



SEBASTIÃO GIOVANI DOS REIS

**DETERMINAÇÃO DAS AÇÕES ATUANTES
NOS SILOS ATRAVÉS DE REDES NEURAIAS
ARTIFICIAIS**

LAVRAS - MG

2011

SEBASTIÃO GIOVANI DOS REIS

**DETERMINAÇÃO DAS AÇÕES ATUANTES NOS SILOS ATRAVÉS DE
REDES NEURAS ARTIFICIAIS**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas, área de concentração em Modelagem de Sistemas Biológicos, para a obtenção do título de Mestre.

Orientador

Dr. Francisco Carlos Gomes

LAVRAS - MG

2011

**Ficha Catalográfica Preparada pela Divisão de Processos Técnicos da
Biblioteca da UFLA**

Reis, Sebastião Giovani dos.

Determinação das ações atuantes nos silos através de redes neurais artificiais / Sebastião Giovani dos Reis. – Lavras : UFLA, 2011.

76 p. : il.

Dissertação (mestrado) – Universidade Federal de Lavras, 2011.

Orientador: Francisco Carlos Gomes.

Bibliografia.

1. Pressões. 2. Escoamento. 3. Aprendizagem. 4. Treinamento. 5. Funções não-lineares. I. Universidade Federal de Lavras. II. Título.

CDD – 681.7631

SEBASTIÃO GIOVANI DOS REIS

**DETERMINAÇÃO DAS AÇÕES ATUANTES NOS SILOS ATRAVÉS DE
REDES NEURAIS ARTIFICIAIS**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas, área de concentração em Modelagem de Sistemas Biológicos, para a obtenção do título de Mestre.

APROVADA em 25 de fevereiro de 2011.

Dr. Francisco Carlos Gomes UFLA

Dr. Wilian Soares Lacerda UFLA

Dr. José Wallace Barbosa Nascimento UFCG

Dr. Francisco Carlos Gomes

Orientador

LAVRAS – MG

2011

Aos meus pais, Vitor e Maria pelo incentivo e confiança

OFEREÇO.

À minha noiva pelo amor, apoio e compreensão,

DEDICO.

AGRADECIMENTOS

A Deus, por me guiar em mais uma etapa da minha vida, pelo amor incondicional e por tudo que me tem concedido.

Aos meus pais, agradeço por tudo que fazem na minha vida e por terem me dado força para que meu sonho se tornasse realidade. Amo vocês.

A minha noiva Juciara, o grande amor da minha vida, por compartilhar comigo momentos felizes, momentos de tristeza e dificuldades. Amo você!

Ao Professor Dr. Francisco Carlos Gomes, pela orientação, paciência, amizade, dedicação e seus ensinamentos que foram de grande relevância para a realização deste trabalho e meu crescimento profissional.

À Universidade Federal de Lavras e ao Departamento de Engenharia, pela oportunidade concedida para a realização do mestrado.

À Fundação de Amparo e Pesquisa do Estado de Minas Gerais (Fapemig) pela concessão de bolsa de estudos.

Aos professores do Departamento de Engenharia da UFLA, pelos ensinamentos transmitidos e harmoniosa convivência.

A todos que colaboraram durante o desenvolvimento deste trabalho.

"Porque dele, e por ele, e para ele são todas as coisas".

Rm 11:36

RESUMO

O Armazenamento de produtos a granel é realizado em construções denominados silos, os quais são tipicamente utilizados na indústria, agricultura, siderurgia e portos, entre outros. Esses silos podem ser construídos com os mais diversos tipos de materiais, tais como, concreto armado, aço, madeira, argamassa armada, etc. A maioria dos silos existentes no mundo não apresenta condições ideais de operação devido ao pouco conhecimento das pressões, fluxo e também devido ao grande número de variáveis envolvidas, que afetam o comportamento dos produtos armazenados nos silos. Isso explica a grande quantidade de acidentes e colapsos. Objetiva-se com este trabalho, determinar e avaliar os métodos de cálculo das pressões atuantes nos silos e o escoamento do produto através de uma técnica de inteligência artificial conhecida como Redes Neurais Artificiais. Esta é uma forte ferramenta computacional utilizada em diferentes áreas da ciência e é inspirada na estrutura neural de organismos inteligentes, que adquirem conhecimento através da experiência. A utilização dessa ferramenta proporciona métodos alternativos para análises dessas ações, fornecendo resultados confiáveis de acordo com os principais códigos normativos internacionais.

Palavras-chave: Silos. Redes Neurais. Pressões. Fluxo.

ABSTRACT

Storage of bulk products is performed in buildings called silos, which are typically used in industry, agriculture, steel and ports, among others. These silos can be built with several types of materials such as concrete, steel mill, wood, mortar, etc.. Most of the silos in the world does not present ideal conditions of operation due to poor knowledge of the pressures, flow and also due to the large number of variables that affect the behavior of the products stored in silos. This explains the large number of accidents and collapse. Objective with this research was to determine and evaluate the methods of calculation of the pressures acting in silos and the flow of product through an artificial intelligence technique known as Artificial Neural Networks. This is a powerful computational tool used in different areas of science and is inspired by the neural structure of intelligent organisms, acquiring knowledge through experience. Using this tool provides alternative methods for analysis of these actions, providing reliable results in accordance with key international regulatory codes.

Keywords: Silos. Neural Networks. Pressure. Flow.

LISTA DE FIGURAS

Figura 1 Partes constituintes dos Silos	18
Figura 2 Célula de cisalhamento de Jenike.....	20
Figura 3 Célula de cisalhamento para determinação do ângulo de atrito com a parede (ϕ_w).....	23
Figura 4 Pressões atuantes em um silo	26
Figura 5 Forças agindo sobre uma camada elementar	28
Figura 6 Representação de um neurônio extraído da coluna vertebral de um mamífero.	37
Figura 7 Modelo não linear de um neurônio.....	38
Figura 8 Estrutura de uma rede neural.....	40
Figura 9 Correção dos pesos por <i>backpropagation</i>	45
Figura 10 Fluxograma do cálculo neural	57

LISTA DE GRÁFICOS

Gráfico 1 Lugar geométrico de deslizamento	21
Gráfico 2 Ângulo de atrito interno e efetivo ângulo de atrito interno.....	22
Gráfico 3 Lugar geométrico de deslizamento com a parede.....	23
Gráfico 4 Pressões na parede do silo em função dos ciclos de carregamento, armazenamento e descarga	27
Gráfico 5 Tipos de função de ativação	39
Gráfico 6 Função erro para um único peso	48
Gráfico 7 Gráfico do erro médio a cada época (10000).....	60
Gráfico 8 Gráfico do erro médio a cada época (20.000).....	61
Gráfico 9 Gráficos comparativos entre as ações atuantes no corpo do silo para armazenamento de produtos: (a) Pressão Horizontal (b) Pressão Vertical (c) Pressão de Atrito.	62
Gráfico 10 Gráficos comparativos entre as ações atuantes na tremonha para armazenamento de produtos: (a) Pressão Normal (b) Pressão de Atrito	64
Gráfico 11 Gráfico comparativo para a escoabilidade do produto	65

