. II. Gomes,  
Francisco Carlos. III. Lacerda, Wilian Soares. IV. Título.

**SIMONE MANCINI**

**REDES NEURAIIS ARTIFICIAIS APLICADAS NO  
ESTUDO DAS PRESSÕES EM SILOS ESBELTOS  
CILÍNDRICOS METÁLICOS: UMA ABORDAGEM SOBRE  
CONFIABILIDADE ESTRUTURAL**

**ARTIFICIAL NEURAL NETWORKS APPLIED TO THE  
STUDY OF PRESSURES IN METALLIC CYLINDRICAL  
SLIMT SILOS: AN APPROACH TO STRUCTURAL  
RELIABILITY**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, área de concentração em Construções, Ambiência e Tratamento de Resíduos para a obtenção do título de Mestre.

APROVADA em 25 de março de 2022.

*DSc.* Francisco Carlos Gomes (DEA / UFLA)

*DSc.* Tadayuki Yanagi Junior (DEA / UFLA)

*DSc.* Wilian Soares Lacerda (DAT / UFLA)

*DSc.* José Wallace Barbosa do Nascimento (UFPB)

Prof. *DSc.* Tadayuki Yanagi Junior  
Orientador

Prof. *DSc.* Francisco Carlos Gomes  
Prof. *DSc.* Wilian Soares Lacerda  
Coorientadores

**LAVRAS – MG  
2022**

## AGRADECIMENTO

Ao meu Deus que se fez presente em todos os momentos guiando meus passos.

Aos meus pais Neide e Osvaldo e minha irmã Juliana pelo esforço na realização desse sonho.

À Universidade Federal de Lavras e ao Programa de Pós-Graduação em Engenharia Agrícola pela oportunidade da realização do mestrado.

De forma muito especial aos professores *DSc.* Francisco Carlos Gomes, *DSc.* Wilian Soares Lacerda e *DSc.* Tadayuki Yanagi Junior, pelo esforço e dedicação total para que a pesquisa se concluísse.

Aos amigos Rômulo e Wisner pela ajuda e contribuição no desenvolvimento da pesquisa.

Aos professores e funcionários do Departamento de Engenharia Agrícola pela atenção e serviço prestado.

Aos colegas da Pós-Graduação pela troca de experiência e aprendizado.

Meu muito obrigada a todas as pessoas que me ajudaram para a realização desse trabalho.

## RESUMO GERAL

A avaliação estrutural dos silos a partir da predição das pressões é um tema de grande interesse de pesquisadores, projetistas e fabricantes. O número de variáveis envolvidas geram incertezas nos cálculos e grande número de falhas e ocorrências de colapsos neste tipo de estruturas. Para compensar as normas, majoram os valores de pressões. Objetivou-se com o presente trabalho desenvolver um modelo de predição das pressões em comparação aos dados experimentais. Para obtenção dos dados foi usado o silo-piloto proposto por Pieper e Schutz, adotado pela norma DIN 1055 (1987). No modelo, foram utilizadas paredes de chapa lisa e fundo plano, variando a relação altura/diâmetro entre 4, 6 e 8. Foram observados e coletados valores de dados de pressões horizontais e de atrito do produto milho com a parede ao longo do silo, para pressões de carregamento e descarregamento. Os resultados das pressões obtidas experimentalmente foram inseridos em um algoritmo utilizando Redes Neurais Artificiais (ANN) do tipo Perceptron multicamadas. As pressões experimentais obtidas nas paredes do silo, durante as etapas de carregamento e descarregamento, foram comparadas com os valores gerados pela ANN, assim como com os valores calculados pelas Normas AS 3774 (1996) e EN 1991-4 (2006). A estimativa da ANN foi obtida com grau de confiabilidade de 90%, demonstrando viabilidade do seu uso nas predições de pressões em silos. Os indicadores estatísticos calculados mostram os valores do Erro Médio Quadrático das pressões horizontais e de atrito, 0,074 e 0,067 respectivamente para carregamento e 0,071 e 0,072 para o descarregamento. No comparativo dos métodos testados, a ANN foi a que melhor estimou os dados de pressão.

**PALAVRAS-CHAVE:** Silos Esbeltos, Redes Neurais Artificiais, Confiabilidade estrutural.

## GENERAL ABSTRACT

Pressure prediction and structural assessment in silos is a topic of great interest in research studies. It can be considered that the degree of uncertainty in the calculations has had repercussions on the large number of failures and occurrences of collapses, in this type of structures in Brazil, and in the world. The objective of the present work was to develop a model for predicting pressures in comparison with experimental data. To obtain the experimental data, the pilot silo proposed by Pieper and Schutz was used, providing the basis for the DIN 1055 (1987) standard. In the silo, smooth plate walls and a flat bottom were used, varying the height/diameter ratio between 4, 6 and 8. Data values of horizontal pressures and friction of the product (maize) with the wall along the silo were observed and collected, for filling and discharge pressures. The results of the pressures obtained experimentally were inserted in an algorithm using Artificial Neural Networks (ANN) of the multilayer Perceptron type. The experimental pressures obtained on the silo walls, during the filling and discharge stages, were compared with the values generated by the ANN, as well as the values calculated by the AS 3774 (1996) and EN 1991-4 (2006) Standards. The ANN estimate was obtained with a confidence level of 90%, demonstrating the feasibility of its use in the predictions of pressures in silos. The calculated statistical indicators show the Mean Square Error values of horizontal and friction pressures: 0.074 and 0.067 respectively for filling and 0.071 and 0.072 respectively for discharge. For dimensions with lower values, the lowest values of horizontal pressures and friction were obtained. At elevation 1.25 m, the values 0.56 kPa and 1.12 kPa for horizontal pressures and 0.18 kPa and 0.41 kPa for friction pressures, being the filling and discharge values, respectively. Such values show significance in the actual data collected in the pilot silo. In comparing the methods tested, the ANN showed the best description of the predictability of pressure data.

**KEYWORDS:** Slender Silos, Artificial Neural Networks, Structural reliability.

## LISTA DE FIGURAS

### PRIMEIRA PARTE

Figura 1 -	Tipos de geometria das tremonhas.....	19
Figura 2 -	Tremonha concêntrica cônica com $\beta = 15^\circ$ .....	19
Figura 3 -	Fluxo de massa e funil.....	22
Figura 4A -	Ábaco para determinação do tipo de fluxo pela norma AS 3774 (1996).....	23
Figura 4B -	Ábaco para determinação do tipo de fluxo pela norma EN 1991- 4 (2006).....	23
Figura 5 -	Pressões atuantes no silo.....	25
Figura 6 -	Forças existentes sobre a camada elementar.....	26
Figura 7 -	Estados de Tensões.....	28
Figura 8 -	Representação da estrutura de um Neurônio Biológico.....	34
Figura 9 -	Neurônio artificial.....	35
Figura 10 -	Função Limiar.....	36
Figura 11 -	Função Linear por Partes.....	36
Figura 12 -	Função Sigmoide.....	36
Figura 13 -	Função ReLU.....	37
Figura 14 -	Estrutura de uma Rede Neural.....	38
Figura 15a -	Rede Neural Artificial <i>feedforward</i> de camada única.....	38
Figura 15b -	Rede Neural Artificial <i>feedforward</i> de múltiplas camadas.....	38
Figura 16 -	Rede Neural Artificial recorrente.....	39

### SEGUNDA PARTE

#### ARTIGO 1

Figura 1 -	Estrutura de uma rede neural.....	55
Figura 2 -	Gráfico da função Sigmoide .....	56
Figura 3 -	Estação experimental no Centro de Pesquisa em Processamento de Produtos Agrícolas da Universidade Federal de Lavras.....	60
Figura 4 -	Sistema de aquisição de dados e sensores.....	60
Figura 5A -	Pressões Horizontais de carregamento.....	68
Figura 5B -	Pressões Horizontais de descarregamento.....	68



Figura 6A -	Pressões de Atrito de carregamento.....	68
Figura 6B -	Pressões de Atrito de descarregamento.....	68
Figura 7B -	Erro Médio a cada época para as pressões Horizontais de carregamento.....	69
Figura 7B -	Erro Médio a cada época para as pressões de Atrito de carregamento.....	69
Figura 8A -	Erro Médio a cada época para as pressões Horizontais de descarregamento.....	69
Figura 8B -	Erro Médio a cada época para as pressões de Atrito de descarregamento.....	69
Figura 9A -	Comparativos de carregamento para as pressões horizontais nas paredes do silo.....	71
Figura 9B -	Comparativos de carregamento para as pressões de atrito nas paredes do silo.....	71
Figura 10A -	Comparativos de descarregamento para as pressões horizontais nas paredes do silo.....	71
Figura 10B -	Comparativos de descarregamento para as pressões de atrito nas paredes do silo.....	71

## **LISTA DE QUADROS**

### **PRIMEIRA PARTE**

Quadro 1 -	Propriedades físicas dos produtos armazenados.....	21
------------	--	----

### **SEGUNDA PARTE**

#### **ARTIGO 1**

Quadro 1 -	Pressões Horizontais e de Atrito de Carregamento.....	61
------------	---	----

Quadro 2 -	Pressões Horizontais e de Atrito de Descarregamento.....	62
------------	--	----

## LISTA DE TABELAS

### PRIMEIRA PARTE

Tabela 1 - Capacidade de armazenamento de grão no Brasil.....	16
Tabela 2 - Normas Internacionais para projetos estruturais de silos.....	18
Tabela 3 - Classificação de silos quanto à esbeltez pelas principais Normas Internacionais.....	18
Tabela 4 - Pressões de carregamento na parede do silo.....	29

### SEGUNDA PARTE

#### ARTIGO 1

Tabela 1 - Faixa dos valores das propriedades físicas do milho.....	61
Tabela 2 - Pressões de carregamento na parede do silo.....	63
Tabela 3 - Arquitetura da Rede Neural Artificial.....	65
Tabela 4 - Comparativos de indicadores estatísticos na predição das pressões horizontais e de atrito de carregamento e descarregamento.....	67
Tabela 5 - Erro Médio Mínimo na época número 3000 para as predições das pressões horizontais e de atrito de carregamento e descarregamento.....	70

## LISTA DE SÍMBOLOS

### PRIMEIRA PARTE

$\alpha$	Ângulo de inclinação na tremonha
$\Phi_i$	Ângulo de atrito interno
$\Phi_w$	Ângulo de atrito com a parede
$\Phi_{w,c}$	Ângulo de atrito entre o produto parede do silo
$\Phi_e$	Efetivo ângulo de atrito interno
ff	Fator fluxo da tremonha
FF	Função fluxo
d	Granulometria
$\gamma$	Peso específico
K	Relação entre a pressão horizontal e vertical
A	Área da seção transversal horizontal do silo
U	Perímetro da seção transversal
q	Pressão de atrito sobre a parede
z	Altura da cota do produto acima da seção transversal considerada
H/D	Relação altura do silo / diâmetro do corpo do silo
Cw e Ch	Coefficientes de sobrepressão usado pelas Normas EN 1991-4: 2006
Cc e Cd	Coefficientes de sobrepressão usado pelas normas AS 3774: 1996
$X_i$	Sinais de entrada da Redes Neurais
$W_i$	Pesos da Redes Neurais
b	Bias da Redes Neurais
$v_k$	Função de ativação
$\eta$	Taxa de aprendizado
$y_i$	I-ésimo valor da variável resposta
$x_{ki}$	I-ésimo valor da k-ésima variável
$\beta_k$	Parâmetros do modelo usado nas da Redes Neurais
$\beta$	Coefficientes de Regressão
$\varepsilon$	Erro ou variância do coeficiente de Regressão
p	Número de parâmetros na Regressão
$\mu'$	Parâmetro na equação de Janssen
ai	Dados reais (teste)
yi	Dados estimados
am	Média dos dados reais
n	Quantidade de dados

### SEGUNDA PARTE

#### ARTIGO 1

H/D	Relação altura do silo / diâmetro do corpo do silo
$v_k$	Função de ativação
K	Relação entre a pressão horizontal e vertical
$\gamma$	Peso específico
A	Área da seção transversal horizontal do silo
U	Perímetro da seção transversal
q	Pressão de atrito sobre a parede
z	Altura da cota do produto acima da seção transversal considerada
$\Phi_e$	Efetivo ângulo de atrito interno
$\Phi_w$	Ângulo de atrito com a parede

$\mu'$	Parâmetro na equação de Janssen
Cw e Ch	Coefficientes de sobrepressão usado pelas Normas EN 1991-4: 2006
$\eta$	Taxa de aprendizado
$y_i$	I-ésimo valor da variável resposta
$y_i$	I-ésimo valor da variável resposta
$x_{ki}$	I-ésimo valor da k-ésima variável
$\beta_k$	Parâmetros do modelo usado nas da Redes Neurais
$\beta$	Coefficientes de Regressão
$\varepsilon$	Erro ou variância do coeficiente de Regressão
$a_i$	Dados reais (teste)
$y_i$	Dados estimados
am	Média dos dados reais
$n$	Quantidade de dados

## SUMÁRIO

### PRIMEIRA PARTE

1	INTRODUÇÃO.....	15
1.1	Objetivo Geral.....	16
1.2	Objetivos Específicos.....	16
2	REFERENCIAL TEÓRICO.....	17
2.1	Silos.....	17
2.2	Tremonhas.....	19
2.3	Propriedades dos produtos armazenados.....	20
2.4	Fluxo.....	22
2.5	Pressões.....	24
2.6	Teorias e Normas Internacionais.....	25
2.7	Modelos experimentais.....	30
2.8	Trabalhos correlacionados.....	32
2.9	Redes Neurais Artificiais.....	32
2.9.1	Neurônio Biológico.....	33
2.9.2	Arquitetura das RNA's.....	37
2.9.3	Treinamento das RNA's.....	39
2.10	Regressão Linear e Polinomial.....	41
2.10.1	Regressão Linear Simples.....	42
2.10.2	Regressão Polinomial.....	42
2.11	Métricas de Desempenho.....	43
2.11.1	Coefficiente $R^2$ .....	43
2.11.2	Erro Médio Absoluto – MAE.....	44
2.11.3	Erro Médio Percentual Absoluto – MAPE.....	44
2.11.4	Erro Médio Quadrático – RMSE.....	44
3	CONSIDERAÇÕES GERAIS.....	46
	REFERÊNCIAS BIBLIOGRÁFICAS.....	47

### SEGUNDA PARTE

	<b>ARTIGO 1 -</b> Uso de redes neurais artificiais na predição das pressões horizontais e de atrito em silo esbelto.....	52
1	INTRODUÇÃO.....	53

2	MATERIAIS E MÉTODOS.....	60
2.1	Configuração do silo e sensores.....	60
2.2	Dados coletados.....	61
2.3	Normas e Teorias.....	63
2.4	Regressão Linear Simples e Regressão Polinomial.....	64
2.5	Rede Neural Artificial (RNA).....	64
2.5.1	Pré-processamento.....	65
2.5.2	Arquitetura da RNA.....	65
2.5.3	Treinamento da RNA.....	65
2.5.4	Métricas de desempenho.....	66
3	RESULTADOS E DISCUSSÃO.....	68
4	CONCLUSÃO.....	74
	REFERÊNCIAS BIBLIOGRÁFICAS.....	75
	APÊNDICE A - Algoritmo para determinação das pressões horizontais e de atrito nas paredes do silo para carregamento, usando a Norma EN 1991-4 (2006) a Norma AS 3774 (1996).....	78
	APÊNDICE B - Algoritmo para determinação das pressões horizontais e de atrito nas paredes do silo para descarregamento, usando a Norma EN 1991-4 (2006) e a Norma AS 3774 (1996).....	80

## **PRIMEIRA PARTE**

### **1 INTRODUÇÃO**

Tem-se buscado nos últimos anos, um maior entendimento sobre a previsibilidade de colapsos em estruturas. Os projetistas vêm otimizando os estudos de mecanismo das falhas juntamente aos parâmetros de funcionalidade e integridade estrutural. Isso acontece a partir do domínio e quantificação das variáveis e grau de incerteza presentes no estudo do comportamento das estruturas. A quantificação dessas incertezas no desempenho da estrutura, é uma tarefa de grande complexidade e tem sido observada pela prática da engenharia a partir de estudos de confiabilidade.

Mesmo com os avanços nas concepções estruturais e também nas metodologias de dimensionamento, ainda se torna necessário o estudo de um modelo com resultados mais representativos da realidade. Dentre as estruturas com grande complexidade no cálculo estrutural, destacam-se as de armazenamento, devido à interação com a variedade de produtos armazenados. Como consequência do aumento significativo do número de falhas e colapsos que vêm ocorrendo no Brasil e no mundo, os projetos de silos metálicos vêm demandando uma maior atenção na sua construção, montagem e detalhes construtivos.

Os silos são estruturas destinadas ao armazenamento e conservação de diversos tipos de produtos em seu interior sem estarem ensacados. Existem vários tipos e modelos de silos, com materiais e dimensões distintas. Essa escolha muitas vezes vai depender das propriedades físicas do produto que será armazenado e também dos recursos disponíveis.

Infelizmente é comum se deparar com acidentes envolvendo as estruturas de armazenamento. Para que essa situação seja evitada, é necessário a execução de um projeto estrutural seguro. Neste contexto, o conhecimento das ações na estrutura é de extrema importância. Dentre as ações variáveis, as pressões geradas pelo produto armazenado, são objeto de análise, diante da carência de informações e estudos nessa área. Também é de relevância a criação de uma Norma Brasileira que calibre os fatores de majoração nos cálculos estruturais de acordo com os produtos nacionais utilizados.



Alguns dados demonstrados na Tabela (1), denotam a expansão do setor de agronegócio e da necessidade de aprimoramento das construções para a armazenagem dos grãos.

Tabela 1 – Capacidade de armazenamento de grão no Brasil

<b>Ano</b>	<b>Produção de grãos</b>	<b>Capacidade de armazenamento</b>
2018	237,7 milhões de toneladas	162,32 milhões de toneladas
2021	252,3 milhões de toneladas	176,4 milhões de toneladas

Fonte: Adaptado de CONAB (2021)

Diante dos dados, é notável a diferença de valores entre produção e estocagem de grãos e a necessidade da ampliação na quantidade de estruturas de armazenamento. No ano de 2021 houve um déficit de estrutura de armazenamento para 75,9 milhões de toneladas de grão.

Devido a imprevisibilidade das ações nos silos e o número de variáveis, o uso de um modelo computacional é indicado para o estudo da confiabilidade da estrutura. A metodologia de inteligência computacional rede neural artificial é capaz de organizar e treinar uma rede de dados. E ainda possibilita um volume de entradas e saídas de acordo com o obtido nos modelos experimentais.

A motivação para o desenvolvimento do trabalho baseia-se na perspectiva de aumento no setor do agronegócio e o volume pequeno de pesquisas na área de previsibilidade estrutural. Acredita-se que esse número limitado de pesquisas é devido ao alto custo dos projetos. Portanto, torna-se um instrumento favorável a previsão das ações no silo através de um modelo com inteligência computacional, o que possibilita o aumento da confiabilidade nas estruturas de armazenamento.

### **1.1 Objetivo geral**

Desenvolver uma rede neural artificial (RNA) e fazer o comparativo com as pressões obtidas de forma experimental no silo-piloto, e também em paralelo as Normas internacionais.

### **1.2 Objetivos específicos**

- Treinar e validar uma rede neural artificial para prever as pressões de carregamento e descarregamento em uma estrutura de armazenamento.
- Utilizar as Normas internacionais: AS 3774 (1996) e EN 1991-4 (2006) para calcular os valores das pressões nas paredes do silo.
- Validar o modelo de redes neurais artificiais para pressões em silos a partir de dados experimentais.

## **2 REFERENCIAL TEÓRICO**

Os silos são estruturas destinadas ao armazenamento de produtos, e são construções que se destacam pelo grau de incertezas em relação à estabilidade estrutural. Algumas variáveis estão associadas ao comportamento do produto armazenado (granular ou pulverulento) e a interação do produto com estrutura do silo.

Os estudos das ações provenientes das pressões relacionadas aos produtos armazenados em silos, datam no final dos anos de 1800 por Janssen (1895), Airy (1897). Com o decorrer dos anos, diversas teorias e normas foram desenvolvidas na área de cálculo destas estruturas, permitindo assim um avanço na confiabilidade das estruturas de armazenamento.

Como o número de pesquisas nessa área é reduzido, ainda existem incertezas em relação as ações variáveis que ocorrem no silo devido ao carregamento e ao descarregamento do produto armazenado. Com o entendimento das propriedades dos produtos armazenados, das ações na estrutura, do uso dos modelos experimentais e das metodologias computacionais têm sido possível o aprofundamento e o desenvolvimento de estudos de confiabilidade estrutural.

### **2.1 Silos**

A palavra silo origina-se do grego “sirus” (lugar escuro e cavernoso). A utilização do silo apresenta diversas vantagens no armazenamento de produtos, como por exemplo, a economia do espaço físico, da mão de obra e do custo de transporte. Os silos conseguem manter e conservar os produtos, bem como oferecer uma boa logística para a indústria.

Segundo Carvalho (2018) os silos podem ser feitos de vários materiais como concreto armado ou protendido; metálicos com chapas corrugadas, lisas e trapezoidais; de alvenaria; e outros diversos materiais.

Atualmente, nos projetos estruturais de silos no Brasil são utilizadas como principais referências as normas internacionais citadas na Tabela (2). Existe uma discrepância nos padrões de calibração entre as normas, por isso, existe a necessidade de uma norma brasileira com parâmetros para os produtos nacionais.

Tabela 2 – Normas internacionais para projetos estruturais de silos

<b>LOCAL</b>	<b>NOME</b>
Americanas	AMERICAN CONCRETE INSTITUTE - ACI 313:1991
	AMERICAN NATIONAL STANDARDS INSTITUTE - ANS/ASAE EP 433:2001
Australiana	(AUSTRALIAN STANDARD - AS3774:1996)
Canadense	(CANADIAN FARM BUILDING CODE - CFBC:1983)
Europeias	EUROPEAN COMMITTEE OF STANDARDIZATION - EN 1991- 4:2006
	DEUTSCHE NORM - DIN 1055-6:2005
	ISO 11698 (INTERNATIONAL ORGANIZATION FOR STANDART - ISO, 2012).

Fonte: Adaptado de CONAB (2021)

Os silos são classificados de acordo com sua forma geométrica, utilizando a altura total pelo diâmetro (H/D). Essa classificação é com relação a sua esbeltez, e existe uma divergência nos valores apresentados pelas normas internacionais para os silos baixo, medianamente esbelto e esbelto, como mostra a Tabela (3).

Tabela 3 – Classificação de silos quanto à esbeltez pelas principais Normas Internacionais

<b>Normas</b>	<b>Classificação</b>		
	<b>Baixos</b>	<b>Medianamente esbeltos</b>	<b>Esbeltos</b>
<b>Australiana</b> AS 3774 (1996)	$H/D < 1,0$	$1,0 \leq H/D \leq 3,0$	$H/D > 3,0$
<b>Europeias</b> EN 1991-4 (2006) DIN 1055-03 (2005)	$0,4 \leq H/D \leq 1,0$	$1,0 \leq H/D \leq 2,0$	$H/D \geq 2,0$
<b>Americanas</b> ACI-313 (1991) ANSI/ASAE EP433 (2001)	$H/D < 2,0$	-	$H/D > 2,0$
<b>Canadense</b> CBFC (1983) ISO 11698 (2012)	$H/D \leq 1,0$ ou $H/D < \tan^2$ $(\phi_e/2+\pi/4)$ $H/D \leq 1,0$	- $1,0 \leq H/D \leq 1,5$	$H/D > 1,0$ e $H/D \geq \tan^2$ $(\phi_e/2+\pi/4)$ $H/D \geq 1,5$


Fonte: Calil Jr e Cheung (2007)

H – Altura do silo com a tremonha.  
D – Diâmetro do corpo do silo.  
 $\phi_e$  – Efetivo ângulo de atrito interno.

## 2.2 Tremonhas

As tremonhas são estruturas instaladas na extremidade inferior do cilindro (paredes) do silo. Seu objetivo é promover o fluxo dos produtos armazenados. Existem tremonhas com diversas formas geométricas, como mostra a Figura (1). De acordo com a escolha da geometria da tremonha, é possível prever o tipo de fluxo que ocorrerá durante o esvaziamento do silo. As tensões na estrutura, também podem ser alteradas dependendo da escolha da tremonha.

Figura 1 – Tipos de geometria das tremonhas




Fonte: Adaptado de Calil Jr. e Cheung (2007)

Existem tremonhas com saída em cunha e com saída cônica. As tremonhas em cunha têm a vantagem de necessitar de uma altura menor em comparação com a cônica, porém, as tremonhas em cunha apresentam como desvantagem a abertura para descarregamento ser igual à largura do silo (CALIL JR e CHEUNG, 2007).

Além da geometria da tremonha, outros fatores que influenciam o comportamento do fluxo e das ações no silo são a inclinação da parede da tremonha (ângulo de inclinação), o tipo de material utilizado e o alinhamento da boca de descarga com relação ao eixo (concentricidade ou excentricidade). Na Figura (2) é possível ver um exemplo de tremonha cônica e onde é localizado o ângulo de inclinação.

Figura 2 – Tremonha concêntrica cônica com  $\alpha = 15^\circ$



Fonte: A autora (2021)

### 2.3 Propriedades dos produtos armazenados

A determinação das propriedades físicas do produto armazenado é necessária, pois, elas influenciam no tipo de fluxo e nas ações presentes na estrutura dos silos. Portanto, o entendimento e a caracterização dos produtos a serem armazenados são de grande importância. As principais propriedades físicas dos produtos são:

- Ângulo de atrito interno ( $\phi_i$ )
- Ângulo de atrito entre o produto parede do silo ( $\phi_{w,c}$ )
- Efetivo ângulo de atrito interno ( $\phi_e$ )
- Fator fluxo da tremonha (ff)
- Função fluxo (FF)
- Granulometria (d)
- Peso específico ( $\gamma$ )

As normas internacionais apresentam valores das propriedades físicas para alguns produtos já padronizados e também métodos e equipamentos para sua determinação. Como esses valores variam muito entre as normas, recomenda-se, sempre que possível, realizar ensaios para caracterização de cada produto a ser armazenado.

As análises para caracterização dos produtos são feitas com bastante rigor, porém não é possível controlar todas as variáveis, sendo necessário o uso de faixas de valores inferiores e superiores para as propriedades físicas do produto (REIMBERT, 1979).

Na faixa de valores inferiores e superiores, é utilizado a situação mais crítica e desfavorável das propriedades físicas do produto para a realização do cálculo estrutural (CALIL JR. 1984-1985). No Quadro (1), está listado alguns produtos já padronizados pela norma EN 1991-4 (2006).

Quadro 1 – Propriedades físicas dos produtos armazenados

Tipo de sólido tabelado	Peso Específico $\gamma$		Ângulo em repouso $\phi_r$	Ângulo de atrito interno $\phi_i$		Relação de pressão lateral K		Coeficiente de atrito da parede $\mu$ ( $\mu = \tan \phi_w$ )				Fator de referência sólido de carga
	Mínimo	Superior		Média	Fator	Média	Fator	Média	Média	Média	Fator	
	kN/m <sup>3</sup>	kN/m <sup>3</sup>	(graus)	$\phi_{im}$	$A\phi$	Km	aK	Tipo de Parede D1	Tipo de Parede D2	Tipo de Parede D2	a $\mu$	
Mistura de ração animal	5,0	6,0	39	36	1,08	0,45	1,10	0,22	0,30	0,43	1,28	0,43
Cevada	7,0	8,0	31	28	1,14	0,59	1,11	0,24	0,33	0,48	1,16	0,5
Cimento	13,0	16,0	36	30	1,22	0,54	1,20	0,41	0,46	0,51	1,07	0,5
Clínquer de cimento	15,0	18,0	47	40	1,20	0,38	1,31	0,46	0,56	0,62	1,07	0,7
Carvão	7,0	10,0	36	31	1,16	0,52	1,15	0,44	0,49	0,59	1,12	0,6
Carvão em pó	6,0	8,0	34	27	1,26	0,58	1,20	0,41	0,51	0,56	1,07	0,5
Farinha de trigo	6,5	7,0	45	42	1,06	0,36	1,11	0,24	0,33	0,48	1,16	0,6
Minério de ferro	19,0	22,0	36	31	1,16	0,52	1,15	0,49	0,54	0,59	1,12	0,5
Cal hidratado	6,0	8,0	34	27	1,26	0,58	1,20	0,36	0,41	0,51	1,07	0,6
Pó de calcário	11,0	13,0	36	30	1,22	0,54	1,20	0,41	0,51	0,56	1,07	0,5
Milho	7,0	8,0	35	31	1,14	0,53	1,14	0,22	0,36	0,53	1,24	0,9
Fosfato	16,0	22,0	34	29	1,18	0,56	1,15	0,39	0,49	0,54	1,12	0,5
Batatas	6,0	8,0	34	30	1,12	0,54	1,11	0,33	0,38	0,48	1,16	0,5
Areia	14,0	16,0	39	36	1,09	0,45	1,11	0,38	0,48	0,57	1,16	0,4
Escória de clínquer	10,5	12,0	39	36	1,09	0,45	1,11	0,48	0,57	0,67	1,16	0,6
Grão de soja	7,0	8,0	29	25	1,16	0,63	1,11	0,24	0,38	0,48	1,16	0,5
Açúcar	8,0	9,0	38	32	1,19	0,50	1,20	0,46	0,51	0,56	1,07	0,4
Trigo	7,5	9,0	34	30	1,12	0,54	1,11	0,24	0,38	0,57	1,16	0,5

Fonte: Adaptado EN 1991-4 (2006).


O aparelho mais utilizado por pesquisadores e normas internacionais para determinar as propriedades dos produtos é o “Jenike Shear Tester”, devido a sua versatilidade no uso.

## 2.4 Fluxo

O fluxo em um silo, é entendido pelo deslocamento vertical da massa do produto armazenado. Ele ocorre quando as pressões são tais que acontece o cisalhamento, sem destruir a isotropia do produto armazenado (JENIKE e JOHANSON, 1968). Quando o fluxo acontece sem o auxílio de nenhum dispositivo, ocorrendo somente por conta da gravidade, ele pode ser classificado como fluxo de massa ou fluxo de funil.

O fluxo de massa é o tipo mais aconselhável para um projeto, e é definido quando todas as partículas do produto armazenado estão em movimento durante a descarga do silo. Nesse tipo de fluxo o silo esvazia-se completamente, não ocorrendo zonas estáticas. O fluxo de funil é caracterizado pela formação de um canal de fluxo alinhado com a boca de descarga, envolvido com duas zonas estáticas da massa de grãos nas laterais do cilindro do silo (PALMA, 2005). Na Figura (3) está descrito o fluxo de funil e o fluxo de massa.

Figura 3 – Fluxo de massa e funil



Fonte: Adaptado Palma (2005)

Uma situação que pode causar o fluxo de funil, é quando se utiliza produtos muito coesivos ou produtos com alto teor de umidade. A ocorrência do fluxo de funil prejudica a eficiência do silo, sendo necessário adotar algum método para fazer a descarga completa. Esses métodos podem ser por meio de sistemas vibratórios, sistemas de pás ou utilizar tremonhas com maiores inclinações e utilizar materiais mais rugosos nas tremonhas. O produto retido nas zonas estáticas do fluxo de funil, se não retirado, poderá perder a qualidade (PALMA, 2005).

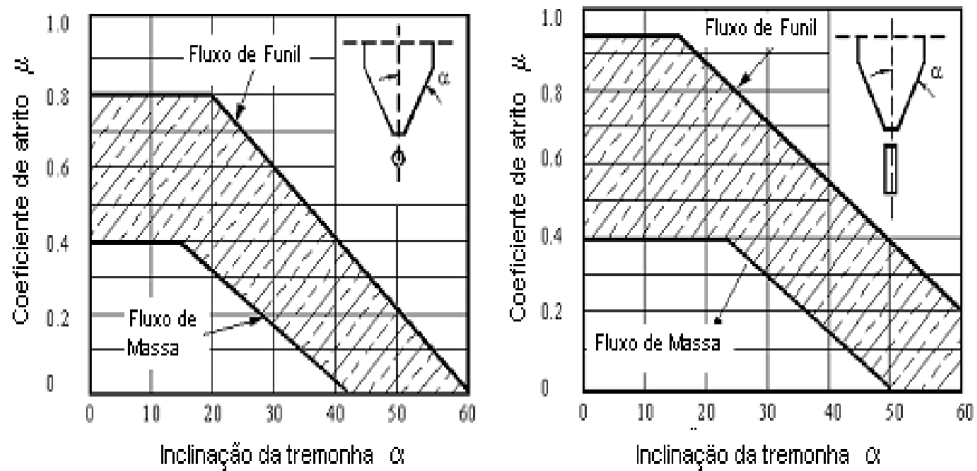
Segundo Schulze (1996) no caso de silos com fluxo de funil, o ângulo de inclinação da tremonha com a vertical é maior que para fluxo de massa. Portanto, a tremonha para este tipo de fluxo tem menor altura e pode ser usada em locais onde a altura do silo é limitada. Contudo,

geralmente necessitam de dispositivos promotores de fluxo, como vibradores para restabelecer o fluxo, promovendo assim, o deslizamento total do produto armazenado.

De acordo com Roberts et al. (1987) algumas vezes quando se utiliza bocas de descarga excêntricas, podem acontecer o fluxo de funil. Portanto, a menos que haja razão para o contrário, devem ser projetados silos com formas geométricas simples e carregamento simétrico, facilitando assim ter o fluxo de massa.

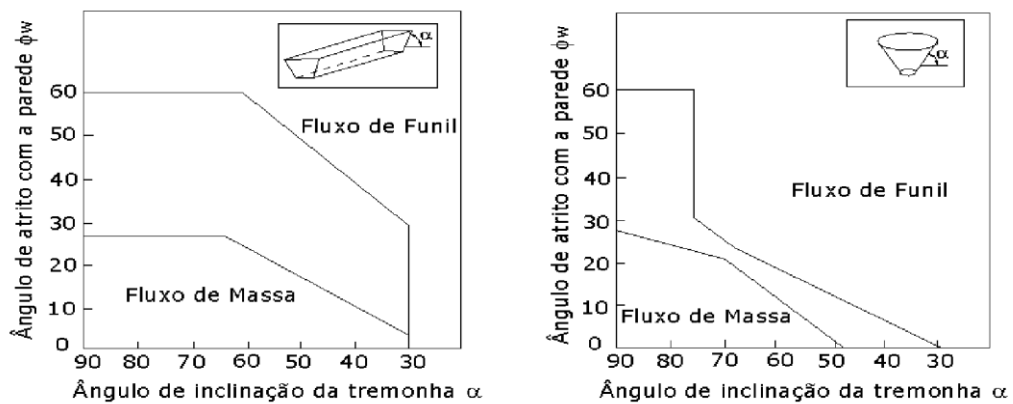
O tipo de fluxo é capaz de influência na distribuição de pressões nas paredes do silo. As normas apresentam Ábacos Figuras (4A e 4A) que possibilitam determinar o tipo de fluxo por meio da inclinação da tremonha, do coeficiente de atrito e da geometria da tremonha.

Figura 4A – Ábaco para determinação do tipo de fluxo pela norma AS 3774 (1996)



Fonte: Adaptado AS 3774 (1996)

Figura 4B – Ábaco para determinação do tipo de fluxo pela norma EN 1991-4 (2006)



Fonte: Adaptado EN 1991-4 (2006)



## 2.5 Pressões

No cálculo de estruturas como os silos, existem problemas diversos. O que pode vir a comprometer o desempenho da estrutura e até mesmo chegar a atingir o colapso. Atualmente o estudo das ações em silos ocorre em diversas frentes, sendo, mais comuns os modelos experimentais ou reais, os modelos computacionais e os modelos teóricos.

O termo ação é designado por qualquer influência ou conjunto de influências capazes de produzir estado de tensão na estrutura (FUSCO, 1976). A determinação das ações é de extrema importância para determinar os esforços atuantes, possibilitando o dimensionamento e a segurança estrutural.

As pressões atuantes nos silos são caracterizadas como aleatórias, pois são inúmeras variáveis que englobam as propriedades dos produtos armazenados e também diversos fatores que interferem na integridade da estrutura do silo.

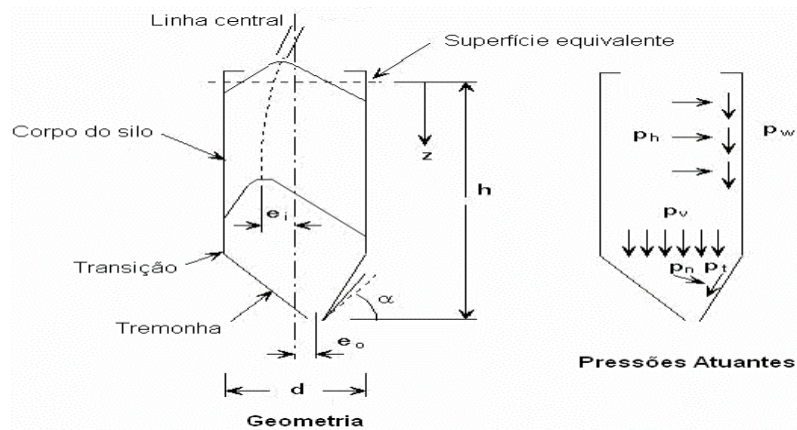
Para o entendimento das pressões que ocorrem no silo é importante, primeiramente, entender as propriedades físicas dos produtos armazenados assim como o critério de ruptura (deslizamento) adequado a ser utilizado. Roberts (1995) afirma que a principal diferença entre os produtos que estão armazenados e os produtos que são considerados fluídos, é que os produtos armazenados são capazes de transmitir tensões tangenciais oriundas do atrito entre os grãos e as paredes. Por sua vez, os produtos fluídos possuem somente o estado de tensão hidrostática com tensões tangenciais nulas.

No projeto de silos, segundo Calil Jr. e Nascimento (1997) devem ser consideradas três ações:

- Permanentes (peso próprio da estrutura e materiais que compõe a estrutura);
- Variáveis (pressões ocorridas pelos produtos armazenados no carregamento e descarregamento, dilatação térmica, ventos, deformação térmicas) e
- Ações excepcionais (impactos de veículos na estrutura do silo ou decorrentes de explosões).

Em síntese as ações exercem pressões nas paredes verticais e no fundo do silo. Nas paredes do silo atuam pressões perpendiculares denominadas pressões horizontais ( $P_h$ ) e as pressões de atrito que são do produto com a parede e do produto com o produto ( $P_w$ ). No fundo do silo atuam as pressões verticais ao silo ( $P_v$ ). Na tremonha tem as pressões normais que são perpendiculares ( $P_n$ ) e também as pressões de atrito na parede da tremonha ( $P_t$ ). Essas pressões estão descritas na Figura (5).

Figura 5 – Pressões atuantes no silo



Fonte: Palma (2005)

As pressões atuantes quando o silo está totalmente vazio e começa a ser carregado com a boca de descarga ainda fechada, é totalmente diferente de quando é realizado alguma descarga no silo. É necessária a atenção no início do descarregamento do silo, pois é onde ocorrerem as maiores pressões. Essas pressões mais elevadas, se encontram na zona de transição, entre o cilindro das paredes do silo e a tremonha (PALMA, 2005).

O estado de tensões em silos, sempre foi uma situação estudada por diversos autores como por exemplo Janssen, 1895; Walker, 1966; Walters, 1973; Jenike et al., 1973; Arnold et al., 1982 e Roberts, 1987; esses estudiosos criaram várias teorias e procedimentos para o estudo do assunto.

## 2.6 Teorias e normas internacionais


A teoria proposta por Janssen (1895) conhecida como Método da Camada Elementar. Este método vem sendo utilizado até nos dias atuais. As hipóteses que são bases da teoria de Janssen são:

- As pressões horizontais são constantes no mesmo plano horizontal;
- O valor do ângulo de atrito do produto com a parede é constante;
- O peso específico do produto é uniforme;
- As paredes do silo são totalmente rígidas.

A formulação de Janssen, consiste no equilíbrio de uma camada elementar do produto de altura  $dz$  com o peso específico  $\gamma$ , sujeitos às pressões verticais  $P_v$  e as pressões devidas ao atrito produzido pela força horizontal  $P_h$  sobre as paredes do silo. O  $A$  é a área da seção transversal do silo e  $U$  é o perímetro. Com o equilíbrio das forças que atuam em uma camada

infinitesimal, são determinadas as pressões verticais, horizontais e de atrito. Na Figura (6) estão indicadas as forças atuantes em uma camada elementar.

Figura 6 – Forças existentes sobre a camada elementar



Fonte: Janssen (1895)

Para  $z = 0$  ( $z$  é a cota da altura), tem-se as Equações (1, 2 e 3) de Janssen para o cálculo das pressões horizontais, verticais e de atrito.