LISTA DE TABELAS

Tabela 1 Classificação quanto à esbeltez.....	17
Tabela 2 Limites apropriados para as propriedades físicas.....	19
Tabela 3 Pressões sobre a parede do corpo do silo.....	32
Tabela 4 Pressões sobre a prede da tremonha.....	35
Tabela 5 Propriedades físicas de diversos produtos agrícolas.....	52
Tabela 6 Propriedades físicas dos produtos sólidos.....	52
Tabela 7 Faixas entre os valores limites dos produtos.....	53

LISTA DE SÍMBOLOS

ϕ_i	Ângulo de atrito interno
ϕ_e	Efetivo ângulo de atrito interno
ϕ_w	Ângulo de atrito com a parede
ϕ_{es}	Valor superior do efetivo ângulo de atrito interno
ϕ_{ws}	Valor superior do ângulo de atrito com a parede
γ	Peso específico
FF	Função fluxo do produto
ff	Fator fluxo da tremonha
σ_{pre}	Tensão normal à célula de cisalhamento na etapa de pré-cisalhamento
σ_1	Tensão de consolidação
σ_c	Tensão inconfiada de ruptura
τ_{pre}	Tensão cisalhante na etapa de pré-cisalhamento
α	Inclinação da tremonha
Ph	Pressão horizontal
Pv	Pressão vertical
Pw	Pressão de atrito com a parede no corpo do silo
Pn	Pressão normal à parede da tremonha
Pt	Pressão de atrito na parede da tremonha
K	Índice K
H	Altura do corpo do silo
D	Dimensional do corpo do silo
φ	Função de ativação da rede neural
$e_k(n)$	Erro produzido na saída da rede neural
$y_k(n)$	Valor de saída da rede neural
$d_k(n)$	Valor desejado para a rede neural
w_{ij}	Peso sináptico
Δw_{ij}	Gradiente do peso sináptico

SUMÁRIO

1	INTRODUÇÃO	14
2	REFERENCIAL TEÓRICO	16
2.1	Estruturas de armazenamento	16
2.2	Propriedade físicas e de fluxo do produto armazenado	18
2.2.1	Peso específico	19
2.2.2	Lugar geométrico de deslizamento	20
2.3	Ações atuantes em silos	25
2.3.1	Teoria de Janssen	27
2.3.2	Teoria de Walker	30
2.3.3	Normas internacionais analisadas	31
2.3.3.1	Pressões no corpo do silo	32
2.3.3.2	Pressões na tremonha	35
2.4	Redes neurais artificiais	36
2.4.1	Aprendizagem	41
2.4.1.1	Aprendizagem por correção de erro	43
2.4.1.2	Rede neural <i>Backpropagation</i>	44
2.4.1.3	Ajustes dos pesos	46
2.4.1.4	Ajustes dos pesos da camada de saída	48
2.4.2	Projeto de uma rede neural	49
2.4.3	Aplicações	50
3	MATERIAIS E MÉTODOS	51
3.1	Levantamento dos dados	51
3.2	Ferramentas de desenvolvimento	53
3.3	Sistema computacional	54
3.3.1	Construção e configuração da rede neural	54
3.3.2	Treinamento do sistema e testes de desempenho	55
3.4	Desenvolvimento da rede neural artificial	56
4	RESULTADOS E DISCUSSÕES	58
4.1	Dados obtidos	58
4.2	Configuração da rede neural	58
4.3	Treinamento da rede neural	59
4.4	Resultados alcançados	61
5	CONCLUSÕES	66
	REFERÊNCIAS	67
	ANEXOS	69

1 INTRODUÇÃO

Silos são estruturas de armazenamentos de produtos granulares e pulverulentos a granel, utilizados na indústria, agricultura, siderurgia e portos, entre outros.

O armazenamento de produtos em silos é considerado uma solução de grande viabilidade devido a uma série de fatores, tais como: economia de espaço físico, mão de obra, conservação do produto ensilado, custo de transporte, controle de escoamento e abastecimento.

A grande demanda por silos no Brasil pode ser explicada devido ao constante crescimento da produção e da exportação agrícola, acarretando assim a necessidade pelo armazenamento de grandes quantidades de produtos em espaços reduzidos.

A elaboração dos projetos estruturais de silos, que é uma tendência mundial, requer uma precisa determinação das ações atuantes nos silos, no intuito de propiciar o correto dimensionamento de maneira segura e econômica, evitando danos e acidentes futuros.

No projeto de silos, as principais ações a serem consideradas são as provenientes dos produtos armazenados que exercem pressões nas paredes verticais e no fundo do silo. Na parede vertical, atuam pressões perpendiculares, denominadas pressões horizontais (P_h) e pressões de atrito do produto com a parede (P_w). No fundo do silo, atuam pressões denominadas pressões verticais (P_v). Outras ações importantes que são consideradas neste trabalho estão relacionadas ao escoamento do produto, que influenciam diretamente nas pressões nas paredes do silo.

Atualmente, há diferentes normas internacionais para projetos de silos, as quais adotam métodos teóricos e empíricos para o estudo das ações. Cada norma internacional adota uma metodologia diferente para o cálculo dessas

ações, resultando em diferentes resultados de dimensionamentos para os projetos em função da grande variabilidade dos fatores que interferem no cálculo das pressões e fluxo.

Essa divergência nas teorias existentes pode oferecer alguns riscos de segurança na elaboração dos projetos, pois, dependendo da região em que se pretenda implementar o projeto, determinadas teorias são ineficientes e não abordam todas as variáveis que influenciam diretamente nas ações atuantes nos silos.

Neste trabalho, procurou-se modelar as ações atuantes nos silos, de maneira mais ampla e que leve em consideração um memorial de estudos já realizados nos cálculos das ações sob as mais diversas situações, por meio de uma técnica de inteligência artificial conhecida como Redes Neurais Artificiais.

A escolha por essa ferramenta matemática foi devido a sua capacidade de extrair modelos e aproximar de funções não lineares complexas. As redes neurais, diferentes de outros modelos computacionais convencionais, processam a informação de forma similar ao sistema nervoso biológico. Essa ferramenta aprende através de exemplos selecionados cuidadosamente, o que a torna eficaz para sistemas não-lineares, na adaptação a circunstâncias e também no seu poder de generalização.

2 REFERENCIAL TEÓRICO

2.1 Estruturas de armazenamento

O armazenamento dos produtos agrícolas faz-se necessário pela oportunidade de aumento da lucratividade das empresas, devido ao poder de conservação do produto, o que possibilita a venda em épocas quando a especulação do mercado está mais favorável.

Segundo Silva (1998), o armazenamento no Brasil, até a década de 70, concentrava-se no litoral, sendo feito predominantemente em sacarias. A partir da década de 70, iniciaram-se a interiorização e granelização da rede de armazenamento nacional.