I) Pressão horizontal de carregamento para as paredes do silo:

$$Ph = \frac{\gamma}{\mu'} \cdot \frac{A}{U} (1 - e^{-zK\mu' \frac{U}{A}}) \quad (1)$$

Conhecendo a fórmula de Janssen para o cálculo da pressão horizontal, pode-se obter a pressão vertical e a pressão de atrito nas paredes.

II) Pressão vertical de carregamento para as paredes do silo:

$$Pv = \frac{Ph}{k} \quad (2)$$

III) Pressão de atrito de carregamento por  $1 \text{ m}^2$  de superfície de parede:

$$Pw = \mu' \cdot Ph \quad (3)$$

sendo:

$\gamma$  = peso específico do produto

$A$  = área da seção transversal horizontal do silo

$U$  = perímetro da seção transversal

$\mu' \mu'$  = parâmetro na equação de Janssen  $\mu = \text{tg} \Phi_w$

$z$  = cota da altura do produto acima da seção transversal considerada

Walker (1966) desenvolveu sua teoria sobre o fluxo de produtos para silos utilizando o fluxo de massa. Sua teoria também é baseada nas forças que atuam sobre uma camada elementar e é válida para as paredes e para a tremonha do silo, tanto nos cálculos as pressões estáticas e as pressões dinâmicas.

Walters (1973) aprofunda os estudos de Walker (1966) para silos com fluxo de massa, analisando as tensões desenvolvidas durante o carregamento e aquelas durante a descarga nas paredes verticais dos silos. A grande vantagem do uso de sua teoria é que é necessária apenas a determinação do ângulo de atrito com a parede e do efetivo ângulo de atrito interno. Além disso, Walters aplica um fator de segurança na zona de transição, onde se observa o local de maior tensão no silo.

Walker (1973) considera nas pressões estáticas nas paredes do silo um coeficiente de empuxo, dado através do efetivo ângulo de atrito interno. As pressões verticais e horizontais são calculadas pelas Equações (4 e 5).


$$P_v = \gamma \cdot z \quad (4)$$

$$P_h = k \cdot P_v \quad \text{onde: } k = \frac{1 - \text{sen} \phi_e}{1 + \text{sen} \phi_e} \quad (5)$$

As pesquisas desenvolvidas pelos pesquisadores Jenike e Johanson (1968), Jenike et al. (1973), Jenike (1985) e Jenike (1987) formam a base da teoria de armazenamento e fluxo dos produtos armazenados. A teoria de Jenike et al. (1973) explica o campo das tensões no produto armazenado por meio da definição de três estados de acordo com o tipo de fluxo que esteja acontecendo Figura (7).

- Estado estático (inicial ou de carregamento, Figura 7a) – a pressão inicial é representada na parte cilíndrica do silo de forma não linear e por uma distribuição linear na tremonha. O produto quando é carregado para dentro do silo, não apresenta grande impacto na estrutura, encontrando-se no estado ativo das tensões.
- Em fluxo (dinâmico ou de descarga, Figura 7b) – durante o fluxo, ocorre uma expansão vertical e uma contração lateral, estabelecendo o estado passivo de tensões.
- Transição (Figura 7c) – é o tempo em que os dois estados de tensão ativo e passivo coexistem. Neste instante ocorre uma sobrecarga de pressão exercida sobre as paredes do silo.

Figura 7 – Estados de tensões



Fonte: Palma (2005).

O desafio da determinação das curvas de pressões é devido a sua variabilidade no espaço e tempo (CALIL JR, 1990). Tornando-se alvo de estudos e discussões as pressões na fase de descarga do produto em relação a fase de carregamento, pois é na descarga do produto que ocorrer os maiores valores de pressões nas estruturas de silo (PALMA, 2005).

Mesmo com a determinação dos estudos das pressões, ainda existem diversos fatores sem resposta e que influenciam no comportamento estrutural dos silos. Por isso, Cheung (2007) afirmou que, para sanar tal situação é necessário diversos estudo analisando as pressões nos silos através de características variáveis e aleatórias.

Segundo Kaminski e Wirska (1998) as pressões verticais e as horizontais podem ser relacionadas por uma constante chamada de  $(K)$ . Essa constante tem seu valor bastante divergente nas pesquisas e nas normas. Algumas normas propõem que o parâmetro possa ser determinado através do efetivo ângulo de atrito interno. Em outras normas é levado em consideração além do efetivo ângulo de atrito interno também o ângulo de atrito com a parede. O que mostra que ainda existe bastante incerteza na determinação desse fator.

As Normas AS 3774 (1996) e EN 1991-4 (2006) adotam para as pressões estáticas nas paredes do silo as fórmulas propostas por Janssen (1895). Para o cálculo das pressões horizontal, vertical e de atrito com a parede, é utilizado o coeficiente de majoração  $(K)$  que está descrito na Tabela (4).

Tabela 4 – Pressões de carregamento na parede do silo

Normas	Pressões			Coeficiente K
	Ph	Pv	Pw	
AS 3774 (1996)	JANSSEN			$\frac{1 + \text{sen}^2 \Phi_e - 2\sqrt{\text{sen}^2 \Phi_e - \mu^2 \text{cos}^2 \Phi_e}}{4\mu^2 + \text{cos}^2 \Phi_e} \geq 0,35$
EN 1991-4 (2006)				$1,1(1 - \text{sen}^2 \Phi_e)$

Fonte: Adaptado de Janssen 1895

Para o cálculo das pressões dinâmicas ou de descargas as normas de uma forma geral utilizam coeficientes de majoração. Esses coeficientes são aplicados às pressões estáticas ou de carregamento para determinar as pressões dinâmicas.

Na Norma Europeia EN 1991-4 (2006) as pressões de descarga são obtidas multiplicando as pressões de carregamento (Equações 1, 2 e 3) pelos coeficientes de majoração  $C_w$  e  $C_h$ . Obtendo  $P_{wd}$  que é a pressão de atrito de descarga Equação (6) e  $P_{hd}$  que é a pressão horizontal de descarga Equação (7).

$$P_{wd} = C_w \cdot P_w \quad (6)$$

$$P_{hd} = C_h \cdot P_h \quad (7)$$

em que:

$$C_w = 1,1$$

$$C_h = 1,35 + 0,02 \cdot (\Phi_e - 30^\circ) \geq 1,35$$

Para a Norma Australiana AS 3774 (1996) a pressão horizontal de descarga  $P_{hd}$  é determinada utilizando a Equação (8).

$$P_{hd} = C_d \cdot P_h \quad (8)$$

No qual  $C_d$  será o maior valor das Equações (9 ou 10).

$$C_d = [7,6 \cdot \left(\frac{h^{0,06}}{d}\right) \left(\frac{h^{0,06}}{d}\right) - 6,4] \cdot C_c \quad (9)$$

$$C_d = 1,2 \cdot C_c \quad (10)$$

sendo:

$C_d$  = coeficiente de majoração

$C_c = 1,0$  para silos com fluxo simétrico

$C_c = 1,2$  para silos com fluxo planar

A pressão de atrito de descarga  $P_{wd}$  na norma AS 3774 (1996), foi obtida de acordo com a Equação (11).

$$P_{wd} = C_q \cdot P_w \quad (11)$$

em que:

$C_q = 1,2$  para silos com fluxo simétrico

$C_q = 1,4$  para silos com fluxo planar

## 2.7 Modelos experimentais

As estações experimentais de silos, consistem em estruturas de escalas reais ou reduzidas. Elas são instrumentadas de maneira a se obter dados decorrente de ensaios controlados de acordo com o interesse. Existem várias estações experimentais para analisar as ações em silos no mundo, como por exemplo Brown et al., 2000; Härtl et al., 2008; Ramirez et al., 2010; Schuricht et al., 2001; Teng e Lin, 2005; Zhong et al., 2001.

A vantagem da obtenção de dados experimentais, é conhecer de maneira mais aproximada, as ações provenientes da estrutura do silo em relação ao produto. Os resultados obtidos através do silo-piloto podem ser utilizados nos estudos de estruturas reais, sendo seu comportamento considerado idêntico em termos qualitativos e quantitativos à escala 1:1. Porém, o custo das estações experimentais é bastante elevado, sendo um dos fatores que restringem muito o campo de pesquisa nessa área (NIELSEN e ASKEGAARD, 1977).

Nos estudos de Wenzel (1963) apud Pieper e Schutz (1980) a estação experimental desenvolvida é constituída por silo armazenador, o elevador e o silo-piloto. O silo piloto tem seu cilindro segmentado em 12 anéis independentes e a tremonha acoplada na parte inferior da estrutura. Ao longo das paredes do silo, da tremonha e dos pilares de sustentação estão presentes sensores para determinar as forças e pressões atuantes. Por meio das equações de normas internacionais são obtidas das pressões horizontais, verticais e de atrito presentes no silo-piloto.

Brown et al. (2000) desenvolveram um silo-piloto prismático metálico no laboratório *Building Research Establishment* em Garston (Reino Unido). As dimensões do silo são 2,5m a altura das paredes do silo, com 1,5m de seção transversal e com 0,68m de altura a tremonha prismática. A espessura das chapas ao longo de todo silo é de 6 mm. O silo é instrumentado

com células de pressão distribuídas nas paredes e tremonha. Os estudos avaliaram que em silos prismáticos as pressões horizontais no mesmo nível variam muito. Isso acontece por conta das deformações nas chapas da estrutura do silo. A teoria de Janssen apresentou uma boa aproximação para as médias das pressões nessa situação.

Cheung (2007), utilizando um modelo experimental, desenvolvido por Pieper e Schutz (1980) padronizado pela norma DIN 1055 (1987), mostrou que é possível prever as pressões em silos. No trabalho foi utilizado a configuração do silo com paredes lisa, fundo plano e variando os produtos soja e ração, para as condições de carregamento e descarregamento. O objetivo do trabalho, foi determinar as pressões horizontais exercidas nas paredes do silo esbelto, metálico, cilíndrico.

Ramírez et al. (2010) projetaram uma estação experimental contendo três silos instrumentados e abastecidos por um elevador de caneca. A estação experimental foi construída na Escola Técnica Superior de Engenheiros Agrónomos (*Escuela Técnica Superior de Ingenieros Agrónomos - ETSIA*) na Universidade Politécnica de Madrid (Espanha). A estação tem como principal objetivo avaliar as pressões normais nas paredes e tremonha do silo. Priorizando com maior atenção a zona de transição entre as paredes e a tremonha do silo. As paredes do silo possuem 5,0 m de altura e 1,9 m de diâmetro. As tremonhas contem 1,9 m de altura e bocal de descarga de 0,32 m. O sistema contém 12 sensores para determinar os valores das pressões.

Couto, Ruiz e Aguado (2012) desenvolveram na Universidade de León (Espanha) uma estação-teste com silos de tamanho médio e com escala real, sendo possível a medição das pressões em silos sob diferentes condições. O silo é instrumentado, e possui 2,0m de altura por 1,0m de diâmetro. No modelo proposto é possível obter as pressões horizontais nas paredes do silo de acordo com a altura, as pressões na zona de transição entre as paredes do silo e a tremonha, as pressões verticais, a pressão de atrito média no corpo do silo e também a relação entre as pressões horizontais e verticais ( $K$ ). A estação possibilita diversas variáveis, como a utilização de fundo plano ou tremonhas, ambos com descargas de diferentes excentricidades, o controle da velocidade de carregamento e diferentes relações de altura diâmetro ( $H/D$ ). Com essas variações a estação possibilita diversas condições utilizando a escala real.



## 2.8 Trabalhos correlacionados

Diversos trabalhos foram desenvolvidos na área de comportamento dos silos relacionados à estrutura, ao fluxo e as ações utilizando o método das redes neurais artificiais - RNA's (Yuksel e Arslan (2010); Reis, 2011).

O trabalho de Yuksel e Arslan (2010) tem grande relevância, pois eles utilizaram RNA's para determinar as forças de interação de quatro silos cilíndricos de concreto armado com as combinações dos silos cheios e vazios. Nesse trabalho também foi utilizado RNA como metodologia para o cálculo das tensões. E mais uma vez foi confirmado a eficácia das RNA's para cálculo das tensões.

Na área de comportamento de silos, o trabalho de Reis (2011) utilizou RNA para a obtenção das pressões horizontais, verticais e de atrito. Foi utilizado as propriedades físicas de produtos agrícolas e sólidos nas equações das normas internacionais, para determinação das pressões. Neste trabalho verificou a confiabilidade no uso de RNA no cálculo das pressões em silos.

A utilização de RNA para problemas relacionados a previsões de pressões em silos e confiabilidade estrutural, vem sendo utilizada e apresentando resultados positivos. A motivação para o desenvolvimento do trabalho baseia-se na perspectiva de aumento no setor do agronegócio e o volume relativamente pequeno de pesquisas nesta direção, por se tratarem de projetos de custo bastante elevado. Portanto, torna-se um instrumento favorável para a pesquisa e previsão das ações, possibilitando assim o aumento da confiabilidade nas estruturas de armazenamento.

## 2.9 Redes neurais artificiais

As redes neurais artificiais (RNA's), é também conhecida como sistemas de processamento paralelo e distribuído. A primeira rede neural foi concebida por Warren McCulloch e Walter Pitts em 1943. Eles escreveram um artigo sobre como os neurônios devem funcionar e, então, modelaram suas ideias criando uma rede neural simples com circuitos elétricos (BRAGA, CARVALHO e LUDERMIR, 2007).

A metodologia de redes neurais artificiais pode ser utilizada em diversas áreas, como por exemplo da saúde, lazer, militar, entre outras. Sua aplicação no Brasil aconteceu no final dos anos 80 e na engenharia de estruturas deu-se no início dos anos 90 (SILVA; PATTI; FLAUZINO, 2010).

As RNA's são sistemas paralelos distribuídos, compostos por unidades de processamento que calculam determinadas funções matemáticas (normalmente não-lineares).

Tais unidades são dispostas em uma ou mais camadas e interligadas por um grande número de conexões. Essas conexões estão associadas a pesos, os quais armazenam o conhecimento representado no modelo. Esses pesos servem para ponderar a entrada recebida por cada neurônio da rede (GOLAFSHANI E BEHNOOD, 2018).

Redes neurais artificiais são algoritmos numéricos inspirados na estrutura do cérebro humano. Elas têm várias funções bem semelhantes ao cérebro humano, como por exemplo o reconhecimento de padrões e processamento de dados (FURTADO, 2019).

Uma grande vantagem no uso das RNA's na solução de problemas é a capacidade de aprender através de exemplos e de generalizar a informação aprendida. A generalização, que está associada à capacidade da rede de aprender através de um conjunto reduzido de exemplos. E, posteriormente, a rede poder dar respostas coerentes para dados não-conhecidos. Isso demonstra a capacidade das RNA's ir muito além do que simplesmente mapear relações de entrada e saída. Sendo assim, RNA's é um tipo de ferramenta computacional extremamente importante para a solução de problemas complexos (GOLAFSHANI E BEHNOOD, 2018).

Segundo Furtado (2019) muitas outras aplicações são constantemente encontradas para as RNA's, as áreas de aplicação são as mais diversas, resolvendo problemas que envolvam extração de características, classificação, categorização, estimativa e previsão; otimização; aproximação de funções; dentre outras. Acredita-se que as pesquisas de um modo geral podem se beneficiar ainda mais do desenvolvimento de modelos que tenham a utilização de RNA's.

### **2.9.1 Neurônio biológico**

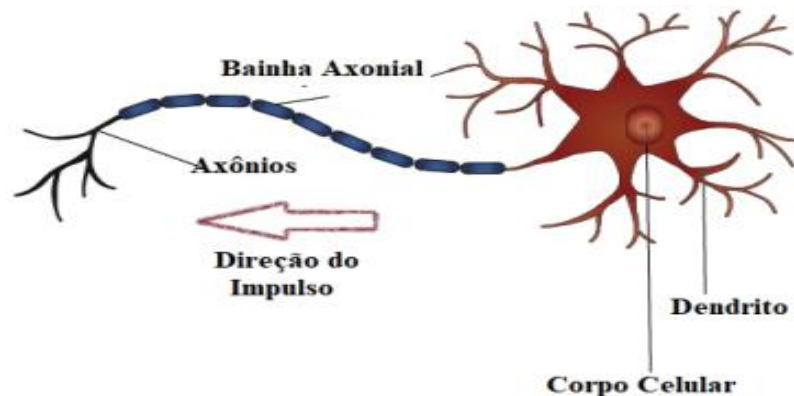
Os neurônios são unidades que apresentam a propriedade de responder a alterações do meio em que se encontram (estímulos). Eles são formados por um corpo celular, que contém o núcleo. O núcleo funciona também como um receptor e integrador de estímulos. Do corpo partem prolongamentos numerosos, os dendritos (do grego, *dentron* = árvore), especializados na função de receber estímulos representado na Figura (8). Eles aumentam consideravelmente a superfície celular, tornando possível receber e integrar impulsos trazidos por numerosos terminais axônicos. O axônio (do grego, *áxon* = eixo) é um prolongamento único, especializado na condução de impulsos que transmitem informações a outras células nervosas. Assim, em geral, as informações são recebidas pelos dendritos e corpo celular e emitidas pelo axônio (FURTADO, 2019).

Segundo Vazirizade, Nozhati e Zadeh (2017) os neurônios são divididos em três seções: o corpo da célula, os dendritos e o axônio, cada um com funções específicas, porém complementares. O corpo do neurônio mede apenas alguns milésimos de milímetros, e os

dendritos apresentam poucos milímetros de comprimento. O axônio, contudo, pode ser mais longo e, em geral, tem calibre uniforme. Os dendritos têm por função receber as informações, ou impulsos nervosos, oriundas de outros neurônios e conduzi-las até o corpo celular. No corpo celular, a informação é processada e novos impulsos são gerados. Estes impulsos são transmitidos a outros neurônios, passando através do axônio até os dendritos dos neurônios seguintes.

O ponto de contato entre a terminação axônica de um neurônio e o dendrito de outro é chamado de sinopse. É pelas sinapses que os nodos se unem funcionalmente, formando redes neurais. As sinapses funcionam como válvulas, e são capazes de controlar a transmissão de impulsos. O efeito das sinapses é variável, e é esta variação que dá ao neurônio capacidade de adaptação. A Figura (8) ilustra de forma simplificada, os componentes do neurônio. Este sistema simples é responsável pela maioria das funções realizadas pelo nosso cérebro. A capacidade de realizar funções complexas surge com a operação em paralelo de todos os nodos do nosso cérebro (VAZIRIZADE, NOZHATI E ZADEH, 2017).

Figura 8 – Representação da estrutura de um neurônio biológico

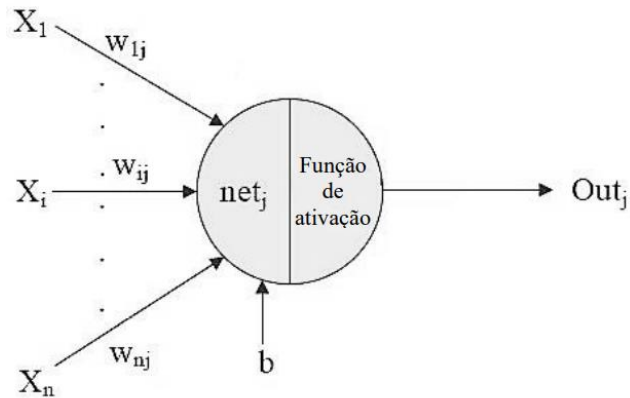


Fonte: Adaptado de FURTADO (2019)

Uma RNA é uma organização de neurônios artificiais em camadas que comunicam entre si. Um neurônio artificial é uma estrutura lógica que recebe informação e a processa de acordo com alguma regra interna.

A rede neural artificial é formada por simuladores de neurônios, esses simuladores podem fazer uma variação nas forças dessas conexões e também nos estímulos propostos para rede, tendo assim a aprendizagem da mesma. A Figura (9) ilustra um neurônio artificial e os seus componentes.

Figura 9 – Neurônio artificial



Fonte: Adaptado de Golafshani e Behnood (2018)

O princípio de funcionamento dos neurônios artificiais inicia-se com a apresentação dos sinais de entrada  $X_i$ , que são multiplicados pelos seus pesos correspondentes  $W_i$ . O “b” corresponde ao bias que é uma entrada especial, de valor constante +1 multiplicado por um peso  $b_k$ , que pode aumentar ou reduzir a importância dos sinais de entrada. Em seguida é feita a soma ponderada dos sinais de entrada, descrita por  $net_j$ , esse resultado passa pela função de ativação que produz a saída do neurônio artificial (GOLAFSHANI E BEHNOOD, 2018).