Segundo Gomes (2000), a expansão da rede armazenadora no Brasil se fez pelo aumento das atividades destinadas à conservação dos produtos agrícolas e manutenção dos estoques reguladores por parte do governo federal.

Uma rede armazenadora é um conjunto de estruturas destinadas a armazenar grãos, além de conservá-los e redistribuí-los, composta por unidades de armazenamento, como silos e armazéns.

Os silos são estruturas de armazenamento mais utilizados entre os produtores, cooperativas, unidades coletoras, intermediárias e terminais. Esse sistema apresenta algumas vantagens, tais como: menor espaço, controle de temperatura, controle de escoamento e menor custo operacional.

Algumas normas apresentam as relações de classificação de silos quanto à esbeltez, conforme listado na Tabela 1.

Tabela 1 Classificação quanto à esbeltez

NORMA	CLASSIFICAÇÃO		
	BAIXOS	MEDIANAMENTE ESBELTOS	ESBELTOS
Australiana AS3774 : 1996	$H/D < 1,0$	$1,0 \leq H/D \leq 3,0$	$H/D > 3,0$
DIN 1055 – 03:2005	$0,4 \leq H/D \leq 1,0$	$1,0 \leq H/D \leq 2,0$	$H/D > 2,0$

Fonte: Calil Junior, Nascimento e Araújo (1997)

Além de serem classificados de acordo com sua esbeltez, os silos se diferenciam quanto a sua forma geométrica. Os tipos mais comumente utilizados são: silos quadráticos, silos cilíndricos e silo de superfície. Cada um deles tem suas vantagens e desvantagens, principalmente, ao custo de construção, facilidade de carregamento e descarga e eficiência na conservação da silagem.

Os silos são constituídos basicamente das seguintes partes (Figura 1):

- a) corpo do silo: estrutura que compreende o topo do silo até a base da tremonha. Diferenciam-se de acordo com sua altura, forma geométrica e material empregado na sua construção;
- b) tremonha: Estrutura por onde se dá o escoamento do produto. Diferenciam-se de acordo com sua altura, forma geométrica, ângulo de inclinação com a superfície e o material empregado na sua construção.

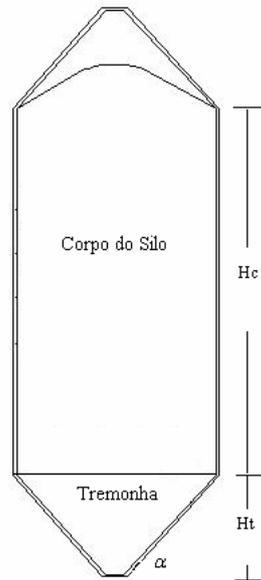


Figura 1 Partes constituintes dos Silos

2.2 Propriedade físicas e de fluxo do produto armazenado

Para o projeto de estruturas a granel, devem-se levar em consideração os parâmetros das propriedades físicas e de fluxo dos produtos armazenados. Normalmente, consideram-se as seguintes propriedades:

- peso específico (γ);
- ângulo de atrito interno (ϕ_i);
- efetivo ângulo de atrito interno (ϕ_e);
- ângulo de atrito com a parede (ϕ_w);
- função fluxo (FF) e
- fator fluxo da tremonha (ff).

Tendo como referência a norma australiana (AUSTRALIAN STANDART, 1996; CALIL JUNIOR; NASCIMENTO; ARAÚJO, 1997; NASCIMENTO, 1996; SILVA, 1998) propuseram limites para cada parâmetro do projeto (Tabela 2), em que são estabelecidos limites com valores máximo e mínimo de cada uma das propriedades, obtendo-se a combinação mais desfavoráveis.

Tabela 2 Limites apropriados para as propriedades físicas

Aplicação da propriedade	Peso específico do produto	Ângulo de atrito com a parede	Relação entre as pressões
Pressão máxima normal na parede	Superior	Inferior	Superior
Força de atrito máxima na parede	Superior	Inferior	Inferior
Pressões máximas na tremonha	Superior	Superior	Superior

Fonte: Adaptado de Calil Junior, Nascimento e Araújo (1997)

2.2.1 Peso específico

Entende-se por peso específico a massa das partículas sólidas, contidas em um recipiente, dividido pelo volume total desse recipiente e multiplicado pela aceleração da gravidade ($g= 9,81 \text{ ms}^{-2}$).

As normas internacionais recomendam que sejam utilizados os valores determinados em laboratório, considerando os valores superiores e inferiores. Caso a determinação em laboratório não seja possível, deverão ser utilizados valores tabelados, multiplicados por 0,75 e 1,25 para a determinação dos valores inferiores e superiores, respectivamente.

2.2.2 Lugar geométrico de deslizamento

Jenike (1964) desenvolveu um aparelho de cisalhamento para a determinação das propriedades dos produtos armazenados em silos conhecido como *Jenike shear tester* (Figura 2), baseado em uma metodologia de ensaios composta por cisalhamentos.

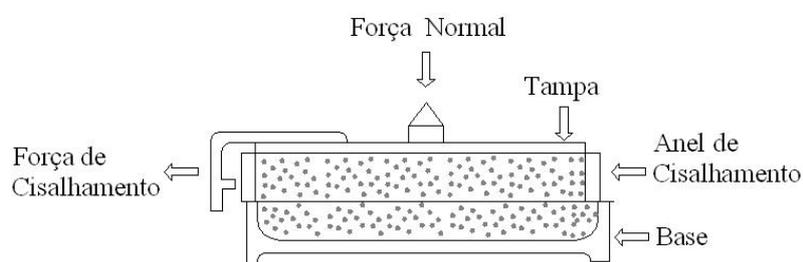


Figura 2 Célula de cisalhamento de Jenike

Fonte: Calil Junior, Nascimento e Araújo (1997)

Esse aparelho funciona da seguinte maneira: a amostra é colocada na célula de cisalhamento do aparelho sob uma tensão normal qualquer, submetido a esforços de cisalhamento necessário para romper a tensão de resistência da amostra. Esse cisalhamento ocorre até um limite onde as tensões passam a ser constantes. Nesse momento, diz-se que a amostra está consolidada. Os valores de tensão normal σ_{pre} e tensão cisalhamento τ_{pre} formam o ponto de estado de fluxo estável, o lugar geométrico de deslizamento e suas tensões formam os semicírculos de Mohr (Gráfico 1), que possibilitam determinar algumas das propriedades, como o ângulo de atrito interno, o efetivo ângulo de atrito interno e, indiretamente, a função fluxo e o fator fluxo.

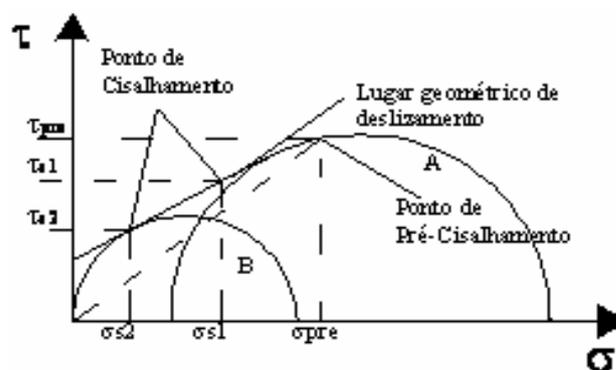


Gráfico 1 Lugar geométrico de deslizamento

Fonte: Calil Junior, Nascimento e Araújo (1997)

O ângulo de atrito interno (ϕ_i) é o ângulo formado entre a linha que representa o lugar geométrico de deslizamento e o eixo das tensões normais. A linha que passa pela origem e tangência o maior semicírculo de Mohr, ou seja, o círculo que representa o estado de fluxo estável, é chamada de efetivo lugar geométrico de deslizamento e o ângulo formado entre essa linha e o eixo das tensões normais, de efetivo ângulo de atrito interno (ϕ_e) (Gráfico 2). De uma maneira mais clara, o ângulo de atrito interno representa o atrito existente entre o produto dentro da estrutura de armazenamento.

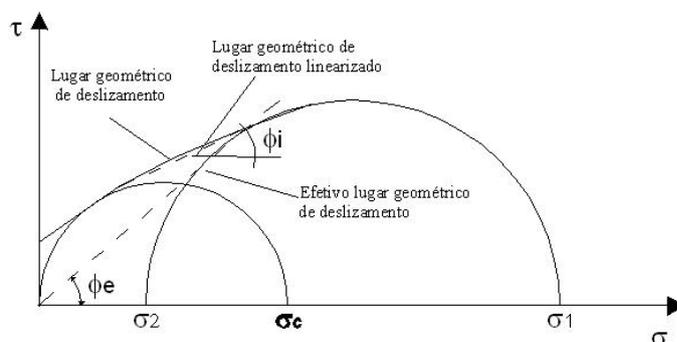


Gráfico 2 Ângulo de atrito interno e efetivo ângulo de atrito interno

Fonte: Calil Junior, Nascimento e Araújo (1997)

Outra propriedade que pode ser determinada utilizando o aparelho de cisalhamento de Jenike, é o ângulo de atrito com a parede (ϕ_w). Esse ângulo representa o atrito existente entre o produto e a parede do silo. Para a determinação dessa propriedade, aplica-se o mesmo procedimento de cisalhamento, porém, substituindo-se o anel inferior da célula de cisalhamento por uma chapa do material da parede a ser estudada (Figura 3), obtêm-se, como resultado, os gráficos das tensões (Gráfico 3), nas quais se pode determinar o ângulo de atrito com a parede. Os materiais comumente utilizados são aço liso, aço rugoso, madeira, acrílico e concreto.

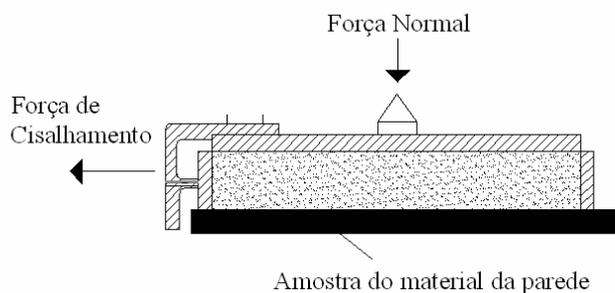


Figura 3 Célula de cisalhamento para determinação do ângulo de atrito com a parede (ϕ_w)

Fonte: Calil Junior, Nascimento e Araújo (1997)

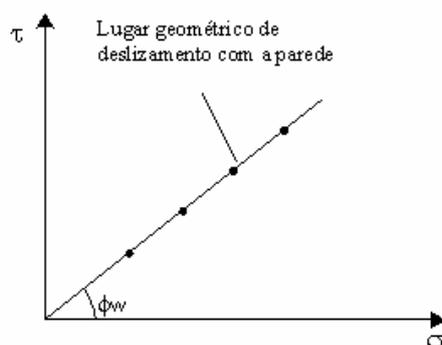


Gráfico 3 Lugar geométrico de deslizamento com a parede

Fonte: Calil Junior, Nascimento e Araújo (1997)

O escoamento do produto pode ser determinado por meio de duas propriedades importantes: função fluxo (FF) e o fator fluxo (ff). Para a determinação da função fluxo, é necessário analisar outras propriedades de fluxo, sendo elas a tensão de consolidação (σ_1) e a tensão incondfinada de ruptura (σ_c). Ambas as propriedades são determinadas através do gráfico das tensões citado anteriormente (Gráfico 1). A tensão de consolidação é igual a tensão principal do maior semicírculo de Mohr, que é tangente ao lugar geométrico de

deslizamento. A tensão confinada representa a maior tensão principal do menor semicírculo de Mohr, que é tangente ao lugar geométrico de deslizamento.

De acordo com Jenike (1964), a função fluxo pode ser classificada de acordo com determinados valores limites. Sendo essa propriedade uma relação direta entre a pressão de consolidação (σ_1) e a resistência confinada (σ_c), sendo expressa da seguinte forma:

$$FF = \frac{\sigma_1}{\sigma_c} \quad (1)$$

Jenike (1964) apresenta os seguintes valores limites:

$FF < 2$	Produto muito coesivo, não flui;
$2 < FF < 4$	Produto coesivo;
$4 < FF < 10$	Produto que flui facilmente e
$FF > 10$	Produto de fluxo livre

O fator fluxo está relacionado com as propriedades físicas do produto armazenado e com as características geométricas do silo. A determinação do fator fluxo da tremonha depende do efetivo ângulo de atrito interno (ϕ_c), do ângulo de atrito do produto com a parede (ϕ_w) e da geometria e inclinação da tremonha (α).

Enstad (1975) propôs um equacionamento que permite determinar o fator fluxo da tremonha (PALMA, 2005):

$$F(\alpha) = \left(\frac{65}{130 + \alpha} \right)^m \left(\frac{200}{200 + \alpha} \right)^{1-m} \quad (2)$$

$$2x\beta = \phi_{ws} + \text{sen}^{-1}\left(\frac{\text{sen}\phi_{ws}}{\text{sen}\phi_{es}}\right) \quad (3)$$

$$\theta = \beta + \alpha \quad (4)$$

$$X = \frac{2^m \text{sen}\phi_{es}}{1 - \text{sen}\phi_{es}} \left[\frac{\text{sen}(\beta + \theta)}{\cos(90 - \alpha)} + 1 \right] \quad (5)$$

$$Y = \frac{[2(1 - \cos\theta)]^m \theta^{1-m} \cos(90 - \alpha) + \text{sen}\beta(\text{sen}\theta)^{1+m}}{(1 - \text{sen}\phi_{es})(\text{sen}\theta)^{2+m}} \quad (6)$$

$$ff = \frac{Y(1 + \text{sen}\phi_{es})}{2(X - 1)F(\alpha)\cos(90 - \alpha)} \quad (7)$$

em que:

$\phi_{es} \rightarrow$ Valor superior do efetivo ângulo de atrito interno;

$\phi_{ws} \rightarrow$ Valor superior do ângulo de atrito com a parede;

$\alpha \rightarrow$ Inclinação da tremonha;

$m = 0$, para tremonhas retangulares, onde $L \geq 30$;

$L \rightarrow$ maior dimensão da boca de descarga retangular (cm);

$m = 1$ para tremonhas de eixo simétrico.