As Equações (12) e (13) descrevem matematicamente o funcionamento de um neurônio artificial. Essas equações foram propostas por Golafshani e Behnood (2018).


$$net_j = \sum_{i=1}^n w_{ij}x_i + b \quad (12)$$

$$\sum_{i=1}^n w_{ij}x_i + b$$

$$out_j = f(net_j) \quad (13)$$

Segundo Golafshani e Behnood (2018) a função de ativação descrita como  $(v_k)$  define a saída da RNA. As principais funções de ativação são Função Limiar, Linear por Partes, Sigmoide e ReLU, descritas nas Figuras (10, 11, 12 e 13), com Equações (14, 15, 16 e 17).


Figura 10 – Função de limiar



Fonte: Adaptado de Golafshani e Behnood (2018)

$$f(\text{net}_j) = \begin{cases} 1 & \text{se } \text{net}_j \geq 0 \\ 0 & \text{se } \text{net}_j < 0 \end{cases} \quad (14)$$


Figura 11 – Função linear por partes



Fonte: Adaptado de Golafshani e Behnood (2018)

$$f(\text{net}_j) = \begin{cases} 1, & \text{net}_j \geq +\frac{1}{2} \\ \text{net}_j + \frac{1}{2} > \text{net}_j > -\frac{1}{2} \\ 0, & \text{net}_j \leq -\frac{1}{2} \end{cases} \quad (15)$$


Figura 12 – Função sigmoide



Fonte: Adaptado de Golafshani e Behnood (2018)

$$f(\text{net}_j) = \frac{1}{1 + \exp(-\alpha \text{net}_j)} \quad (16)$$

Figura 13 – Função ReLU



Fonte: Adaptado de Golafshani e Behnood (2018)

$$f(\text{net}_j) = \max(z, 0) \quad (17)$$


### 2.9.2 Arquitetura das RNA's

As redes neurais possuem três níveis de camadas de neurônios. A arquitetura da RNA é fundamental para que se obtenha a melhor resposta de saída de acordo com o problema estudado. A melhor arquitetura para uma RNA é aquela que é mais eficiente para solução do problema abordado. Essa escolha é feita através de várias tentativas, até que se encontre uma que ofereça melhor desempenho possível. A arquitetura da RNA é dividida no número de camadas ocultas da rede e no número de neurônios em cada camada (VAZIRIZADE, NOZHATI E ZADEH, 2017).

Segundo Vazirizade, Nozhati e Zadeh (2017) as camadas da RNA são descritas em etapas da seguinte forma Figura (14):

- Camada de entrada: são os dados de entrada no sistema, onde as propriedades ou padrões são apresentados à rede.
- Camada de saída: são os dados gerados pela rede (resposta inteligente), onde saem os resultados, consistindo na última camada.
- Camada intermediária ou oculta: são os neurônios que atribuem os pesos e funções, onde ocorre a maior parte do processamento. Situadas entre a camada de entrada e de saída.

Figura 14 – Estrutura de uma rede neural



Fonte: Golafshani e Behnood (2018)

A RNA classificada como *feedforward* é alimentada sempre adiante, e pode ser uma estrutura chamada de *feedforward* de camada única ou *feedforward* múltiplas camadas. Na RNA de *feedforward* de camada única, possui uma de camada de entrada que se projeta sobre a camada de neurônios de saída. As redes que são chamadas de *feedforward* com camada composta, são aquelas que apresentam camadas ocultas, além da camada de entrada e saída. Os neurônios ocultos intervêm entre a entrada e a saída da rede. Quando se adicionam as camadas ocultas, aumenta a capacidade da rede de extrair estatísticas de ordem mais elevada (BRAGA, CARVALHO e LUDERMIR, 2007). A Figura (15A) ilustra uma RNA *feedforward* de camada única e a Figura (15B) ilustra uma RNA *feedforward* de múltiplas camadas.

Figura 15A – Rede neural artificial  
*feedforward* de camada única





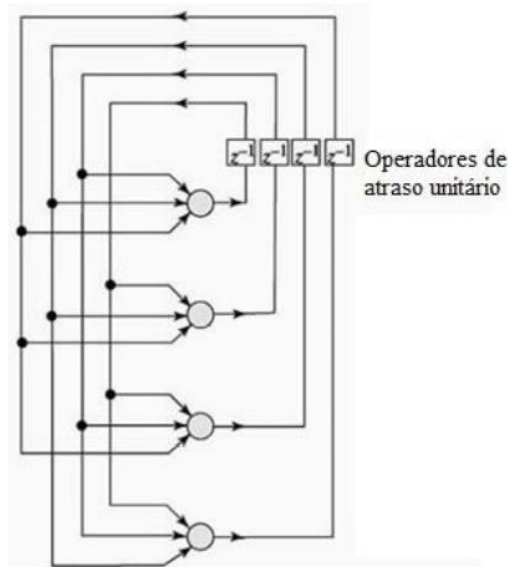
Figura 15B – Rede neural artificial  
*feedforward* de múltiplas camadas



Fonte: Adaptado de Golafshani e Behnood (2018)

Existem também as RNA's do tipo recorrentes em que a saída do neurônio é reinserida novamente na RNA, conforme ilustrado na Figura (16). Quando a RNA é recorrente, ela possui pelo menos um laço de realimentação, no qual cada neurônio alimenta seu sinal de saída de volta para as entradas de todos os outros neurônios (GOLAFSHANI E BEHNOOD, 2018).

Figura 16 – Rede neural artificial recorrente



Fonte: Adaptado de Golafshani e Behnood (2018)

### 2.9.3 Treinamento das RNA's

As redes neurais artificiais possuem a capacidade de aprender por exemplos e fazer interpolações e extrapolações do que aprenderam. É necessário um conjunto de procedimentos bem definidos para que a RNA possa aprender uma determinada função, essa aprendizagem é chamada de algoritmo de aprendizado. Existem vários tipos de algoritmo de aprendizado. Estes algoritmos diferem pela maneira pela qual o ajuste dos pesos é feito (VAZIRIZADE, NOZHATI E ZADEH, 2017).

De acordo com Reis (2011) o desenvolvimento do algoritmo de aprendizagem *backpropagation*, sem dúvida, foi um dos maiores avanços nos estudos em RNA's, pois, esse tipo de algoritmo de aprendizagem foi o pioneiro no ajuste de pesos em redes neurais de multicamadas, permitindo o desenvolvimento de redes de forma mais genéricas.

O *backpropagation* é um algoritmo de treinamento supervisionado, pode ser usado em redes que tenham neurônios com qualquer tipo de função de ativação. Este algoritmo permite modificar aos poucos os valores das sinapses de modo a otimizar a saída da rede (FURTADO, 2019).

O algoritmo *backpropagation* consiste em duas fases, onde inicialmente, realiza-se a propagação para frente, sendo que, os pesos gerados aleatoriamente são multiplicados pelos



seus respectivos sinais de entrada. Posteriormente, realiza-se então, a soma e, a função de ativação fornece a saída da rede que é subtraída do valor da saída esperada. Em um segundo momento, os pesos são ajustados e propagados para trás para serem atualizados. Esse processo se repete até que a saída da RNA seja igual a saída esperada ou atenda aos critérios de interrupção do treinamento (ISAAC JÚNIOR, 2018).

O algoritmo *backpropagation* é descrito matematicamente por Isaac Júnior (2018) da seguinte forma, na fase de propagação para frente, toma-se um exemplo de treinamento da época representado por  $(x(n), d(n))$ , com o vetor de entrada  $x(n)$  aplicado na camada de entrada de neurônios e o vetor de saída esperada  $d(n)$  é apresentado a camada de saída de neurônios. O campo local induzido  $v_j^{(l)}(n)$  para o neurônio  $j$  na camada  $l$  é determinado pela Equação (18).

$$v_j^{(l)}(n) = \sum_{i=0}^{m_0} w_{ji}^{(l)}(n) y_i^{l-1} \quad (18)$$

sendo:

$v_j^{(l)}(n)$ : é o campo local induzido para o neurônio  $j$  na camada  $l$ ;

$y_i^{l-1}(n)$ : é o sinal de saída do neurônio  $i$  na camada anterior  $l - 1$ , na iteração  $n$ ;

$w_{ji}^{(l)}(n)$ : é o peso do neurônio  $j$  da camada  $l$ , alimentado pelo neurônio  $i$  da camada  $l - 1$ .

Para  $i = 0$ , tem-se  $y_0^{l-1}(n) = +1$  e  $w_{j0}^{(l)}(n) = b_j^{(l)}(n)$  é o bias aplicado ao neurônio  $j$  na camada  $l$ .

Utilizando uma função sigmoide, o sinal de saída do neurônio  $j$  na camada  $l$  é calculado pela Equação (19).

$$v_j^{(l)}(n) = \varphi_j(v_j^{(l)}(n)) \quad (19)$$

Em que,

$v_j^{(l)}(n)$ : é a saída do neurônio  $j$  na camada  $l$ ;

$\varphi_j(v_j^{(l)}(n))$ : função de ativação sigmoide no  $j$ -ésimo neurônio na camada de saída no instante  $n$ .

Em seguida, calcula-se o sinal do erro pela Equação (20).

$$e_j(n) = d_j - o_j(n) \quad (20)$$

Sendo,

$d_j(n)$ : é o  $j$ -ésimo elemento do vetor resposta desejada  $d(n)$ ;

$o_j(n)$ : é o sinal funcional na saída do neurônio  $j$ .

Posteriormente, inicia-se a fase de retropropagação do erro. Calcula-se os  $\delta$ s (i.e., gradientes locais) da rede, definidos por:

- Para o neurônio  $j$  da camada de saída  $L$  usa-se a Equação (21).

$$\delta_j^{(l)}(n) = e_j^{(L)}(n) \varphi_j'(v_j^{(L)}(n)) \quad (21)$$

- Para o neurônio  $j$  da camada oculta  $l$  adota-se a Equação (22).

$$\delta_j^{(l)}(n) = \varphi_j'(v_j^{(l)}(n)) \sum_k \delta_k^{(l+1)}(n) w_{kj}^{(l+1)}(n) \quad (22)$$

A apóstrofe em  $\varphi_j'(\cdot)$  representa a diferenciação em relação ao argumento. Realiza-se o ajuste dos pesos da rede na camada  $l$  utilizando a Equação (23).

$$w_{ji}^{(l)}(n+1) = w_{ji}^{(l)}(n) + \alpha [w_{ji}^{(l)}(n-1)] + \eta \delta_j^{(l)}(n) y_i^{(l-1)}(n) \quad (23)$$

Sendo,  $\eta$ : é a taxa de aprendizado e  $\alpha$  é a constante de momento.

Esse procedimento é executado até que seja satisfeito o critério de parada estabelecido.

De acordo com Golafshani e Behnood (2018) no treinamento da rede, a taxa de aprendizado é uma constante que controla a taxa com que os pesos serão ajustados. Quanto menor for esse parâmetro, menores serão as variações dos pesos da rede de uma iteração para outra. E também mais suave será a trajetória no espaço dos pesos, porém isso implica em um treinamento lento. Por outro lado, se a taxa de aprendizado for muito elevada, o treinamento será acelerado com grandes modificações nos pesos o que pode tornar a rede instável.

A constante de momento é um número positivo que ao ser incorporado no algoritmo *backpropagation*, proporciona uma pequena modificação na atualização dos pesos. O termo de momento pode evitar que o processo de treinamento da RNA termine em um mínimo local na superfície de erro ao invés do mínimo global que é o objetivo do processo de aprendizagem. Para o critério de parada do algoritmo *backpropagation* geralmente é utilizado um número máximo de épocas, considerando a taxa de erro médio por época (GOLAFSHANI E BEHNOOD, 2018).

## 2.10 Regressão linear e polinomial

É possível através das análises de regressão estabelecer relações entre a variável dependente e as variáveis independentes. Os modelos de regressão podem ser empregados para estudos de decisões, formar impressões ou atitudes.

### 2.10.1 Regressão linear simples

A regressão linear simples, é um procedimento para prever dados. Ela utiliza a regra de minimização da soma de quadrados dos erros. Na análise de regressão linear, é considerada

apenas uma variável independente. Na representação da regressão linear simples a equação tem como forma uma reta (ROMITTI, 2014).

O modelo de regressão linear simples, conforme Hoffmann e Vieira (1998), pode ser expresso de acordo com a Equação (24).

$$y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_k x_{ki} + \varepsilon_i \quad (24)$$

em que:

$y_i$  = i-ésimo valor da variável resposta, sendo  $i = 1, 2, \dots, N$  observações

$x_{ki}$  = i-ésimo valor da k-ésima variável explicativa, sendo  $k=1, 2, \dots, K$  variáveis

$\beta_k$  = parâmetros do modelo

$\varepsilon_i$  = erros aleatórios

### 2.10.2 Regressão polinomial

De acordo com Romitti (2014) na utilização de regressão polinomial é possível estabelecer relação funcional entre uma variável dependente e várias variáveis independentes. A influência da variável independente pode ser em vários graus (linear, quadrático, cúbico etc.). As regressões polinomiais são representadas de acordo com o grau linear, quadrática ou grau  $p$ , através das Equações (25, 26 e 27).

$$y_i = \beta_0 + \beta_1 x_{li} + \varepsilon_i \quad (25)$$

$$y_i = \beta_0 + \beta_1 x_{li} + \beta_2 x_{li}^2 + \varepsilon_i \quad (26)$$

$$y_i = \beta_0 + \beta_1 x_{li} + \beta_2 x_{li}^2 + \beta_p x_{li}^p + \varepsilon_i \quad (27)$$

Sendo:

$\beta$  = coeficientes de regressão

$\varepsilon$  = erro ou variância do coeficiente de regressão

$p$  = número de parâmetros

Na forma matricial, a regressão polinomial pode ser representada de acordo com a Equação (28).

$$Y = \begin{bmatrix} Y_1 \\ Y_2 \\ \dots \\ Y_n \end{bmatrix}; X = \begin{bmatrix} 1 & X_1 & X_1^2 & \dots & X_1^p \\ 1 & X_2 & X_2^2 & \dots & X_2^p \\ \dots & \dots & \dots & \dots & \dots \\ 1 & X_n & X_n^2 & \dots & X_n^p \end{bmatrix}; \beta = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \dots \\ \beta_p \end{bmatrix} \text{ e } \varepsilon = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \dots \\ \varepsilon_n \end{bmatrix} \quad (28)$$

## 2.11 Métricas de desempenho

As métricas de desempenho são medidas quantificáveis usadas para analisar o resultado de um processo, são medidas que avaliam o desempenho dos resultados. Existem várias métricas de desempenho que são próprias para avaliar o resultado de previsões das RNA's, como por exemplo o coeficiente de determinação ( $R^2$ ), erro médio absoluto (MAE), erro médio absoluto percentual (MAPE), e o erro médio quadrático (RMSE).

### 2.11.1 Coeficiente $R^2$

O coeficiente de determinação, também chamado de  $R^2$ , é uma medida de ajuste de um modelo estatístico. Esse coeficiente nos fornece o grau de correlação entre a variável dependente e a variável independente. O coeficiente  $R^2$  pode variar entre 0 e 1, sendo expresso em termos percentuais (%). Esse coeficiente estatístico expressa a quantidade da variância dos dados. Assim, quanto maior o  $R^2$ , mais explicativo é o modelo, ou seja, melhor ele se ajusta à amostra (DEVORE, 2006). A equação para calcular o coeficiente  $R^2$  é a divisão da soma dos valores observados menos os valores médios observados ao quadrado, pelos valores observados menos os valores estimados ao quadrado, descrito na Equação (29).

$$R^2 = 1 - \frac{SQ_{tot}}{SQ_{res}} = 1 - \frac{\sum_{i=1}^n (a_i - am)^2}{\sum_{i=1}^n (a_i - y_i)^2} \quad (29)$$

sendo,

$a_i$  = Dados reais (teste)

$y_i$  = Dados estimados

$am$  = Média dos dados reais

$n$  = quantidade de dados

### 2.11.2 Erro médio absoluto - MAE

Erro médio absoluto (MAE) é uma das métricas mais utilizadas para avaliar métodos de previsão. Segundo Lopes (2002), o MAE consiste na média da diferença absoluta entre valores realizados (reais) e os valores previstos (estimados). Quanto menor o valor do MAE, melhor está o modelo de previsão. A Equação (30) é utilizada para calcular o MAE.

$$MAE = \frac{\sum_{i=1}^n |ai - yi|}{n} \quad (30)$$

em que:

$ai$  = Dados reais (teste)

$yi$  = Dados estimados

$n$  = quantidade de dados

### 2.11.3 Erro médio percentual absoluto - MAPE

O erro médio percentual absoluto (MAPE) é uma métrica bastante utilizada para avaliar métodos de estimativas, e fornece a taxa de erro em termos percentuais (%). Segundo Lopes (2002), o erro médio percentual absoluto é a média de todos os erros absolutos percentuais, fornecendo uma indicação do tamanho médio do erro, expresso como uma porcentagem que quanto menor o valor, mais preciso será o modelo. A Equação (31) é utilizada para o cálculo do MAPE.

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{ai - yi}{ai} \right| * 100}{n} \quad (31)$$

Sendo:

$ai$  = Dados reais (teste)

$yi$  = Dados estimados

$n$  = quantidade de dados

### 2.11.4 Erro médio quadrático – RMSE

O erro médio quadrático (RMSE) é o desvio padrão da amostra da diferença entre os valores previstos (estimados) e os valores realizados (reais). Quanto menor o valor, melhor foi sua representatividade do modelo. O RMSE é calculado pela Equação (32).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (ai - yi)^2}{n}} \quad (32)$$

em que:

$ai$  = Dados reais (teste)

$yi$  = Dados estimados

$n$  = quantidade de dados

### **3 CONSIDERAÇÕES GERAIS**

O cálculo e a determinação das pressões nas paredes dos silos são os principais objetos de estudo utilizados no dimensionamento estrutural. Os modelos teóricos e as Normas baseiam-se em propriedades físicas do produto e características geométricas da estrutura calculada. O uso de Normas e a ponderação dos coeficientes de majoração, conduzem a escolha da norma específica para a situação em estudo. No cálculo de estruturas de silos metálicos, dentre as normas utilizadas, podemos optar pelas Normas EN 1991-4 (2006) e AS 3774 (1996).

Dentre as técnicas e métodos matemáticos de previsão de ações nas estruturas, a inteligência computacional RNA é adequada para previsão dos valores das pressões horizontais e de atrito nas paredes dos silos. Com o desenvolvimento de algoritmos é possível prever as ações nas paredes do silo, utilizando configurações e características físicas diferentes. A aplicação da tecnologia de RNA na determinação das ações e na construção desse tipo de estrutura é eficiente e precisa, sugerindo uma maior segurança e, conseqüentemente, prevenindo diversas patologias e até mesmo colapsos nas estruturas.

## REFERÊNCIAS BIBLIOGRÁFICAS

- AIRY, W. Comparison of various methods used in the analysis of silos without wall friction. Computational Methods and Experimental Measurements XII 425. Department of Civil Engineering, Lebanese University, Lebanon. p. 425-441, 1897.
- AMERICAN CONCRETE INSTITUTE. **ACI 313**: Standard Practice for Design and Construction of Concrete Silos and Stacking Tubes for Storing Granular Materials. EUA, 1991.
- AMERICAN NATIONAL STANDARDS INSTITUTE. **ANSI/ASAE EP 433:1991** (reaffirmed DEC/2001). Loads exerted by free-flowing grain on shallow storage structures. EUA, 2001.
- ARNOLD, P. C.; MCLEAN, A. G.; ROBERTS, A. W. **Bulk solids: Storage, flow and handling**. Newcastle, Australia, University of Newcastle, 1982.
- AUSTRALIAN STANDARD **AS 3774**. (1996) Loads on bulk containers. Sydney. AS 3774 Supplement 1 (1996).” Loads on bulk containers – Commentary. Sydney.
- BRAGA, A. P., CARVALHO, A. P. L., LUDERMIR, T. B. Redes Neurais Artificiais: Teoria e Aplicações. Livros técnicos e científicos. Ed. S.A. Rio de Janeiro - RJ. 2007.
- BROWN, C. J.; LAHLOUH, E. H.; ROTTER, J. M. Experiments on a square planform steel silo. **Chemical Engineering Science**, v. 55, n. 20, p. 4399-4413, 2000.
- CANADIAN FARM BUILDING CODE **CBFC** - Part 2, Structural design. Ottawa, Canada, 1983.
- CALIL Jr. Determinação das propriedades físicas de materiais granulares e pulverulentos para o projeto estrutural. **Revista Brasileira de Armazenagem**, Viçosa, v.9-10, n.1-2, p. 3-6, 1984-1985.
- CALIL Jr, C.; NASCIMENTO, J.W.B. Ações em silos pelo método dos estados limites: proposta de norma brasileira. **Engenharia Agrícola, Jaboticabal**, v. 16, n. 4, p. 110-117, 1997.
- CALIL Jr, C.; CHEUNG, A. B. Silos: pressões, fluxo, recomendações para o projeto e exemplos de cálculo. **Escola de Engenharia de São Carlos. USP. São Carlos. SP**, 2007.