2.3 Ações atuantes em silos

As ações atuantes nos silos, devido ao produto armazenado, exercem pressões nas paredes verticais e no fundo do silo. Nas paredes verticais, atuam pressões perpendiculares, denominadas de pressões horizontais (P_h) e pressões

de atrito do produto com a parede (P_w). No fundo do silo, atuam as pressões denominadas de pressões verticais, que são representadas pelas pressões perpendiculares à parede da tremonha (P_n) e pressões de atrito na parede da tremonha (P_t) (Figura 4).

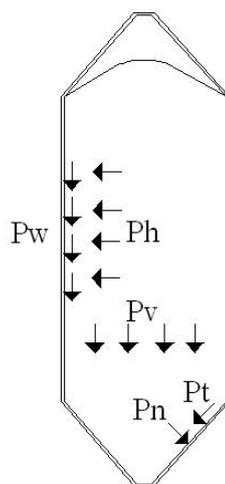


Figura 4 Pressões atuantes em um silo

Um ponto importante a respeito das pressões incidentes nas paredes é o ciclo de carregamento do silo. Durante o seu tempo de uso, o silo é solicitado por uma série de ciclos: armazenamento, carregamento e descarga. Como visto na Gráfico 4, as tensões que ocorrem enquanto o silo está sendo carregado são completamente diferentes das tensões dinâmicas, que ocorrem no descarregamento do silo.

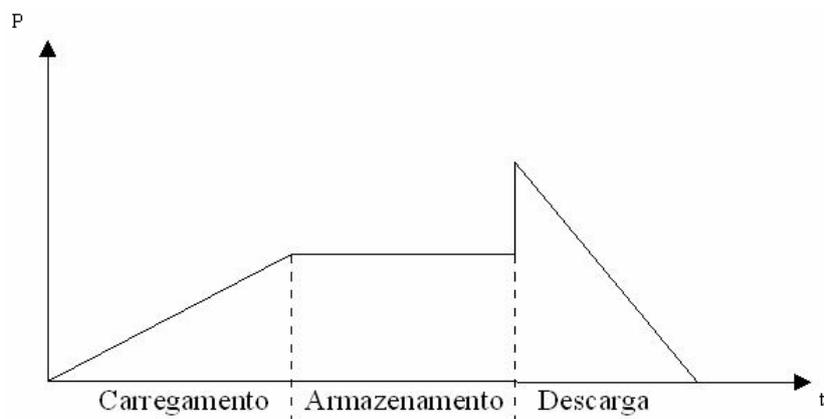


Gráfico 4 Pressões na parede do silo em função dos ciclos de carregamento, armazenamento e descarga

Fonte: Ravenet (1992)

Um dos trabalhos considerados de maior importância no estudo das pressões em silos foi o mostrado por Janssen (1895), na Alemanha. Janssen (1895) propôs a teoria conhecida como método da camada elementar (RAVENET, 1992). A teoria de Janssen (1895) é utilizada ainda hoje pela maioria das normas internacionais para o cálculo das pressões estáticas e de carregamento. As pressões dinâmicas também podem ser determinadas pela mesma teoria, entretanto devem ser utilizados coeficientes de sobrepressão aos valores obtidos nas condições estáticas.

2.3.1 Teoria de Janssen

A teoria de Janssen é baseada nas seguintes hipóteses:

- a) as pressões horizontais são constantes no mesmo plano horizontal;
- b) o valor do ângulo de atrito do produto com a parede é constante;
- c) o peso específico do produto é uniforme;
- d) as paredes do silo são totalmente rígidas;

- e) a relação entre as pressões horizontais e verticais (índice K) é constante em toda a altura do silo.

As pressões vertical e horizontal são determinadas pelo equilíbrio das forças verticais que atuam numa camada infinitesimal do produto armazenado.

Sobre essa camada infinitesimal, atuam o peso próprio da mesma, as forças nas faces superior e inferior, devido ao produto armazenado, e a força devido ao atrito entre o produto e a parede (Figura 9).

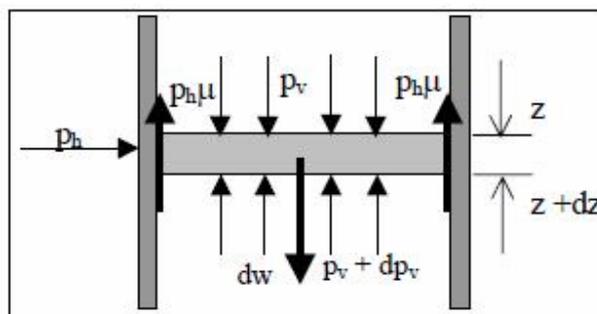


Figura 5 Forças agindo sobre uma camada elemental

Fonte: Janssen (1895)

sendo:

q = pressão de atrito sobre a parede, onde $q = \mu \text{ tg}\phi_w$.

γ = peso específico do produto;

A = área da seção transversal horizontal do silo;

l = perímetro da seção transversal;

z = altura do produto acima da seção transversal considerada;

R = raio hidráulico.

Sendo a força de atrito total que atua na camada infinitesimal:

$$q_{total} = qldz \quad (8)$$

Através do equilíbrio das forças na direção vertical, chega-se à seguinte equação diferencial:

$$\frac{dp_v}{z - \frac{\mu' kp_v}{R}} = dy \quad (9)$$

Integrando-se a equação anterior, tem-se:

$$\ln\left(z - \frac{\mu' kp_v}{R}\right) = \left(-\frac{\mu' k}{R} z\right) + c \quad (10)$$

Quando $z = 0$, tem-se $p_v=0$, então $c = \ln(z)$ e, chega-se às equações de Janssen:

a) Pressão horizontal:

$$Ph = \frac{\gamma R}{\mu'} \left(1 - e^{-\frac{\mu' K}{R} z}\right) \quad (11)$$

b) Pressão vertical:

$$P_v = \frac{\gamma R}{K\mu'} \left(1 - e^{-\frac{\mu'K}{R}z} \right) = \frac{Ph}{K} \quad (12)$$

c) Pressão de atrito por 1m^2 de superfície de parede:

$$P_{w_f} = \gamma R \left(1 - e^{-\frac{\mu'K}{R}z} \right) \quad (13)$$

2.3.2 Teoria de Walker

Em 1966, na Inglaterra, Walker desenvolve a sua teoria sobre o fluxo de produtos para silos. Sua teoria também é baseada nas forças que atuam sobre uma camada elementar.

Para pressões estáticas no corpo do silo, Walker considera um coeficiente de empuxo (relação entre as pressões) dado pelo efetivo ângulo de atrito interno. Sendo as pressões iniciais dados por:

$$P_v = \gamma \cdot z \quad (14)$$

$$P_h = K \cdot P_v \quad (15)$$

sendo:

$$K = \frac{1 - \text{sen}\phi_e}{1 + \text{sen}\phi_e} \quad (16)$$

Para as pressões estáticas na tremonha, admite-se que a pressão principal maior está na vertical. Dois casos são considerados:

1º caso: Se $\text{sen}\phi_e \geq \frac{\text{sen}\phi_w}{\text{sen}(\phi_w + 2\alpha)}$, as pressões na tremonha são dadas

por:

$$P_{nt,e} = \gamma \cdot z \cdot \frac{\text{tg}\alpha}{\text{tg}\alpha + \text{tg}\phi_w} \quad (17)$$

$$P_{tt,e} = P_{nt,e} \cdot \text{tg}\phi_w = P_{nt,e} \cdot \mu \quad (18)$$

2º caso: Se $\text{sen}\phi_e \leq \frac{\text{sen}\phi_w}{\text{sen}(\phi_w + 2\alpha)}$, as pressões na tremonha são dadas

por:

$$P_{nt,e} = \gamma \cdot z \cdot \frac{1 - \text{sen}\phi_e \cos 2\alpha}{1 + \text{sen}\phi_e} \quad (19)$$

$$P_{tt,e} = \gamma \cdot z \cdot \frac{\text{sen}\phi_e \cos 2\alpha}{1 + \text{sen}\phi_e} \quad (20)$$

2.3.3 Normas internacionais analisadas

A seguir será apresentado um resumo das recomendações propostas pelas mais importantes normas internacionais utilizadas no projeto de silos: AS 3774 (AUSTRALIAN STANDART, 1996), DIN 1005-6 (DEUTSCHE NORM, 2000) e ISO 11697 (INTERNATIONAL STANDART, 1995), para a

determinação das pressões exercidas pelos produtos armazenados sobre as paredes laterais e o fundo, sob condições estáticas e dinâmicas de silos verticais esbeltos.

2.3.3.1 Pressões no corpo do silo

Para pressões estáticas no corpo do silo, todas as normas analisadas adotam a formulação proposta por Janssen (1895) para cálculo das pressões horizontais, pressões verticais e pressões de atrito com a parede, variando apenas o valor do coeficiente de majoração utilizada para a obtenção da pressão vertical na base em silos com fundo plano (Tabela 3).

Tabela 3 Pressões sobre a parede do corpo do silo

Norma	Pressões Estáticas			K
	Ph	Pv	Pw	
ISO 11697				$1,1(1 - \text{sen}\phi_e)$
AS		JANSSEN		$\frac{1 + \text{sen}^2\phi_e - 2\sqrt{\text{sen}^2\phi_e - \mu^2 \cos^2\phi_e}}{4\mu^2 + \cos^2\phi_e} \geq 0,35$
DIN				$1,1(1 - \text{sen}\phi_i)$

Para pressões dinâmicas, as normas, de uma forma geral, adotam coeficientes de majoração, também chamados de coeficientes de sobrepressão, aplicados às pressões estáticas para a determinação das pressões dinâmicas.

Cada norma adota os seguintes equacionamentos para os coeficientes de sobrepressão:

Norma ISO 11697 (ISO, 1995)

As pressões de descarga serão obtidas multiplicando as pressões de carregamento por um coeficiente de sobrepressão C.

Para silos esbeltos ($h/d > 1,5$) C vale 1,35.

Para produtos não tabelados, C pode ser calculado pela seguinte equação:

$$C = 1,35 + 0,02(\phi_e - 30^\circ) \geq 1,35 \quad (21)$$

Norma AS 3774 (AUSTRALIAN STANDART, 1996)

A pressão horizontal de descarga será determinada pela seguinte equação:

$$P_{hd} = C_d \cdot P_h \quad (22)$$

Na qual C_d é o maior valor de

$$C_d = \left[7,6 \left(\frac{h}{d} \right)^{0,06} - 6,4 \right] \cdot C_c \quad (23)$$

$$C_d = 1,2C_c$$

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

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

A pressão de atrito será obtida pela seguinte equação:

$$P_{wd} = C_q P_w \quad (24)$$

na qual

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

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

Norma DIN 1055-6 (DEUTSCHE NORM, 2000)

As pressões de descarga serão obtidas multiplicando as pressões de carregamento por coeficientes de sobrepressão C_w e C_h .

$$P_{wd} = C_w \cdot P_w \quad (25)$$

$$P_{hd} = C_h \cdot P_h \quad (26)$$

Nas quais

$C_w = 1,1$ e $C_h = C_o$

em que:

Para $\phi_e < 30^\circ$, $C_o = 1,35$

Para $\phi_e \geq 30^\circ$,

$$C_o = 1,35 + 0,02 (\phi_e - 30^\circ) \quad (27)$$

2.3.3.2 Pressões na tremonha

As pressões normais à tremonha são calculadas pela soma dos carregamentos devido ao enchimento da tremonha e pelos carregamentos resultantes da sobrecarga vertical diretamente acima da transição.

A Tabela 4 apresenta de forma resumida as prescrições conforme as normas.

Tabela 4 Pressões sobre a prede da tremonha

Norma	Pn (Pressão Normal)	Pt (Pressão Atrito)
ISO	$Pn1 + Pn2 + Pn3$	μPn
AS	$Pn = K_n P_{vn}$	μPn
DIN	$Pn3 + Pn4 + (Pn5 - Pn4) \frac{x}{\ln}$	μPn

sendo:

$$Pn1 = 1,5P_h \left(\frac{1}{k} \cos^2 \Omega + \text{sen}^2 \Omega \right) \quad (28)$$

$$Pn2 = \frac{1,5}{K} P_h \cos^2 \Omega \quad (29)$$

$$Pn3 = 3,0 \frac{A}{U} \frac{\gamma K}{\sqrt{\mu}} \text{sen}^2 \Omega \quad (30)$$

$$Pn4 = 1,2P_v \cos^2 \Omega \quad (31)$$

$$Pn5 = P_v(1,2 \cos^2 \Omega + Ksen^2 \Omega) \quad (32)$$

nos quais:

$$\Omega = 90^\circ - \alpha \quad (33)$$

$$Pn = K_n P_{vn} \quad (34)$$

$$K_n = \frac{1 + sen\phi_e \cos(2\eta)}{1 - sen\phi_e \cos[2(\alpha + \eta)]} \quad (35)$$

$$\eta = 0.5 \left(\phi_w + \sin^{-1} \left(\frac{\phi_w}{\phi_e} \right) \right) \quad (36)$$

2.4 Redes neurais artificiais

Conforme Jackson (2002), rede neural artificial é uma classe de sistemas modelados segundo o cérebro humano. Assim como o cérebro humano é constituído de milhões de neurônios conectados por sinapses, as redes neurais são formadas por um grande número de simuladores de neurônios conectados de uma maneira similar aos neurônios do cérebro humano. A força dessas conexões pode variar em resposta a estímulos, permitindo o aprendizado.