CHEUNG, A. B. **Modelo estocástico de pressões de produtos armazenados para a estimativa da confiabilidade estrutural de silos esbeltos**. Tese de doutorado. EESC/USP – São Carlos – SP. 305p. 2007.

CONAB. COMPANHIA NACIONAL DE ABASTECIMENTO. Acompanhamento de safra brasileiro – grãos: Nono levantamento, junho 2018 – safra 2017/2017: Brasília: Companhia Nacional de Abastecimento. 2017. Disponível em: <https://www.conab.gov.br/armazenagem/serie-historica-da-armazenagem> . Acesso em: 02 jul. 2020.

COUTO, A.; RUIZ, A.; AGUADO, P. J. **Design and instrumentation of a mid-size test station for measuring static and dynamic pressures in silos under different conditions - Part I: Description**. Computers and Electronics in Agriculture, v. 85, p. 164-173, 2012.

DEUTSCHE NORM – **DIN 1055**. Design loads for buildings: loads in silo bins. Berlin: Deutsche Norm, 1987. 6p.

DEUTSCHE NORM - **DIN 1055-6**: Basis of design and actions on structures – Part 6: design loads for buildings and loads in silo bins. Berlin, Verlaz, 2005.

DEVORE, Jay L. **Probabilidade e Estatística para Engenharia e Ciências**. Editora Thomson, 2006.

EUROPEAN COMMITTEE OF STANDARDIZATION. **EN 1991-4**: Eurocode 1: Basis of Design and Actions on Structures, Part 4 – Silos and Tanks. CEN, Brussels, 2006.

FURTADO, M. I. V. **Redes neurais artificiais: uma abordagem para sala de aula**. Ponta Grossa – PR. Ed. Atena, 2019.

FUSCO, P. B. **Estruturas de concreto: fundamentos do projeto estrutural**. McGraw-Hill, 1976.

GOLAFSHANI, E. M.; BEHNOOD, A. **Application of soft computing methods for predicting the elastic modulus of recycled aggregate concrete**. *Journal of Cleaner Production*, v. 176, p. 1163–1176, 2018.

HAYKIN, S. **Redes neurais: princípios e prática**. 2 ed. Porto Alegre: Bookman, 2001. 900 p.



- HAERTL, J. et al. The influence of a cone-in-cone insert on flow pattern and wall pressure in a full-scale silo. **chemical engineering research and design**, v. 86, n. 4, p. 370-378, 2008.
- HOFFMANN, R.; VIEIRA S. **Análise de regressão: uma introdução à econometria**. 3. ed. São Paulo: HUCITEC, 1998. 379p.
- INTERNATIONAL ORGANIZATION FOR STANDART **ISO 11697**: Bases for design of structures: Loads due to bulk materials, London, 2012.
- ISAAC JÚNIOR, M. A. **Modelo misto e rede neural artificial para estimativas dendométricas de árvores individuais**. 2018. 82 f. Tese (Doutorado em Engenharia Florestal) - Departamento de ciências florestais, Universidade Federal de Lavras, Lavras – MG.
- JANSSEN, H. A. Versuchüber Getreidedruck in Sillozellen. **Zeitschrift des Vereins Deutscher Ingenieure**, v. 39, p. 1045–1049, 1895.
- JENIKE, A. W. New developments in the theory of particulate solids flow. **EFCE, Serie No49, Bergen, Norway**, 1985.
- JENIKE, A. W. A theory of flow of particulate solids in converging and diverging channels based on a conical yield function. **Powder technology**, v. 50, n. 3, p. 229-236, 1987.
- JENIKE, Andrew W.; JOHANSON, Jerry R. Bin loads. **Journal of the Structural Division**, v. 94, n. 4, p. 1011-1042, 1968.
- JENIKE, A. W.; JOHANSON, J. R.; CARSON, J. W. Bin loads—Part 2: concepts. **Journal of Engineering for Industry**, v. 95, n. 1, p. 1-5, 1973.
- KAMINSKI, M.; WIRSKA, E. Variation of pressures in flexible walled silo model. **Powder Handling & Processing**. V.10 n.4, p.349-355, 1998.
- LOPES, R.D. **Previsão de Autopeças: Estudo de Caso em uma Concessionária de Veículos**. Dissertação de Mestrado. UFSC, 2002.
- NIELSEN, J; ASKEGAARD, V. Scale errors in model tests on granular media with special reference to silo models. **Powder technology**, v. 16, n. 1, p. 123-130, 1977.
- PALMA, G; CALIL Jr, C. **Pressões e fluxo em silos esbeltos**. São Carlos, 2005.

PIEPER, K.; SCHÜTZ, M. Bericht Über das Forschungsvorhaben - **Norm-Mess-Silo für Schüttguteigenschaften**. Technische Universität Braunschweig - Lehrstuhl für Hochbaustatik, Deutschland. 1980.

RAMÍREZ, A.; NIELSEN, J; AYUGA, F. Pressure measurements in steel silos with eccentric hoppers. **Powder Technology**, v. 201, n. 1, p. 7-20, 2010.

REIMBERT, M. A. **Silos: Teoría e Práctica**. Editorial Américalee S.R.L. Buenos Aires. 464 p. 1979.

REIS, S. G. dos. **Determinação das ações atuantes nos silos através de redes neurais artificiais**. 2011. 76 p. Dissertação (Mestrado em Engenharia de Sistemas) - Universidade Federal de Lavras, Lavras, 2011.

ROBERTS, A. W. 100 years of Janssen. **Storage Bulk Solids Handling**, v. 15, n. 3, p. 369-383, 1995.

ROBERTS, A. W; McLEAN, A. G; ARNOLD, P.C. **Determination of bin geometry**. Paper 5. Storage, Flow and Handling of Bulk Solids. 1987.

ROMITTI, M. V. A modelagem matemática da aveia no ajuste da densidade populacional no principal biotipo cultivado. 2014. 131p. Dissertação (Mestrado em Modelagem Matemática) - Universidade Regional do Noroeste do Estado do Rio Grande do Sul, Ijuí, 2014.

SCHULZE, D. Silos-Design Variants and Special Types. **Bulk Solids Handling**, v. 16, n. 2, p. 225-232, 1996.

SCHURICHT, T; FÜRL, C; ENSTAD, G. G. Full scale silo tests and numerical simulations of the „cone in cone” concept for mass flow. In: **Handbook of Powder Technology**. Elsevier Science BV, 2001. p. 175-180.

SILVA, I; SPATTI, D. H; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas**. São Paulo: Artliber, v. 23, n. 5, p. 33-111, 2010.

TENG, J. G.; LIN, X. Fabrication of small models of large cylinders with extensive welding for buckling experiments. **Thin-walled structures**, v. 43, n. 7, p. 1091-1114, 2005.

WALKER, D. M. An Approximate Theory for Pressures and Arching in Hoppers. **Chemical Engineering Science**, v. 21, p. 975-997, 1966.

WALTERS, J. K. A theoretical analysis of stresses in silos with vertical walls. **Chemical Engineering Science**, v. 28, n. 1, p. 13-21, 1973.

YUKSEL, S. Bahadir; ARSLAN, M. Hakan. Design force estimation using artificial neural network for groups of four cylindrical silos. **Advances in Structural Engineering**, v. 13, n. 4, p. 681-693, 2010.

ZHONG, Z.; OOI, J. Y.; ROTTER, J. M. The sensitivity of silo flow and wall stresses to filling method. **Engineering structures**, v. 23, n. 7, p. 756-767, 2001.

## SEGUNDA PARTE – ARTIGOS

### ARTIGO 1

Artigo redigido conforme norma da Revista Científica: “Scientia Agricola”.

#### **Uso de redes neurais artificiais na predição das pressões horizontais e de atrito em silo esbelto**

Simone Mancini  
Francisco Carlos Gomes  
Wilian Soares Lacerda  
Tadayuki Yanagi Junior

**RESUMO:** Os estudos de confiabilidade estrutural nas predições das pressões em silos são temas de grande interesse, pois o número de variáveis nos cálculos das pressões em silos é grande, o que pode gerar inúmeras falhas e ocorrências de colapso. Objetivou-se com o presente trabalho, propor um modelo de predição das pressões utilizando redes neurais artificiais (RNAs) em comparativo aos dados experimentais. Para a realização da coleta de dados, foi utilizado um modelo de silo-piloto, proposto por Pieper e Schutz (1980), adotado pela norma Alemã DIN 1055 (1987). As medições das pressões foram realizadas no carregamento e descarregamento do silo. Foram utilizadas no silo as paredes lisas, com fundo plano, variando a relação altura/diâmetro entre 4, 6 e 8. As pressões observadas nas paredes do silo, foram as horizontais e a de atrito do produto com a parede. Os resultados das pressões obtidas experimentalmente, foram inseridos num algoritmo utilizando RNA's do tipo *Perceptron Multicamadas*. As pressões medidas nas paredes do silo foram comparadas com os valores preditos pelas RNA's, pelas regressões linear e polinomial, e também pelos valores calculados por meio das Normas Europeia EN 1991-4: 2006 e Australiana, AS 3774 (1996). Dos modelos utilizados, o melhor desempenho foi obtido pelas RNA's, que foram capazes de predizer as pressões nas paredes do silo com menores erros.

**PALAVRAS-CHAVE:** Silos, Inteligência artificial, Confiabilidade estrutural.

## 1 INTRODUÇÃO

Os silos são construções destinadas ao armazenamento de diversos produtos. a utilização do silo apresenta diversas vantagens no armazenamento de produtos como por exemplo a economia do espaço físico, da mão de obra, do custo de transporte, mantendo e conservando os produtos, bem como oferecendo uma boa solução de logística para a indústria.

Algumas incertezas estão associadas ao comportamento do produto armazenado sejam eles granular ou pulverulento, e a interação do produto com estrutura do silo. De modo geral os silos se destacam pelo grau de incertezas em relação à estabilidade estrutural.

As teorias relacionadas ao cálculo das ações das pressões dos produtos sólidos armazenados, vem sendo alvo de estudos desde 1895, a partir da teoria de Janssen. Com o decorrer dos anos, diversas teorias e normas foram desenvolvidas, possibilitando o avanço do estudo de confiabilidade nas estruturas de armazenamento.

Como existem inúmeras incertezas em relação as ações variáveis que ocorrem no silo devido ao carregamento e ao descarregamento do produto armazenado, com o entendimento das propriedades dos produtos armazenados, das ações na estrutura, nos modelos experimentais têm sido possíveis o aprofundamento e o desenvolvimento de estudos de confiabilidade estrutural.

Segundo Carvalho (2018) existem diversos materiais que podem ser empregados na construção de silos, como por exemplo, o concreto armado ou protendido; metálicos, podendo ser de chapas corrugadas, lisas e trapezoidais; de madeira; de alvenaria e argamassa armada.

Atualmente, nos projetos estruturais de silos no Brasil são utilizadas como principais referências as diversas normas internacionais tais como: Americanas: (AMERICAN CONCRETE INSTITUTE - ACI 313:1991 e AMERICAN NATIONAL STANDARDS INSTITUTE - ANS/ASAE EP 433:2001); Australiana (AUSTRALIAN STANDARD - AS3774:1996); Canadense (CANADIAN FARM BUILDING CODE - CFBC:1983); Europeias: (EUROPEAN COMMITTEE OF STANDARDIZATION - EN 1991-4:2006 e DEUTSCHE NORM - DIN 1055-6:2005) e a ISO 11698 (INTERNATIONAL ORGANIZATION FOR STANDART - ISO, 2012), verifica-se uma discrepância nos padrões de calibração entre as normas.

Os silos são classificados em relação à sua altura total pelo diâmetro (H/D). Essa classificação é com relação à esbeltez. As Normas internacionais classificam os silos com relação à altura/diâmetro como esbelto, medianamente esbelto e baixo.

Para um melhor entendimento sobre a previsibilidade de colapsos em estruturas, os projetistas vêm otimizando os estudos de mecanismos das falhas atentando para os parâmetros de funcionalidade e integridade estrutural. No estudo de comportamento estrutural existe um conjunto de variáveis e graus de incertezas.

O grau de incerteza nos cálculos e o número de falhas e ocorrências de colapso que vêm ocorrendo no Brasil e no mundo é significativo. Mesmo com os avanços nas concepções estruturais, no controle de qualidade dos elementos de construção, metodologias de dimensionamento, ainda é necessário o estudo de modelos que resultem em resultados mais representativos da realidade.

Alguns dados denotam a expansão do setor de agronegócio e da necessidade de aprimoramento das construções para a armazenagem dos grãos, no ano de 2021 o Brasil teve capacidade de armazenagem de 176,3 milhões de toneladas de grãos e a produção de grãos fechou em 252,3 milhões de toneladas, apresentando assim um déficit de 75,9 milhões de toneladas de armazenamento. Diante dos dados, é notável a necessidade da ampliação na quantidade de estruturas de armazenamento para grãos (COMPANHIA NACIONAL DE ABASTECIMENTO - CONAB, 2021).

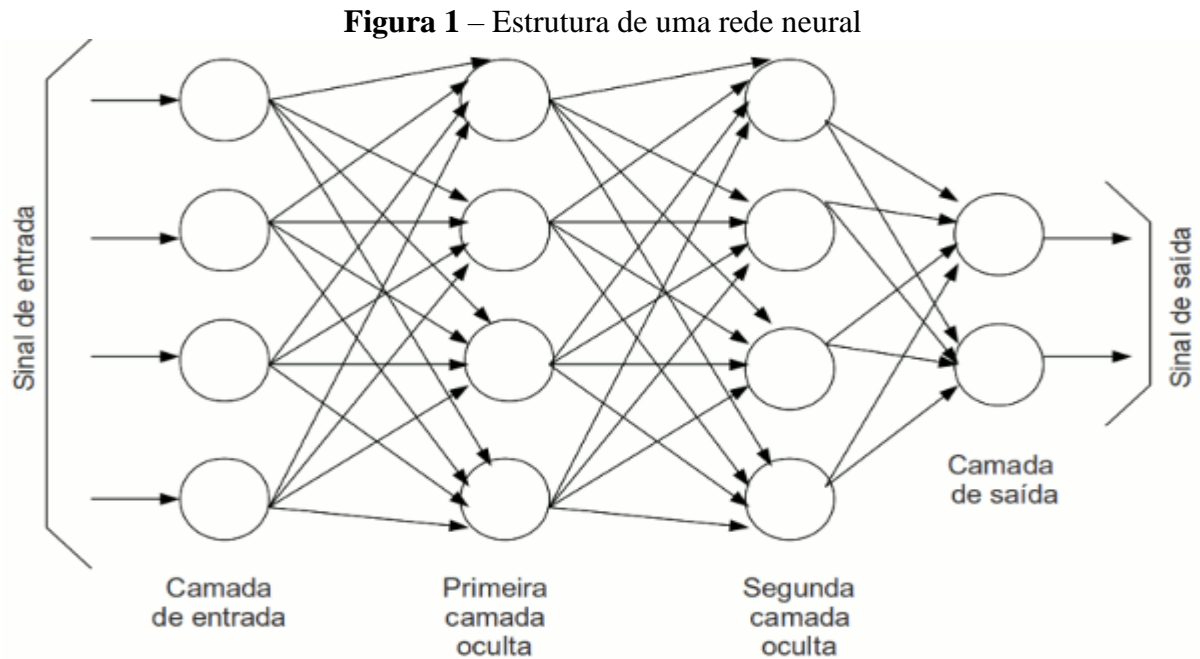
Em consequência da aleatoriedade das ações nos silos e o número de variáveis e dados gerados em modelos experimentais ou reais, o uso de modelos computacionais é indicado. Desta forma, para o estudo da confiabilidade da estrutura de silos, a ferramenta de inteligência computacional tem sido escolhida e utilizada em diversos trabalhos, pois através de algoritmos de RNA's é possível organizar e treinar a rede de dados, possibilitando a previsão dos resultados.

Vazirizade, Nozhati e Zadeh (2017) afirmaram que as redes neurais artificiais (RNA's) consistem em um modo para solucionar problemas que envolvam inúmeras variáveis. As RNA's visam construir circuitos (neurônios artificiais), e modelar esses circuitos (ensinando o computador), esperando-se como resultado uma resposta inteligente.

A metodologia de RNA trabalha no desenvolvimento e solução de sistemas inteligentes com técnicas semelhantes ao comportamento do cérebro humano nas etapas: aprendizado; percepção; raciocínio; evolução e adaptação (VAZIRIZADE, NOZHATI E ZADEH, 2017).

Segundo Golafshani e Behnood (2018) as redes neurais possuem três níveis de camadas de neurônios, a camada de entrada, saída e intermediária. As camadas de entrada são os dados

de entrada no sistema, onde as propriedades ou padrões são apresentados à rede. As camadas de saída, são os dados gerados pela rede (resposta inteligente), onde os resultados são apresentados, e consisti na última camada. E as camadas intermediárias ou ocultas são os neurônios que atribuem os pesos e funções, onde ocorre a maior parte do processamento, situadas entre a camada de entrada e de saída. Na Figura 1 estão ilustradas as camadas e estrutura de uma rede neural.




Fonte: Golafshani e Behnood (2018)

No processo de treinamento das RNA's, no *Backpropagation* desenvolvido por Rumelhart por volta de 1985. No Algoritmo *Backpropagation* os dados de saída são corrigidos e levados as camadas ocultas e de entrada. Nesse processo é onde acontece a aprendizagem da rede. Nas RNA's a camada de entrada recebe os dados, onde cada valor de entrada é multiplicado por seu peso sináptico, posteriormente é realizado o somatório desses produtos. Logo após é feito a soma do valor de bias que é um número arbitrário (+1), que serve para acelerar o processo de aprendizado da rede. Também é aplicado a função de ativação, que serve para realização da aprendizagem da rede.

Golafshani e Behnood (2018) define a função de ativação ( $v_k$ ) como a saída do neurônio. A função de ativação Sigmoidé é calculada através da Equação 1 e apresenta o gráfico do tipo na Figura 2. A função Sigmóide é bastante utilizada em redes neurais artificiais, seu intervalo de saída está entre 0 e 1.

$$f(net_j) = \frac{1}{1 + \exp(-anet_j)} \frac{1}{1 + \exp(-anet_j)} \quad (1)$$

**Figura 2** – Gráfico da função Sigmoide

Fonte: Adaptado de Golafshani e Behnood (2018)

A constituição de uma rede neural de *Múltiplas Camadas* é composta por camada de entrada e saída e as camadas intermediárias ou ocultas. Os neurônios desse tipo de função apresentam uma função não linear de ativação.

Segundo Vazirizade, Nozhati e Zadeh (2017) para dar início a configuração, desenvolvimento e treinamento de uma rede neural artificial são coletos os dados relativos ao problema ou situação real estudada. Posteriormente é feito a separação dos dados em um conjunto de treinamento e um conjunto de testes. A configuração da RNA ocorre geralmente, utilizando 60 a 90% dos dados para treinamento, onde se insere dados de entrada e dados de saída, apresentando o caminho de resposta à rede. E é utilizado de 10 a 40% dos dados restantes para o teste, que é a verificação da resposta encontrada com os dados da resposta já conhecida. Quanto maior o volume de dados amostrais, menor tenderá a ser o valor do erro obtido.

Para conseguir determinar a parada do processamento de uma rede neural, pode seguir vários métodos. É preciso uma escolha do critério correto, para que se alcance um bom resultado final. Segundo Simões e Shaw (2007) esse critério de parada é de suma importância para obtenção de um resultado que represente bem os dados. Um dos critérios de parada mais utilizado é o critério de número máximo de épocas de treinamento. Ferreira et. al. (2016) utilizou o critério de número máximo de épocas de treinamento e obteve um resultado representativo dos dados, comprovando que o uso do mesmo é viável.

Uma época é dada pela apresentação de todas as amostras do conjunto de treinamento à rede neural. No critério de número máximo de épocas de treinamento, deve-se observar que um número excessivo de ciclos pode levar a rede à perda do poder de generalização conhecido com *overfitting*. Esse processo é quando o modelo tem um desempenho excelente, porém quando utilizamos os dados de teste o resultado é ruim. Por outro lado, com um número muito pequeno



de épocas a rede pode não chegar ao seu melhor desempenho que é conhecido como *underfitting*. Nessa situação, o modelo não consegue aprender suficientemente sobre os dados, ou seja, é levado à um erro elevado tanto nos dados de treino como também nos dados de teste (ISAAC JÚNIOR, 2018).