Arbib (2003) apresenta um neurônio básico (Figura 6) extraído da coluna vertebral de um mamífero. A partir do copo celular, formam-se os dendritos, que juntos constituem a maior parte do neurônio e representam a superfície de entradas dos neurônios. Também se forma a partir do corpo celular

uma longa fibra chamada axônio. Os axônios são a linha de saída, e suas extremidades se conectam a outros neurônios. Essas conexões são chamadas de sinapses.

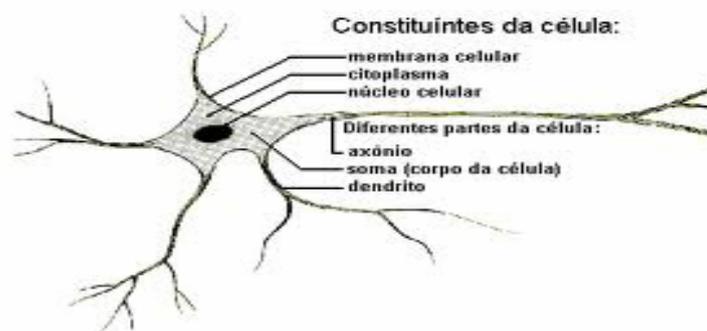


Figura 6 Representação de um neurônio extraído da coluna vertebral de um mamífero

Fonte: Adaptada de Arbib (2003)

As redes neurais são modelos que simulam o comportamento dos neurônios naturais. Nesse sentido, Haykin (2001) define redes neurais como um processador que funciona de forma paralela e distribuída, constituído de unidades de processamento simples, que armazenam o conhecimento experimental e o tornam disponível para o uso.

De acordo com Haykin (2001), uma rede neural se assemelha ao cérebro, pois:

- a) o conhecimento é adquirido através de um processo de aprendizagem;
- b) são utilizadas forças de conexão entre os neurônios, conhecidas como pesos sinápticos, para armazenar o conhecimento adquirido.

Haykin (2001) apresenta um modelo de neurônio artificial (Figura 7). Segundo esse modelo, para cada sinal de entrada X_n (sinapse) em um neurônio

k , existe um peso associado, W_{kn} chamado de peso sináptico. O autor ressalta que, diferentemente do cérebro humano, esse peso pode assumir valores negativos e positivos. A junção aditiva soma os diversos sinais de entrada ponderados pelas respectivas sinapse do neurônio. Esse resultado é submetido à função de ativação, que restringe o sinal de saída, y_k , a um valor finito.

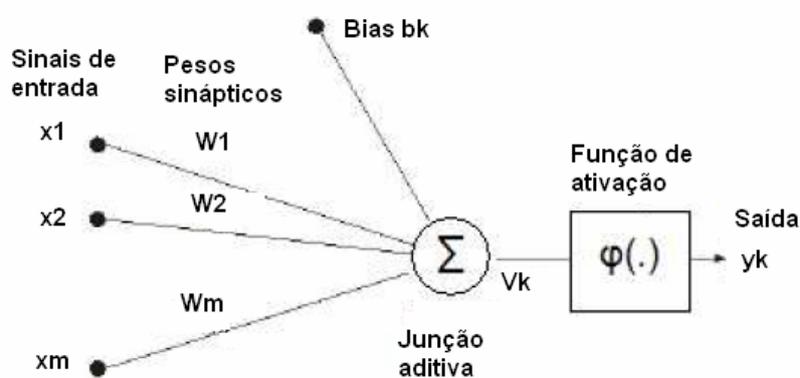


Figura 7 Modelo não linear de um neurônio

Fonte: Haykin (2001)

A *bias*, representado na Figura 7 por b_k , tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação. Considerando uma entrada com valor fixo igual a 1, pode-se considerar a bias semelhante a qualquer outro peso sináptico.

Como exemplo de função de ativação, no Gráfico 5, Haykin (2001) apresenta três tipos de função: (a) função limiar; (b) função linear por partes e (c) função sigmóide para parâmetro de inclinação variável.

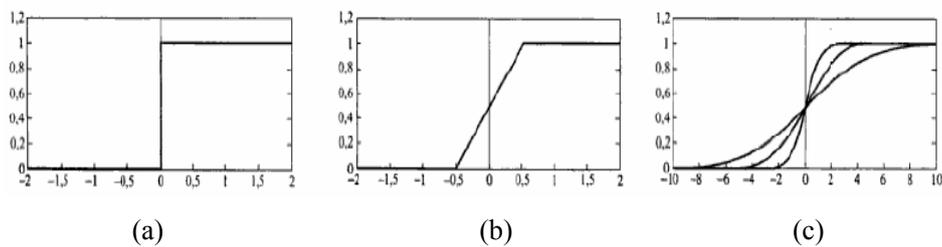


Gráfico 5 Tipos de função de ativação

Fonte: Haykin (2001)

A função sigmóide, representada pelo gráfico c do Gráfico 5, é a mais utilizada na construção de redes neurais artificiais. Um exemplo de função sigmóide é a função logística, definida por:

$$\varphi(v) = \frac{1}{1 + e^{-av}} \quad (37)$$

Em que a é o parâmetro de inclinação da função sigmóide.

Outro exemplo de função de ativação utilizado é a tangente hiperbólica. A principal diferença desta em relação às demais é que essa função pode assumir valores negativos. Ela é definida como:

$$\varphi(v) = \tanh(v) \quad (38)$$

Usualmente as redes neurais possuem três níveis de camadas de neurônios (Figura 8):

- a) uma camada de entrada: onde as propriedades ou padrões são apresentadas a rede;
- b) uma camada de saída: onde o resultado é apresentado;

- c) uma camada intermediária ou oculta: onde é feita a maior parte do processamento, através das conexões ponderadas. Elas situam-se entre a camada de entrada e a camada de saída.

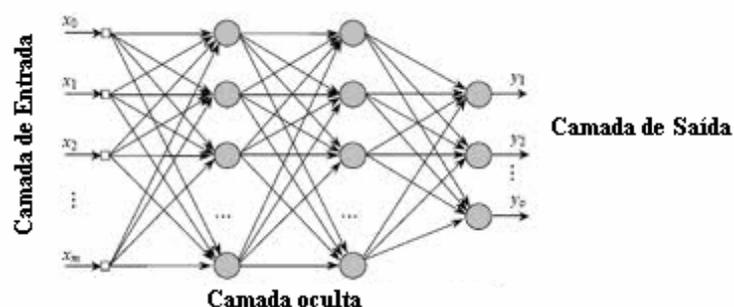


Figura 8 Estrutura de uma rede neural

Fonte: Alves (2001)

Segundo Haykin (2001), aprendizagem é um processo pelo qual os parâmetros de uma rede neural são adaptados através de um processo de estimulação do ambiente no qual a rede está inserida. Os neurônios artificiais se conectam entre si, formando diferentes tipos de arquitetura de redes.