Taxa de aprendizado é o parâmetro que tem uma grande influência durante o processo de treinamento da rede neural. Uma taxa de aprendizado muito baixa torna o aprendizado da rede muito lento, ao passo que uma taxa de aprendizado muito alta provoca oscilações no treinamento e impede a convergência do processo de aprendizado. Geralmente seu valor varia de 0,1 a 1,0. Pode incluir o *termo momentum* na rede, que tem por objetivo aumentar a velocidade de treinamento da rede neural e reduzir o perigo de instabilidade, seu valor varia de 0,0 (quando não for utilizado) à 1,0 (ISAAC JÚNIOR, 2018).

Vários estudos têm sido desenvolvidos na área de previsão das pressões em silos. Como por exemplo Cheung (2007), utilizando um modelo desenvolvido por Pieper e Schutz (1980) padronizado pela norma DIN 1055 (DIN, 1987) mostrou que é possível prever as pressões em silos cilíndricos com fundo de tremonha. Tal modelo pode ser utilizado para diversas configurações de silo.

Nessa estação de teste o silo-piloto foi baseado nos estudos de Wenzel (1963) e Pieper e Schutz (1980). O silo-piloto apresenta as dimensões e escala compatíveis com as reais. Portanto, os resultados obtidos através do silo-piloto podem ser utilizados nos estudos de estruturas reais, sendo seu comportamento considerado idêntico em termos qualitativos e quantitativos à escala 1:1. A estação de silo é constituída pelo silo armazenador, elevador e o silo-piloto. O silo-piloto tem seu corpo segmentado em 12 anéis independentes e tremonhas intercambiáveis. Ao longo do corpo do silo, da tremonha e dos pilares de sustentação estão presentes sensores que por meio de medições de forças e pressões e utilizando equações que permitem a obtenção das pressões horizontais, verticais e de atrito presentes no silo.

Na estação de teste silo de médio porte em escala real, Couto, Ruiz e Aguado (2012) desenvolveram na Universidade de León (Espanha) uma estação foi desenvolvida para medições dinâmicas em silos sob diferentes condições. O silo instrumentado possui 2 metros de altura por 1 metro de diâmetro. No modelo proposto é possível obter as pressões horizontais nas paredes do silo de acordo com a altura, as pressões na zona de transição entre as paredes do silo e a tremonha, as pressões verticais, a pressão de atrito média no cilindro do silo, e a relação entre as pressões horizontais e verticais (K). A estação possibilita diversas variáveis, como:

fundo plano e diversas tremonhas, ambos com descargas de diferentes excentricidades; controle da velocidade de carregamento; diferentes relações de altura diâmetro (H/D). Portanto, a estação possibilita diversas condições utilizando uma escala real.

Brown et al. (2000) desenvolveram um silo-piloto prismático metálico no laboratório *Building Research Establishment* em Garston (Reino Unido). As dimensões utilizadas foram escolhidas para dar uma imagem realista das magnitudes de pressão e distribuição em escala real. A altura do cilindro do silo é de 2,5 metros e seção transversal de 1,5 m, a tremonha prismática com 68 centímetros de altura. A espessura do aço maciço em todo o silo foi de 6 mm, sendo a união do corpo do silo soldado nos quatro cantos. O conjunto apresenta células de pressões distribuídas ao longo das posições verticais e horizontais nas paredes e na tremonha do silo. Os estudos avaliaram que em silos prismáticos as pressões horizontais no mesmo nível variam por conta das deformações das espessuras e rigidez das chapas no cilindro do silo.

Ramírez et al. (2010) projetaram uma estação experimental contendo três silos instrumentados abastecidos por um elevador de caneca. A estação experimental foi construída na Escola Técnica Superior de Engenheiros Agrônomos (*Escuela Técnica Superior de Ingenieros Agrónomos - ETSIA*) na Universidade Politécnica de Madrid (Espanha). A estação tem o principal objetivo em avaliar as pressões nas paredes e na tremonha do silo. Priorizando a zona de transição entre as paredes e a tremonha do silo. O cilindro do silo possui 5,0 m de altura e 1,9 m de diâmetro. As tremonhas contem 1,9 m de altura e bocal de descarga de 0,32 m. O sistema contém 12 sensores de pressão e foi avaliado em dois conjuntos de medições, com o objetivo de analisar as ações das pressões nas paredes dos silos pelas cargas não simétricas e excentricidade de tremonhas utilizando trigo e milho.

Gandia (2021) desenvolveu um estudo visando avaliar as pressões normais em silo metálico esbelto, utilizando o método dos elementos finitos. No desenvolvimento do trabalho verificou-se que uma influência do coeficiente de atrito na parede e também do peso específico nos valores das pressões no silo.

Atualmente são diversos trabalhos relacionados a estrutura, fluxo e ações no comportamento dos silos com utilizando o Método das RNA's.

Na área de comportamento dos silos, o trabalho de Reis (2011), utilizou RNA para a obtenção das pressões do silo através das equações das normas com valores das propriedades físicas dos produtos. Obtendo como boa resposta o uso de RNA's na área de confiabilidade estrutural do sistema de silos.

Yuksel e Arslan (2010) utilizaram RNA para determinar as forças de interação de quatro silos cilíndricos de concreto armado com as combinações dos silos cheios e vazios. Nesse trabalho também foi utilizado RNA's como ferramenta para cálculo das tensões.

O trabalho de Meira et. al. (2020) utilizaram silos para o armazenamento de grão e/ou produtos pulverulentos. Foi feito o estudo das pressões durante o processo de carregamento, armazenamento e descarregamento do produto. O trabalho teve por objetivo a comparação das pressões horizontais durante o processo de carregamento entre a situação de silo baixo (relação altura/diâmetro =  $h/d = 1$ ) e silo esbelto (relação altura/diâmetro =  $h/d = 4$ ). Para tanto foi utilizado um silo vertical elevado, composto por corpo e tremonha em aço inox com 2.50 m de altura e 0.64 m de diâmetro com 10-3 m de espessura, e o produto armazenado foi o milho. Neste trabalho verificou-se que, quanto maior a relação  $h/d$ , maiores as pressões durante o carregamento na área mais próxima a zona de transição entre o corpo do silo e a tremonha.

Portanto, devido ao caráter aleatório das pressões medidas em um silo, a utilização de RNA's para problemas relacionados a previsões e confiabilidade, vem sendo utilizada e apresentando resultados positivos. Os estudos de Reis (2011), utiliza RNA's para a previsão de pressões em silos, esse trabalho serviu como base para o desenvolvimento do presente trabalho. Lima (2021) utilizou RNA's para o desenvolvimento de um sistema de alerta de previsibilidade precoce de inundação repentina. O trabalho de Araújo, Dantas Neto e Souza Filho (2015) utilizaram redes neurais com um algoritmo do tipo Perceptron para fazer a previsão de vazão para açude a partir de dados hidrometeorológicos.

A motivação para o desenvolvimento do trabalho baseia-se na perspectiva de aumento da necessidade de armazenamento de produtos advindos do setor do agronegócio e da quantidade relativamente pequena de pesquisas nesta direção por se tratarem de projetos de custo bastante elevado. Portanto, torna-se um instrumento favorável para a pesquisa e previsão das ações, possibilitando assim o aumento da confiabilidade nas estruturas de armazenamento.


## 2 MATERIAIS E MÉTODOS

### 2.1 Configuração do silo e sensores

Os dados experimentais das pressões horizontais e de atrito na parede do silo, foram coletados na Universidade Federal de Lavras no Departamento de Engenharia Agrícola no Laboratório de Propriedades Físicas e de Fluxo dos Produtos Armazenados. O produto utilizado nos ensaios foi o milho. No silo foi utilizado parede lisa e fundo plano (90°), e as relações H/D: 4, 6 e 8. As pressões horizontais e de atrito, foram coletadas com três repetições para cada ensaio de carregamento e descarregamento, totalizando 75 amostras.

O silo-piloto onde as amostras foram coletadas, é feito em estrutura metálica com geometria cilíndrica e padronizado pela norma DIN 1055: 1987. O sistema é constituído por um silo de armazenamento, o elevador e o silo-piloto. Para obtenção dos dados foi utilizado um sistema de aquisição de dados conectado a um computador portátil, como mostra a Figura 3.


**Figura 3** - Estação experimental no Centro de Pesquisa em Processamento de Produtos Agrícolas da Universidade Federal de Lavras



O silo é constituído por 12 conjuntos de anéis independentes suspensos de modo estaticamente determinado. Cada anel possui 50 cm de altura apresentando um diâmetro interno de 70,5 cm utilizando a parede lisa. A altura total dos doze anéis totaliza 6 m e um volume de armazenamento de 2,35 m<sup>3</sup>. Antes da obtenção dos dados, o silo já havia sido calibrado e instrumentado para medir as pressões em seu carregamento e descarregamento.

Os dados das pressões são obtidos por meio de células de carga instaladas no silo. Na Figura 4A ilustra as 2 células de carga tipo viga, localizado na base de cada pilar. Na tremonha foram instaladas 5 células de pressão, posicionadas estrategicamente ilustradas na Figura 4B. No cilindro do silo possui 50 células de carga do tipo extensômetros, sendo 24 sensores na posição horizontal, para determinação da força normal nas paredes e 26 sensores na posição vertical, para determinação da força de atrito, ilustrado pela Figura 4C.

**Figura 4 - Sistema de aquisição de dados e sensores**



## 2.2 Dados coletados

Os valores das propriedades físicas no milho foram divididos em faixa com valores máximo e mínimo (Tabela 1).

**Tabela 1** – Faixa dos valores das propriedades físicas do milho

	$\gamma(\text{kN/m}^3)$	$\Phi_e(^{\circ})$	$\Phi_w(^{\circ})$
<b>MILHO</b>	7,52 --- 7,83	19,4^{\circ} --- 32,3^{\circ}	9,3^{\circ} --- 13,2^{\circ}

Segue os dados experimentais de pressões horizontais e de atrito que foram coletados no silo-piloto para carregamento e descarregamento.

**Quadro 1 – Pressões horizontais e de atrito de carregamento**

Nº da amostra	Altura do silo (m)	h/d	CARREGAMENTO		Nº da amostra	Altura do silo (m)	h/d	CARREGAMENTO	
			Pressões horizontais (KPa)	Pressões de atrito (KPa)				Pressões horizontais (KPa)	Pressões de atrito (KPa)
1	3.25	4	0.026051	0.006402	40	5.75	6	5.385836	1.574279
2	3.25	4	0.024036	0.005216	41	5.75	6	5.265872	1.568351
3	3.25	4	0.017881	0.004269	42	5.75	6	5.219564	1.593249
4	3.75	4	0.752044	0.181401	43	0.75	8	0.015478	0.002846
5	3.75	4	0.494453	0.142987	44	0.75	8	0.022075	0.005454
6	3.75	4	0.058995	0.060941	45	0.75	8	0.012889	0.00415
7	4.25	4	2.409005	0.491325	46	1.25	8	0.564265	0.18235
8	4.25	4	2.084213	0.496067	47	1.25	8	0.520817	0.18069
9	4.25	4	1.400383	0.305892	48	1.25	8	0.99196	0.18152
10	4.75	4	3.636132	0.805517	49	1.75	8	1.557791	0.505553
11	4.75	4	3.479671	0.728214	50	1.75	8	1.663165	0.491088
12	4.75	4	2.357301	0.60064	51	1.75	8	1.704517	0.49832
13	5.25	4	3.984146	1.029365	52	2.25	8	3.328598	0.693356
14	5.25	4	3.735759	0.950638	53	2.25	8	3.119761	0.664901
15	5.25	4	3.574104	0.829941	54	2.25	8	2.71886	0.679128
16	5.75	4	4.903789	1.425838	55	2.75	8	4.472477	1.116626
17	5.75	4	4.819958	1.361103	56	2.75	8	4.928736	1.068489
18	5.75	4	4.715869	1.451448	57	2.75	8	4.565206	1.092557
19	2.25	6	0.140692	0.017785	58	3.25	8	4.5114	1.206971
20	2.25	6	0.227871	0.043157	59	3.25	8	4.535116	1.174247
21	2.25	6	0.086736	0.048611	60	3.25	8	4.600583	1.190609
22	2.75	6	1.398449	0.327234	61	3.75	8	4.0339	1.176381
23	2.75	6	1.550021	0.233095	62	3.75	8	4.069653	1.154329
24	2.75	6	1.09126	0.412124	63	3.75	8	3.823874	1.165355
25	3.25	6	3.254957	0.714698	64	4.25	8	4.303066	1.197961
26	3.25	6	3.294165	0.740307	65	4.25	8	4.423313	1.233292
27	3.25	6	3.055816	0.695965	66	4.25	8	4.020567	1.215626
28	3.75	6	3.730052	0.894676	67	4.75	8	4.878949	1.372722
29	3.75	6	3.718963	0.947556	68	4.75	8	4.611867	1.395487
30	3.75	6	3.529041	0.842508	69	4.75	8	3.975751	1.384104
31	4.25	6	4.23552	1.021776	70	5.25	8	4.521148	1.37699
32	4.25	6	4.191995	1.021775	71	5.25	8	4.509738	1.406631
33	4.25	6	4.12404	1.051653	72	5.25	8	4.107618	1.39181
34	4.75	6	4.820578	1.195352	73	5.75	8	5.168799	1.498162
35	4.75	6	4.799771	1.205785	74	5.75	8	5.118147	1.492471
36	4.75	6	4.679558	1.261984	75	5.75	8	5.006574	1.495316
37	5.25	6	4.786341	1.224043					
38	5.25	6	4.54791	1.197012					
39	5.25	6	4.564809	1.191557					

**Quadro 2 – Pressões horizontais e de atrito de descarregamento**

Nº da amostra	Altura do silo (m)	h/d	DESCARREGAMENTO		Nº da amostra	Altura do silo (m)	h/d	DESCARREGAMENTO	
			Pressões horizontais (KPa)	Pressões de atrito (KPa)				Pressões horizontais (KPa)	Pressões de atrito (KPa)
1	3.25	4	0.038249	0.002609	40	5.75	6	5.708237	1.575702
2	3.25	4	0.029246	0.002845	41	5.75	6	5.019574	1.47516
3	3.25	4	0.002251	0.008774	42	5.75	6	4.972366	1.505276
4	3.75	4	1.238702	0.386515	43	0.75	8	0.025192	0.020867
5	3.75	4	0.822177	0.300676	44	0.75	8	0.01893	0.009485
6	3.75	4	0.144542	0.135636	45	0.75	8	0.026055	0.015176
7	4.25	4	3.585401	0.896573	46	1.25	8	1.217367	0.418764
8	4.25	4	3.526089	0.856973	47	1.25	8	1.161795	0.398609
9	4.25	4	2.529415	0.562699	48	1.25	8	2.041359	0.408687
10	4.75	4	4.286952	1.198671	49	1.75	8	3.086174	0.929297
11	4.75	4	4.410173	1.207208	50	1.75	8	3.3691	0.889459
12	4.75	4	3.413866	1.004229	51	1.75	8	3.412824	0.909378
13	5.25	4	3.836852	1.151009	52	2.25	8	5.287731	1.24586
14	5.25	4	3.635364	1.090304	53	2.25	8	5.175861	1.20365
15	5.25	4	3.563305	0.994506	54	2.25	8	4.734382	1.224755
16	5.75	4	4.658401	1.363712	55	2.75	8	8.036385	1.450736
17	5.75	4	4.902791	1.293759	56	2.75	8	8.732272	1.336204
18	5.75	4	4.768964	1.379836	57	2.75	8	8.424112	1.39347
19	2.25	6	0.174235	0.037704	58	3.25	8	5.612293	1.503141
20	2.25	6	0.372251	0.051457	59	3.25	8	5.816018	1.43556
21	2.25	6	0.117624	0.042921	60	3.25	8	5.926347	1.469351
22	2.75	6	2.687118	0.713986	61	3.75	8	5.164144	1.322925
23	2.75	6	3.00192	0.417341	62	3.75	8	5.328721	1.305379
24	2.75	6	2.214553	0.727739	63	3.75	8	5.339586	1.314152
25	3.25	6	4.750419	1.16334	64	4.25	8	6.451477	1.294945
26	3.25	6	4.915561	1.158834	65	4.25	8	6.651239	1.326957
27	3.25	6	4.70871	1.135834	66	4.25	8	6.735742	1.310951
28	3.75	6	4.774708	1.262695	67	4.75	8	6.487083	1.564083
29	3.75	6	4.959692	1.348061	68	4.75	8	6.233908	1.597281
30	3.75	6	4.849333	1.215033	69	4.75	8	6.091921	1.580682
31	4.25	6	5.803637	1.248705	70	5.25	8	5.463401	1.337627
32	4.25	6	5.916596	1.237797	71	5.25	8	5.63467	1.36466
33	4.25	6	5.908281	1.291388	72	5.25	8	5.661114	1.351143
34	4.75	6	5.706838	1.505039	73	5.75	8	5.01564	1.412796
35	4.75	6	5.842284	1.506935	74	5.75	8	4.796665	1.362289
36	4.75	6	5.543964	1.479666	75	5.75	8	4.824626	1.387543
37	5.25	6	4.816509	1.272892					
38	5.25	6	4.772479	1.170217					
39	5.25	6	5.033934	1.263643					

### 2.3 Normas e teorias

Os dados das propriedades físicas do milho foram utilizados nas teorias e Normas para o cálculo das pressões no silo. Foram utilizadas as Equações (2, 3 e 4) da teoria de Janssen para o cálculo das pressões estáticas.

Equações para as pressões estáticas (carregamento):

- I) Pressão horizontal de carregamento para as paredes do silo:

$$Ph = \frac{\gamma}{\mu' \cdot U} \left( 1 - e^{-zK\mu' \frac{U}{A}} \right) \quad (2)$$

Conhecendo a fórmula de Janssen para o cálculo da pressão horizontal, pode-se obter a pressão vertical e a pressão de atrito nas paredes.

II) Pressão vertical de carregamento para as paredes do silo:

$$P_v = \frac{Ph}{k} \quad (3)$$

III) Pressão de atrito de carregamento por 1 m<sup>2</sup> de superfície de parede:

$$P_w = \mu' \cdot Ph \quad (4)$$

em que:

$\gamma$  = peso específico do produto

$A$  = área da seção transversal horizontal do silo

$U$  = perímetro da seção transversal

$\mu' \mu'$  = parâmetro na equação de Janssen  $\mu = \text{tg}\Phi_w$

$z$  = cota da altura do produto acima da seção transversal considerada

Para a Norma EN 1991-4 (2006) foi utilizado o parâmetro K:

**Tabela 2** – Pressões de carregamento na parede do silo

Normas EN	Pressões			Coefficiente K
	Ph	Pv	Pw	1,1(1 – sen $\Phi_e$ )

Para o cálculo das pressões de descarga de acordo com a Norma Europeia EN 1991-4 (2006), foi multiplicado as pressões de carregamento das Equações 2 e 4 por coeficientes de sobrepressão  $C_w$  e  $C_h$ .

$$P_{hd} = C_h \cdot P_h \quad (5)$$

$$P_{wd} = C_w \cdot P_w \quad (6)$$

sendo:

$$C_w = 1,1$$

$$C_h = 1,35 + 0,02 \cdot (\Phi_e - 30^\circ) \geq 1,35$$



## 2.4 Regressão linear simples e regressão polinomial

A regressão é um procedimento com amplo poder de explicação de previsões, por isso foi escolhida para esse trabalho. A regressão linear simples tem 2 variáveis, uma dependente (valores das pressões) e a independente (altura do silo). A regressão polinomial pode estabelecer relação entre uma variável dependente e várias independentes. Foi calculado a regressão linear e a regressão polinomial de 4º grau (Equações 7 e 8, respectivamente), pois obteve melhores resultados com os dados amostrais.

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i \quad (7)$$

$$y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \beta_3 x_i^3 + \beta_4 x_i^4 + \varepsilon_i \quad (8)$$

## 2.5 Rede neural artificial (RNA)

O trabalho utilizou de redes neurais artificiais como ferramenta na interpretação dos dados. A linguagem de programação foi desenvolvida no Scilab na versão 6.1.1, que é uma linguagem de alta interpretação de dados e diversas ferramentas numéricas.

Uma vantagem no uso do Scilab é a presença de biblioteca conhecida como ANN (*Artificial Neural NetWork Toolbox*), no qual contém algumas funções implementadas para a criação da RNA, o que facilita muito na criação do algoritmo. E ainda é uma linguagem gratuita, podendo ser utilizada sem custo.

Os algoritmos que foram desenvolvimentos e utilizados na pesquisa, estão listados nos Anexo A, B, C e D.

### 2.5.1 Pré-processamento

Inicialmente os dados foram lidos pela rede e separados para o treinamento e teste. Logo após, os dados foram normalizados para aumentar a integridade de dados. Os eixos já normalizados terão o intervalo de 0 até 1. Os dados foram misturados de forma aleatória e não tendenciosa, para que aconteça o treinamento da rede. Logo após a mistura dos dados, foi feita a definição da arquitetura da rede, no qual, a taxa de aprendizagem foi de 0,9, o número de iterações feitas pela rede que obteve maior significância e com menor valor de erro foi de 3000 épocas. O valor da taxa de momento escolhido foi de 0,6. O treinamento da rede aconteceu através do *Backpropagation*.

### 2.5.2 Arquitetura da RNA

Para o desenvolvimento do trabalho, foi utilizado uma rede neural artificial com a arquitetura dividida da seguinte forma, demonstrada na Tabela 3.

**Tabela 3** – Arquitetura da rede neural artificial

CAMADAS	DADOS
Camada de entrada	Cotas de alturas utilizadas no silo e a relação altura diâmetro do silo
Camada oculta ou intermediária	2 camadas ocultas 10 neurônios na primeira camada e 3 neurônios na segunda camada
Camada de saída	Valores das pressões nas paredes do silo obtidos experimentalmente

A função de ativação que foi utilizada é a Sigmóide Logística, com intervalo de saída está entre -1 a 1. A Equação 9 foi utilizada para calcular a função de ativação.

$$S(x) = \frac{1}{1 + e^{-x}} = \frac{e^x}{e^x + 1} = \frac{1}{1 + e^{-x}} = \frac{e^x}{e^x + 1} = 1 - S(-x) \quad (9)$$

### 2.5.3 Treinamento da RNA

A técnica utilizada foi redes neurais artificiais do tipo *Perceptron Multicamadas (MLP – Multi-Layer Perceptron)*, no qual consiste em vários neurônios artificiais que estão interligados com um determinado peso associado a cada conexão. Foi utilizado o algoritmo do tipo *Backpropagation*, com 40% dos dados para o treinamento da rede e 60% dos dados para o teste de desempenho da rede.

A rede neural foi composta por duas partes, onde a primeira parte é o módulo de aprendizagem (treinamento da rede) e utilizou 60% dos dados (45 amostras) e a segunda parte é chamada de módulo de teste (execução do programa) e utilizou 40% dos dados (30 amostras).

O critério de parada para o treinamento da rede foi o de número máximo de épocas de treinamento, buscando um número mínimo de erro médio quadrático.

### 2.5.4 Métricas de desempenho

Para comparação dos valores obtidos por meio dos modelos desenvolvidos com os obtidos experimentalmente, foram utilizadas as métricas de desempenho, coeficiente de determinação ( $R^2$ ), erro absoluto médio (MAE), erro médio percentual absoluto (MAPE) e erro médio quadrático (RMSE) (Equações 10, 11, 12 e 13, respectivamente).

$$R^2 = 1 - \frac{SQ_{tot}}{SQ_{res}} = 1 - \frac{\sum_{i=1}^n (ai - am)^2}{\sum_{i=1}^n (ai - yi)^2} \quad (10)$$

sendo,

$ai$  = Dados reais (teste)

$yi$  = Dados estimados

$am$  = Média dos dados reais

$n$  = quantidade de dados

$$MAE = \frac{\sum_{i=1}^n |ai - yi|}{n} \quad (11)$$

em que:

$ai$  = Dados reais (teste)

$yi$  = Dados estimados

$n$  = quantidade de dados

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{ai - yi}{ai} \right| * 100}{n} \quad (12)$$

Sendo:

$ai$  = Dados reais (teste)

$yi$  = Dados estimados

$n$  = quantidade de dados

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (ai - yi)^2}{n}} \quad (13)$$

em que:

$ai$  = Dados reais (teste)

$yi$  = Dados estimados

$n$  = quantidade de dados

### 3. RESULTADOS E DISCUSSÕES

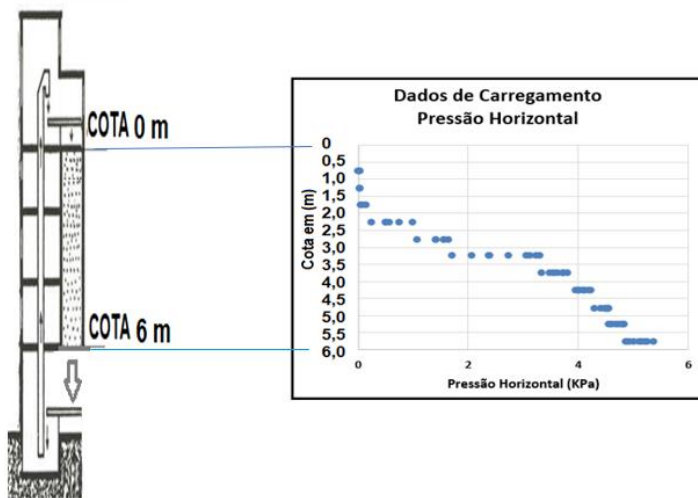
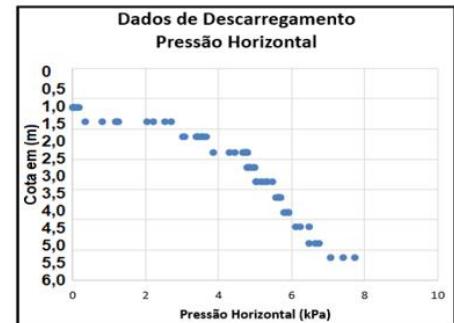
Os indicadores estatísticos  $R^2$ , MAPE, MARE e RMSE que foram obtidos por meio da comparação entre os dados experimentais e os dados simulados a partir dos sistemas RNA, regressões linear e polinomial e as Normas Europeia EN 1991-4 (2006) e Australiana AS 3774 (1996) estão listados na Tabela 4.

**Tabela 4** - Comparativos de indicadores estatísticos na predição das pressões horizontais e de atrito de carregamento e descarregamento.

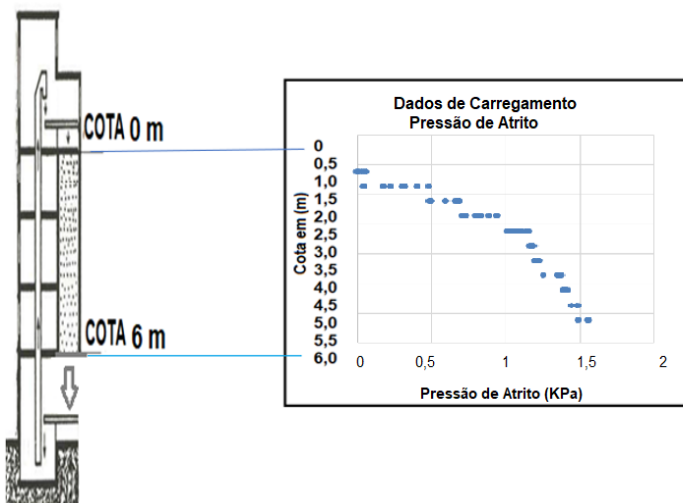
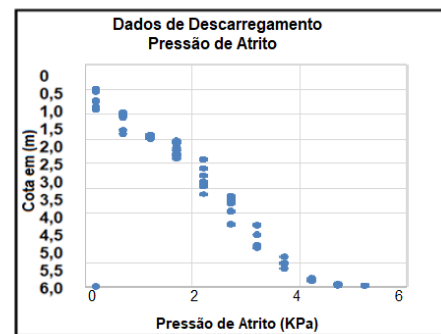
Tipo	Pressão	Método	$R^2$	MAE	MAPE	RMSE
Carregamento	Horizontal	Redes neurais	0,952	0,058	5,10%	0,074
		Regressão linear	0,744	0,132	13,50%	0,171
		Regressão polinomial	0,742	0,138	11,18%	0,172
		Norma EN 1991-4	0,558	0,323	12,65%	0,422
		Norma AS 3774	0,653	0,327	11,81%	0,367
	Atrito	Redes neurais	0,954	0,055	7,55%	0,067
		Regressão linear	0,863	0,097	20,86%	0,116
		Regressão polinomial	0,855	0,094	18,91%	0,119
		Norma Europeia	-0,494	0,292	18,32%	0,382
Descarregamento	Horizontal	Redes neurais	0,908	0,052	5,11%	0,071
		Regressão linear	0,312	0,161	13,62%	0,196
		Regressão polinomial	0,469	0,147	11,19%	0,173
		Norma EN 1991-4	0,535	0,239	5,78%	0,292
		Norma AS 3774	0,357	0,376	3,23%	0,122
	Atrito	Redes neurais	0,938	0,061	5,13%	0,072
		Regressão linear	0,501	0,187	13,63%	0,203
		Regressão polinomial	0,593	0,164	11,15%	0,184
		Norma Europeia	0,036	0,172	5,79%	0,283

Analisando os resultados de  $R^2$  e RMSE dos dados listados na Tabela 4, observa-se que o sistema utilizando redes neurais artificiais apresentou os melhores valores, sendo eles 95,2% e 0,074; 95,4% e 0,067, respectivamente, para as pressões horizontais e de atrito no processo de carregamento do milho no silo e 90,8% e 0,071; 93,8% e 0,072, respectivamente para o descarregamento. Estes resultados apontam a boa capacidade da rede Neural artificial nas predições das pressões nas paredes do silo, mostrando eficiência no modelo.

Com os dados de cota em (m) do silo e as pressões em (kPa) horizontais referentes ao carregamento e descarregamento, foram traçados os gráficos das Figuras 5A e 5B.

**Figura 5A** – Pressões horizontais de carregamento**Figura 5B** – Pressões horizontais de descarregamento

Nas Figuras 6A e 6B estão representados nos gráficos, as cotas em (m) do silo e as pressões em (kPa) de atrito referente ao carregamento e descarregamento. Onde quanto menor o valor da cota menor será o valor da pressão. Para carregamento e descarregamento das pressões horizontais no cota 1,25 m obteve-se os valores 0,56 kPa e 1,21 kPa, respectivamente.

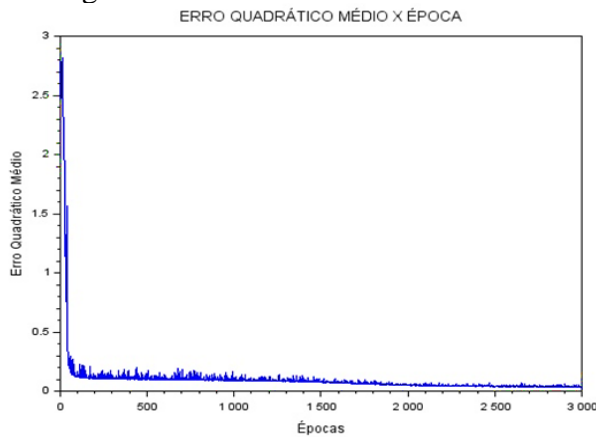
**Figura 6A** – Pressões de atrito de carregamento**Figura 6B** – Pressões de atrito de descarregamento

Gandia (2021) ao analisar as pressões em um silo por meio de elementos finitos, percebeu-se uma influencia do coeficiente de atrito na parede e do peso específico na pressões. Esses comportamentos também foram observados nas pressões horizontais (Figuras 5A e 5B) e nas pressões de atrito (Figuras 6A e 6B).

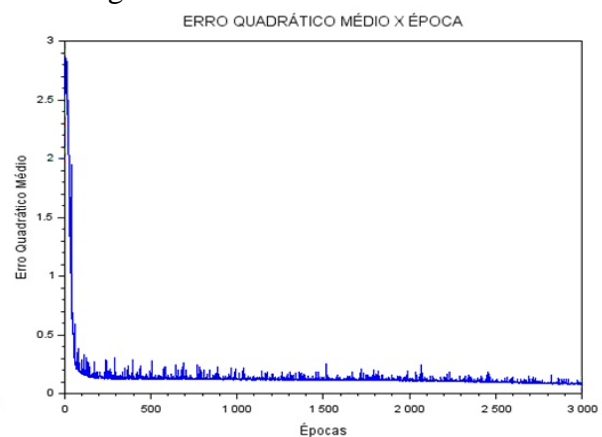
Na pressão de atrito no silo foram obtidos na cotas menores valores com menor pressão, sendo para descarregamento 0,41 kPa e para carregamento 0,18 kPa ambos para cota 1,25 m.

Os comportamentos dos valores de erro quadrático médio mínimo para cada época de treinamento para as pressões horizontais e de atrito, durante o carregamento, são ilustrados nas Figuras 7A e 7B, respectivamente.

**Figura 7A** – Erro quadrático médio mínimo a cada época para as pressões horizontais de carregamento

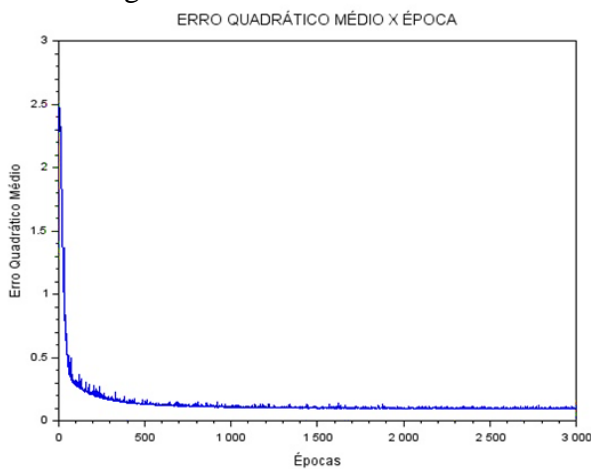


**Figura 7B** – Erro quadrático médio mínimo a cada época para as pressões de atrito de carregamento

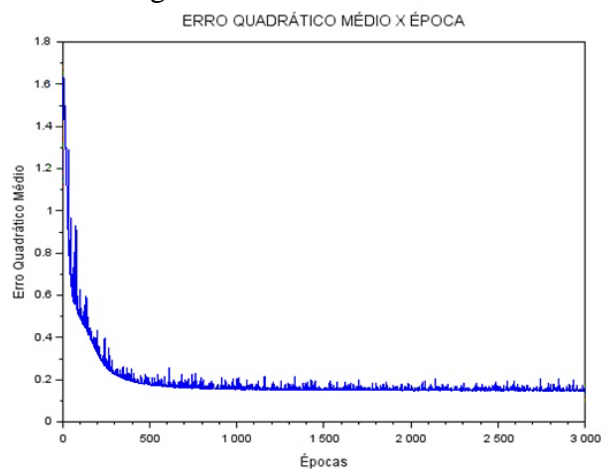


Nas Figuras 8A e 8B, são mostrados o comportamento do Erro Quadrático Médio Mínimo obtido até 3000 épocas de treinamento para o descarregamento das pressões horizontais e de atrito respectivamente.

**Figura 8A** – Erro quadrático médio mínimo a cada época para as pressões horizontais de descarregamento



**Figura 8B** – Erro quadrático médio mínimo a cada época para as pressões de atrito de descarregamento



Na Tabela 5 estão listados os valores do erro quadrático médio mínimo obtidos na última época calculada.

**Tabela 5** – Erro quadrático médio mínimo na época número 3000 para as pressões das pressões horizontais e de atrito de carregamento e descarregamento

<b>Pressões</b>	<b>Situação</b>	<b>Erro quadrático médio mínimo</b>
Horizontal	Carregamento	0,0788107
	Descarregamento	0,1476175
Atrito	Carregamento	0,0393519
	Descarregamento	0,0966921

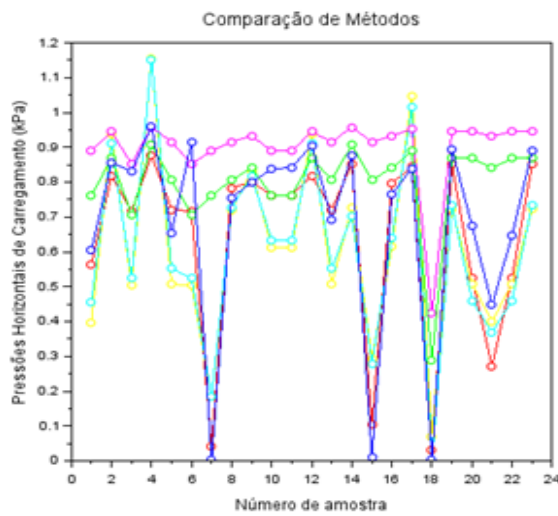
Com objetivo de verificar se o aumento do número de épocas de treinamento diminuiria de forma significativa o valor do erro, foi realizado treinamentos com 5.000 e 10.000 épocas. Porém, a taxa de diminuição do erro foi muito pequena e valor se manteve quase que constante ao treinamento com 3.000 épocas.

Outra pesquisa que também usou redes neurais artificiais para o cálculo das pressões em Silo, obteve-se o menor erro com 10.000 épocas e utilizando 10% dos dados, e obteve um bom resultado nos valores do erro quadráticos médio mínimo (REIS, 2011).



No comparativo entre os resultados, utilizaram os dados experimentais como parâmetro, foi possível mensurar a eficiência da rede neural, das regressões linear e polinomial e a Norma Europeia.

Nas Figuras 9A e 9B são ilustrados os gráficos comparativos dos diferentes métodos utilizados para carregamento para as pressões horizontais e de atrito nas paredes do silo.

**Figura 9A** – Comparativos de carregamento para as pressões horizontais nas paredes do silo




**Figura 9B** – Comparativos de carregamento para as pressões de atrito nas paredes do silo





Nas Figuras 10A e 10B são ilustrados os gráficos comparativos dos diferentes métodos utilizados para descarregamento para as pressões horizontais e de atrito nas paredes do silo.

**Figura 10A** – Comparativos de descarregamento para as pressões horizontais nas paredes do silo



**Figura 10B** – Comparativos de descarregamento para as pressões de atrito nas paredes do silo





Ao analisar os valores obtidos na comparação dos métodos, é possível perceber que a variação entre os valores reais e os valores encontrados pela RNA das pressões nas paredes do silo, são muito próximas, existe uma pequena variação insignificante entre elas.

No trabalho de Cheung (2007) que fez a comparação do estudo teórico, numérico e experimental, obteve-se como resultado que os modelo de Janssen (1895) e Jenike et. al. (1973) podem ser utilizados para os cálculos de pressões em silo. Embora tenha sido observada variação em relação aos dados reais, esta foi insignificante. Ademais, os parâmetros utilizados permitiram aproximação das pressões em silos aos valores reais.

Comparando os dados obtidos através das Normas EN 1991-4 (2006) e AS 3774 (1996), aos dados reais, as Normas apresentaram valores superiores aos reais, devido o uso de coeficientes de majoração nas normas. Comparando ambas as normas, a Norma EN 1991-4 (2006) utiliza coeficientes com valores maiores de majoração.

Nos dados obtidos pela regressão linear e polinomial, não há diferença significativa entre as regressões quando comparadas aos dados reais.

Segundo Meira et. al. (2020) quando compara os dados experimentais com as Normas Europeia EN 1991-4 (2006) e Australiana AS 3774 (1996) obteve-se também resultados superiores na EN 1991-4 (2006). Em ambas as normas valores superiores aos experimentais, isso deve-se aos coeficientes de majoração.

#### 4. CONCLUSÃO

Este trabalho discute a possibilidade de implementação de redes neurais artificiais para predição de pressões horizontais e de atrito no carregamento e descarregamento nas paredes dos silos metálicos esbeltos, a partir das características do grão e da geometria do silo. Foram avaliados diversos métodos como regressões lineares e polinomiais, RNA e Normas Internacionais. Os resultados indicam que o sistema de RNA estudado apresentou desempenho satisfatório na previsão das pressões atuantes no silo, com valores de coeficiente de correlação superiores à 90%. As RNAs também apresentaram melhores métricas de desempenho ao se considerar o MAE, MAPE.

O modelo de sistemas proposto no estudo se mostrou confiável e capaz de fornecer resultados com precisão, tornando possível afirmar que a implementação de rede neural artificial na predição de pressões em silo é viável. Pode-se afirmar que um sistema de RNA, como o construído, pode representar uma nova modelagem no auxílio dos cálculos em ações atuantes no silo, contribuindo significativamente para o avanço tecnológico da confiabilidade estrutural.

## REFERENCIAS BIBLIOGRÁFICAS

- [1] AMERICAN CONCRETE INSTITUTE. **ACI 313**: Standard Practice for Design and Construction of Concrete Silos and Stacking Tubes for Storing Granular Materials. EUA, 1991.
- [2] AMERICAN NATIONAL STANDARDS INSTITUTE. **ANSI/ASAE EP 433:1991** (reaffirmed DEC/2001). Loads exerted by free-flowing grain on shallow storage structures. EUA, 2001.
- [3] ARAÚJO, C. B. C., DANTAS NETO, S. A. e SOUZA FILHO, F. A. **Streamflow forecasting for the dam Orós/CE from hydrometeorological data using perceptrons**. Rev. Bras. Meteorol. 30/ Mar 2015.
- [4] AUSTRALIAN STANDARD **AS 3774**. (1996) Loads on bulk containers. Sydney. AS 3774 Supplement 1 (1996).” Loads on bulk containers – Commentary. Sydney.
- [5] BROWN, C. J.; LAHLOUH, E. H.; ROTTER, J. M. Experiments on a square planform steel silo. **Chemical Engineering Science**, v. 55, n. 20, p. 4399-4413, 2000.
- [6] CANADIAN FARM BUILDING CODE **CBFC** - Part 2, Structural design. Ottawa, Canada, 1983.
- [7] CARVALHO, Haridasa F. **Análise de tensões em silos circulares metálicos de baixa relação altura/diâmetro**. 2018. 43 f. Trabalho de Conclusão do Curso (Bacharelado em Engenharia Civil) - Universidade Tecnológica Federal do Paraná. Pato Branco, 2018.
- [8] CHEUNG, A. B. **Modelo estocástico de pressões de produtos armazenados para a estimativa da confiabilidade estrutural de silos esbeltos**. 2007. 333 p. Tese (Doutorado em Engenharia de Estruturas) - Universidade de São Paulo, São Paulo, 2007.
- [9] CONAB. COMPANHIA NACIONAL DE ABASTECIMENTO. Acompanhamento de safra brasileiro – grãos: **4º Levantamento - Safra 2021/22**: Brasília: Companhia Nacional de Abastecimento. 2001. Disponível em: <https://www.conab.gov.br/info-agro/safras/graos/boletim-da-safra-de-graos>. Acesso em: 02 jan. 2021.
- [10] COUTO, A.; RUIZ, A.; AGUADO, P. J. **Design and instrumentation of a mid-size test station for measuring static and dynamic pressures in silos under different conditions** - Part I: Description. Computers and Electronics in Agriculture, v. 85, p. 164-173, 2012.

- [11] **DIN 1055**. Design loads for buildings: loads in silo bins. Berlin: Deutsche Norm, 1987. 6p.
- [12] DEUTSCHE NORM - **DIN 1055-6**: Basis of design and actions on structures – Part 6: design loads for buildings and loads in silo bins. Berlin, Verlag, 2005.
- [13] EUROPEAN COMMITTEE OF STANDARDIZATION. **EN 1991-4**: Eurocode 1: Basis of Design and Actions on Structures, Part 4 – Silos and Tanks. CEN, Brussels, 2006.
- [14] FERREIRA, A., FERREIRA, R., SILVA, A., FERREIRA, A. **Um estudo sobre previsão da demanda de encomendas utilizando uma rede neural artificial**. XVIII simpósio de pesquisa operacional & logística da marinha. Aug, 2016.
- [15] GANDIA, Rômulo Marçal et al. **Influence of specific weight and wall friction coefficient on normal pressures in silos using the Finite Element Method**. Revista Engenharia na Agricultura-REVENG, v. 29, p. 192-203, 2021.
- [16] GOLAFSHANI, E. M.; BEHNOOD, A. **Application of soft computing methods for predicting the elastic modulus of recycled aggregate concrete**. Journal of Cleaner Production, v. 176, p. 1163–1176, 2018.
- [17] ISAAC JÚNIOR, M. A. **Modelo misto e rede neural artificial para estimativas dendométricas de árvores individuais**. 2018. 82 f. Tese (Doutorado em Engenharia Florestal) - Departamento de ciências florestais, Universidade Federal de Lavras, Lavras – MG.
- [18] INTERNATIONAL ORGANIZATION FOR STANDART **ISO 11697**: Bases for design of structures: Loads due to bulk materials, London, 2012.
- [19] JANSSEN, H. A. Versuchüber Getreidedruck in Sillozellen. **Zeitschrift des Vereins Deutscher Ingenieure**, v. 39, p. 1045–1049, 1895.
- [20] JENIKE, A. W.; JOHANSON, J. R.; CARSON, J. W. Bin loads—Part 2: concepts. **Journal of Engineering for Industry**, v. 95, n. 1, p. 1-5, 1973.
- [21] LIMA, G. R. T. e SCOFIELD, G. B. **Feasibility study on operational use of neural networks in a flash flood early warning system**. Scientific Technical Article. 2021.

- [22] MEIRA A.S., NASCIMENTO J.W.B., SILVA V.R., NASCIMENTO R.T. & SOARES H.R. (2020) **Análise comparativa de pressões horizontais durante o carregamento em silos verticais metálicos**. Pesquisa e Ensino em Ciências Exatas e da Natureza, 4: e1539. <http://dx.doi.org/10.29215/pecen.v4i0.1539> Editor acadêmico: Angel Ramon Sanchez Delgado. Recebido: 04 setembro 2020. Aceito: 30 outubro 2020. Publicado: 15 dezembro 2020.
- [23] PIEPER, K.; SCHÜTZ, M. **Bericht Über das Forschungsvorhaben - Norm-Mess-Silo für Schüttguteigenschaften**. Technische Universität Braunschweig - Lehrstuhl für Hochbaustatik, Deutschland, 1980, 109p.
- [24] RAMÍREZ, A.; NIELSEN, J; AYUGA, F. Pressure measurements in steel silos with eccentric hoppers. **Powder Technology**, v. 201, n. 1, p. 7-20, 2010.
- [25] REIS, S. G. dos. **Determinação das ações atuantes nos silos através de redes neurais artificiais**. 2011. 76 p. Dissertação (Mestrado em Engenharia de Sistemas) - Universidade Federal de Lavras, Lavras, 2011.
- [26] SIMÕES, M. G.; SHAW, I. S. Controle e Modelagem fuzzy. São Paulo: Blucher: FAPESP, 2007
- [27] VAZIRIZADE, S. M.; NOZHATI, S.; ZADEH, M. A. **Seismic reliability assessment of structures using artificial neural network**. Journal of Building Engineering, v. 11, n. November 2016, p. 230–235, 2017.
- [28] YUKSEL, S. B.; ARSLAN, M. H. Design force estimation using artificial neural network for groups of four cylindrical silos. **Advances in Structural Engineering**, v. 13, n. 4, p. 681-693, 2010.

## APÊNDICE A- Algoritmo para determinação das pressões horizontais e de atrito nas paredes do silo para carregamento, utilizando as Normas EN 1991-4 (2006) e AS 3774 (1996)

```

clear all
close
clc
disp('Lendo parametros...');
fname=('C:\Users\Simone\Desktop\MESTRADO\DADOS-REDES NEURAIIS.xls');
pasta=readxls(fname);
planilha1=pasta(1);
indice=samwvr(75,1,1:75);
ind_1 = max([treinamento(:,1); teste(:,1)]);
ind_2 = max([treinamento(:,2); teste(:,2)]);
ind_3 = max([treinamento(:,3); teste(:,3)]);
treinamento(:,1) = treinamento(:,1)/ind_1;
teste(:,1) = teste(:,1)/ind_1;
treinamento(:,2) = treinamento(:,2)/ind_2;
teste(:,2) = teste(:,2)/ind_2;
treinamento(:,3) = treinamento(:,3)/ind_3;
teste(:,3) = teste(:,3)/ind_3;
entrada=treinamento(:,1:2)';
saida=treinamento(:,3)';
entradataeste=teste(:,1:2)';
saidateste=teste(:,3)';
// Arquitetura da rede:
n=[size(entrada,1),10,3,1];
maxepocas=3000;
w=ann_FF_init(n);
erroepoca=[];
tp=[0.9, 0, 0.6, 0];
for k=1:maxepocas
    disp(k)
    [entrada,saida]=ann_pat_shuffle(entrada,saida);
    for z=1:size(entrada,2)
w=ann_FF_Mom_online(entrada(:,z),saida(:,z),n,w,tp,1);
//Fim
    end
//Resposta de treinamento (70%)
y=ann_FF_run(entrada,n,w);
// "Soma dos erros quadrados" dados de treinamento
erro=ann_sum_of_sqr(y,saida);
erroepoca=[erroepoca erro];
end
//Resposta de teste (30%)
resposta=ann_FF_run(entradataeste,n,w);
// "Soma dos erros quadrados" dados de teste (Validação)
errovalidacao=ann_sum_of_sqr(resposta,saidateste);
scf();
//Títulos do gráfico
xtitle('ERRO QUADRÁTICO MÉDIO X ÉPOCA', 'Épocas','Erro Quadrático Médio');
plot(erroepoca);
// Regressão Linear Multipla (RL)
X = [entrada; ones(1,size(entrada,2))];
w_RL = (X'*X)\X'*saida';
Xtteste = [entradataeste; ones(1,size(entradataeste,2))];
resposta_RL = [Xtteste*w_RL]';
// Regressão Polinomial (RP) - Com Regularização
xtitle('Comparação de Métodos', 'Número de amostra','Pressões Horizontais de Carregamento (kPa)');
X = [entrada; entrada.^2; entrada.^3; entrada.^4;
ones(1,size(entrada,2))];
lambda = 0;
w_RP = (X'*X + lambda*eye(size(X,2)))\X'*saida'
Xtteste = [entradataeste; entradataeste.^2; entradataeste.^3;
entradataeste.^4; ones(1,size(entradataeste,2))];
resposta_RP = [Xtteste*w_RP]';
// Norma - Eurocode
// Parâmetros
gama = 7.83; //gama médio
phi_w = 14.7*%pi/180; //phi_w médio
phi_e = 32.3*%pi/180; //phi_e médio
A = %pi*0.35^2;
U = %pi*0.7;
mi = tan(phi_w);
Z = entradataeste(1,:)*ind_1; // altura não normalizada

K_eu = 1.1*(1 - sin(phi_e));

NE = (gama/mi)*(A/U)*(1-exp(-Z*K_eu*mi*(U/A)));
resposta_NE = NE/ind_3;

// Norma - Australiana

K_au = (1+sin(phi_e)^2-2*sqrt(sin(phi_e)^2-mi^2*cos(phi_e)^2))/(4*mi^2+cos(phi_e)^2);
if K_au >= 0.35
    K_au = 0.35;
end

NA = (gama/mi)*(A/U)*(1-exp(-Z*K_au*mi*(U/A)));
resposta_NA = (mi*NA)/ind_3;

// Plot
scf();
plot(resposta,'o-r');
plot(resposta_RL,'o-g');
plot(resposta_RP,'o-c');
plot(resposta_NE,'o-m');
plot(saidateste,'o-b');
legend('Redes Neurais','Regressão Linear','Regressão Polinomial','Norma EN 1991-4 (2006)','Dados reais',-4);
// Medidas de Comparação
SQ_tot = sum((saidateste - mean(saidateste)).^2); //
SQ_res_RN = sum((saidateste - resposta).^2);
SQ_res_RL = sum((saidateste - resposta_RL).^2);
SQ_res_RP = sum((saidateste - resposta_RP).^2);
SQ_res_NE = sum((saidateste - resposta_NE).^2);
R2_RN = 1 - (SQ_res_RN / SQ_tot)
R2_RL = 1 - (SQ_res_RL / SQ_tot)
R2_RP = 1 - (SQ_res_RP / SQ_tot)
R2_NE = 1 - (SQ_res_NE / SQ_tot)

```

$MAE_{RN} = \text{mean}(\text{abs}(\text{resposta} - \text{saidateste}))$   
 $MAE_{RL} = \text{mean}(\text{abs}(\text{resposta}_{RL} - \text{saidateste}))$   
 $MAE_{RP} = \text{mean}(\text{abs}(\text{resposta}_{RP} - \text{saidateste}))$   
 $MAE_{NE} = \text{mean}(\text{abs}(\text{resposta}_{NE} - \text{saidateste}))$

$MAPE_{RN} = 100 * \text{mean}(\text{abs}(\text{saidateste} - \text{resposta}) / \text{saidateste})$   
 $MAPE_{RL} = 100 * \text{mean}(\text{abs}(\text{saidateste} - \text{resposta}_{RL}) / \text{saidateste})$   
 $MAPE_{RP} = 100 * \text{mean}(\text{abs}(\text{saidateste} - \text{resposta}_{RP}) / \text{saidateste})$   
 $MAPE_{NE} = 100 * \text{mean}(\text{abs}(\text{saidateste} - \text{resposta}_{NE}) / \text{saidateste})$

$MSE_{RN} = \text{mean}((\text{saidateste} - \text{resposta})^2)$   
 $MSE_{RL} = \text{mean}((\text{saidateste} - \text{resposta}_{RL})^2)$   
 $MSE_{RP} = \text{mean}((\text{saidateste} - \text{resposta}_{RP})^2)$   
 $MSE_{NE} = \text{mean}((\text{saidateste} - \text{resposta}_{NE})^2)$

$RMSE_{RN} = \text{sqrt}(MSE_{RN})$   
 $RMSE_{RL} = \text{sqrt}(MSE_{RL})$   
 $RMSE_{RP} = \text{sqrt}(MSE_{RP})$   
 $RMSE_{NE} = \text{sqrt}(MSE_{NE})$

$RMSE_{p_{RN}} = RMSE_{RN} * 100 / \text{mean}(\text{saidateste})$   
 $RMSE_{p_{RL}} = RMSE_{RL} * 100 / \text{mean}(\text{saidateste})$   
 $RMSE_{p_{RP}} = RMSE_{RP} * 100 / \text{mean}(\text{saidateste})$   
 $RMSE_{p_{NE}} = RMSE_{NE} * 100 / \text{mean}(\text{saidateste})$

## APÊNDICE B - Algoritmo para determinação das pressões horizontais e de atrito nas paredes do silo para descarregamento, utilizando as Normas EN 1991-4 (2006) e AS 3774 (1996)

```

clear all
close
clc
disp('Lendo parametros...');
fname=('C:\Users\Simone\Desktop\MESTRADO\DADOS-REDES NEURAIIS.xls');
pasta=readxls(fname);
planilha1=pasta(1);
indice=samwvr(75,1,1:75);
ind_1 = max([treinamento(:,1); teste(:,1)]);
ind_2 = max([treinamento(:,2); teste(:,2)]);
ind_3 = max([treinamento(:,3); teste(:,3)]);
treinamento(:,1) = treinamento(:,1)/ind_1;
teste(:,1) = teste(:,1)/ind_1;
treinamento(:,2) = treinamento(:,2)/ind_2;
teste(:,2) = teste(:,2)/ind_2;
treinamento(:,3) = treinamento(:,3)/ind_3;
teste(:,3) = teste(:,3)/ind_3;
entrada=treinamento(:,1:2)';
saida=treinamento(:,3)';
entradateste=teste(:,1:2)';
saidateste=teste(:,3)';
// Arquitetura da rede:
n=[size(entrada,1),10,3,1];
maxepocas=3000;
w=ann_FF_init(n);
erroepoca=[];
tp=[0.9, 0, 0.6, 0];
for k=1:maxepocas
    disp(k)
    [entrada,saida]=ann_pat_shuffle(entrada,saida);
    for z=1:size(entrada,2)
w=ann_FF_Mom_online(entrada(:,z),saida(:,z),n,w,tp,1);
//Fim
    end
//Resposta de treinamento (70%)
y=ann_FF_run(entrada,n,w);
// "Soma dos erros quadrados" dados de treinamento
erro=ann_sum_of_sqr(y,saida);
erroepoca=[erroepoca erro];
end
//Resposta de teste (30%)
resposta=ann_FF_run(entradateste,n,w);
NE_desc = NE*Ch;
resposta_NE_desc = NE_desc/ind_3;
// Norma - Australiana
K_au = (1+sin(phi_e)^2-2*sqrt(sin(phi_e)^2-
mi^2*cos(phi_e)^2))/(4*mi^2+cos(phi_e)^2);
if K_au >= 0.35
    K_au = 0.35;
end
NA = (gama/mi)*(A/U)*(1-exp(-Z*K_au*mi*(U/A)));
resposta_NA_desc = (mi*NA*1.4)/ind_3;

// "Soma dos erros quadrados" dados de teste (Validação)
errovalidacao=ann_sum_of_sqr(resposta,saidateste);
scf();
//Títulos do gráfico
xtitle('ERRO QUADRÁTICO MÉDIO X ÉPOCA', 'Épocas','Erro
Quadrático Médio');
plot(erroepoca);
// Regressão Linear Multipla (RL)
X = [entrada; ones(1,size(entrada,2))];
w_RL = (X'*X)\X'*saida';
Xteste = [entradateste; ones(1,size(entradateste,2))];
resposta_RL = [Xteste*w_RL]';
// Regressão Polinomial (RP) - Com Regularização
xtitle('Comparação de Métodos', 'Número de
amostra','Pressões Horizontais de Descarregamento
(kPa)');
X = [entrada; entrada.^2; entrada.^3; entrada.^4;
ones(1,size(entrada,2))];
lambda = 0;
w_RP = (X'*X + lambda*eye(size(X,2)))\X'*saida'
Xteste = [entradateste; entradateste.^2; entradateste.^3;
entradateste.^4; ones(1,size(entradateste,2))];
resposta_RP = [Xteste*w_RP]';
// Norma - Eurocode - Descarregamento
// Parâmetros
gama = 7.83; //gama médio
phi_w = 14.7*pi/180; //phi_w médio
phi_e = 32.3*pi/180; //phi_e médio
A = %pi*0.35^2;
U = %pi*0.7;
mi = tan(phi_w);
Z = entradateste(1,:)*ind_1; // altura não normalizada

K_eu = 1.1*(1-sin(phi_e));

NE = (gama/mi)*(A/U)*(1-exp(-Z*K_eu*mi*(U/A)));

Ch = 1.35 + 0.02*(phi_e - 30*pi/180);
if Ch>= 1.35
    Ch = 1.35;
end
MAPE_RN = 100*mean(abs((saidateste -
resposta)/saidateste))
MAPE_RL = 100*mean(abs((saidateste -
resposta_RL)/saidateste))
MAPE_RP = 100*mean(abs((saidateste -
resposta_RP)/saidateste))
MAPE_NE = 100*mean(abs((saidateste -
resposta_NE)/saidateste))

MSE_RN = mean((saidateste - resposta).^2)
MSE_RL = mean((saidateste - resposta_RL).^2)
MSE_RP = mean((saidateste - resposta_RP).^2)
MSE_NE = mean((saidateste - resposta_NE).^2)

RMSE_RN = sqrt(MSE_RN)
RMSE_RL = sqrt(MSE_RL)
RMSE_RP = sqrt(MSE_RP)

```



```

plot(resposta_RL,'o-g');
plot(resposta_RP,'o-c');
plot(resposta_NE,'o-m');
plot(saidateste,'o-b');
legend('Redes Neurais','Regressão Linear','Regressão
Polinomial','Norma EN 1991-4 (2006)','Dados reais',-4);
// Medidas de Comparação
SQ_tot = sum((saidateste - mean(saidateste)).^2); //
SQ_res_RN = sum((saidateste - resposta).^2);
SQ_res_RL = sum((saidateste - resposta_RL).^2);
SQ_res_RP = sum((saidateste - resposta_RP).^2);
SQ_res_NE = sum((saidateste - resposta_NE).^2);
R2_RN = 1 - (SQ_res_RN / SQ_tot)
R2_RL = 1 - (SQ_res_RL / SQ_tot)
R2_RP = 1 - (SQ_res_RP / SQ_tot)
R2_NE = 1 - (SQ_res_NE / SQ_tot)
MAE_RN = mean(abs(resposta - saidateste))
MAE_RL = mean(abs(resposta_RL - saidateste))
MAE_RP = mean(abs(resposta_RP - saidateste))
MAE_NE = mean(abs(resposta_NE - saidateste))

```

```
RMSE_NE = sqrt(MSE_NE)
```

```
RMSE_p_RN = RMSE_RN*100/mean(saidateste)
```

```
RMSE_p_RL = RMSE_RL*100/mean(saidateste)
```

```
RMSE_p_RP = RMSE_RP*100/mean(saidateste)
```

```
RMSE_p_NE = RMSE_NE*100/mean(saidateste)
```