Uma vez definida a arquitetura da rede, ela precisa ser treinada para que possa começar a ser utilizada. Segundo Haykin (2001), os perceptrons de múltiplas camadas (MLP) são redes neurais alimentadas diretamente com múltiplas camadas. Esse tipo de redes neurais tem sido aplicado com sucesso para resolver diversos problemas, dentre eles, o de aproximar funções não lineares, utilizando o algoritmo de treinamento supervisionado chamado de algoritmo de retropropagação de erro ou *error backpropagation*.

O algoritmo de retropropagação de erro utiliza a aprendizagem supervisionada e, segundo Haykin (2001), a aprendizagem ocorre em duas etapas. Primeiramente acontece a propagação em que um vetor de entrada é aplicado na entrada da rede neural. Os pesos sinápticos não se alteram e o sinal

se propaga através da rede, camada por camada, até chegar à saída da rede neural. O valor final encontrado representa a resposta real da rede.

A segunda etapa, chamada de retropropagação, inicia-se com subtração entre a resposta da rede e a resposta desejada. Este resultado é chamado de sinal de erro. Esse valor é propagado para trás através da rede, com direção das conexões sinápticas, ajustando os pesos sinápticos de modo que a resposta real da rede se aproxime da resposta desejada.

Cybenko (1989) demonstrou que qualquer função contínua pode ser uniformemente aproximada por uma rede neural contínua de apenas uma camada interna e com uma sigmoideal contínua não linear arbitrária. Ou seja, funções contínuas de qualquer grau e com relação às variáveis, sendo lineares, logísticas ou qualquer outra, podem ser aproximadas a uma rede neural. Além disso, com duas ou mais camadas internas, as Redes Neurais podem aproximar uma função não linear sendo, ela contínua ou não.

2.4.1 Aprendizagem

A propriedade mais importante das redes neurais é a habilidade de aprender de seu ambiente e com isso melhorar seu desempenho. Isso é feito através de um processo iterativo de ajustes aplicado a seus pesos, o treinamento. O aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas.

O processo de aprendizagem nas redes neurais acontece internamente por meio do ajuste dos pesos sinápticos das conexões, durante a exposição dos exemplos, em resposta à quantidade de erros gerados pela rede. Ou seja, a rede neural é capaz de modificar-se em função da necessidade de aprender a informação que lhe foi apresentada (TAFNER; XEREZ; RODRIGUES FILHO, 1995).

As redes neurais são treinadas para aprender a partir dos dados de entrada. Assim como o cérebro humano, elas aprendem a partir de experiências e não através de programação. Por esse motivo, deve-se tomar bastante cuidado com a formação do conjunto de treinamento. Esse conjunto deve ser gerado a partir de dados históricos, ou seja, a partir de experiências e fatos ocorridos no passado.

Como já mencionado anteriormente, a rede deve ser capaz de generalizar. Mas, ao mesmo tempo, deve-se tomar cuidado para que não aconteça um “supertreinamento” e memorização dos dados. Se uma rede neural é submetida a um supertreinamento, ela perde a capacidade de solução do problema fora do conjunto de treinamento. Para evitar essa situação, deve-se ter um conjunto de teste com dados diferentes do conjunto de treinamento, e a rede deve ser capaz de solucioná-la corretamente, provando assim sua flexibilidade e capacidade de generalização.

Os três principais paradigmas de aprendizagem são apresentados a seguir:

- a) aprendizagem supervisionada (ou aprendizagem com professor), quando é utilizado um agente externo que indica à rede a resposta desejada para o padrão de entrada. O ajuste dos pesos ocorre quando o sistema compara a saída da rede com a resposta desejada previamente conhecida.
- b) aprendizagem não supervisionada (ou aprendizagem sem professor), quando não existe um agente externo indicando a resposta desejada para os padrões de entrada. A rede neural utiliza os neurônios como classificadores, e os dados de entrada como elementos de classificação. Esse tipo de rede trabalha essas entradas e se organiza de modo a classificá-las mediante algum critério de semelhança.

- c) aprendizagem híbrida, que mescla os conceitos apresentados acima. Parte dos pesos é determinada através da aprendizagem supervisionada, enquanto outros são obtidos através da aprendizagem não supervisionada.

Em um processo de aprendizagem, os pesos dos neurônios são ajustados através de um algoritmo de aprendizagem. O algoritmo de aprendizagem é um conjunto preestabelecido de regras bem-definidas para resolução de um problema de aprendizagem (HAYKIN, 2001). Ele tem como objetivo encontrar pesos para a rede que permitam que esta gere saídas compatíveis com as desejadas. Os algoritmos existentes diferem entre si pela forma como ocorre o ajuste dos pesos sinápticos dos neurônios, ou seja, pela regra de aprendizagem adotada.

De acordo com Haykin (2001), existem cinco regras básicas de aprendizagem através das quais os pesos sinápticos de uma rede podem ser ajustados: aprendizagem por correção de erro, baseada em memória, hebbiana, competitiva e aprendizagem de Boltzmann.

2.4.1.1 Aprendizagem por correção de erro

A aprendizagem por correção de erro é baseada no paradigma de aprendizagem supervisionada, no qual a saída desejada para as entradas é fornecida para a rede. O sinal de saída gerado pela rede, representado por $y_k(n)$, é comparado com a resposta desejada, representada por $d_k(n)$, produzindo um sinal de erro $e_k(n)$. Este erro é dado por:

$$e_k(n) = d_k(n) - y_k(n) \quad (39)$$

O sinal de erro é então utilizado para ajustar os pesos das conexões com o objetivo de aproximar o sinal de saída $y_k(n)$ da resposta desejada $d_k(n)$, reduzindo o erro $e_k(n)$.

2.4.1.2 Rede neural *Backpropagation*

A rede neural comumente denominada *backpropagation* é na verdade uma rede neural *feedforward* (Gráfico 5), multicamada, treinada pelo algoritmo *backpropagation*. Segundo Lawrence (2010), essa rede é a mais utilizada no desenvolvimento de redes neurais. O desenvolvimento desse algoritmo de aprendizagem foi um dos marcos mais importantes das pesquisas em redes neurais artificiais (DANDOLINI, 1997). Esse trabalho foi o primeiro que possibilitou o ajuste dos pesos em redes multicamadas *feedforward*, abrindo caminho para a elaboração de redes neurais mais genéricas. Devido a grande popularidade do método *backpropagation*, seu nome é utilizado para denominar as redes que o utilizam no seu treinamento.

A atratividade do método *backpropagation* vem do conjunto de equações bem definidas e explícitas para correção dos pesos da rede (DANDOLINI, 1997). Esse algoritmo consiste em realizar a retropropagação do erro gerado na comparação entre a saída da rede e a saída desejada com o objetivo de minimizar o erro total da saída gerada pela rede. O treinamento de uma rede através desse algoritmo envolve três etapas: a propagação dos dados da camada de entrada para a camada de saída da rede, o cálculo e a retropropagação do erro gerado pela rede, e o ajuste dos pesos (FAUSETT, 1994).

Na primeira etapa, estímulos de entrada são apresentados à rede e as ativações fluem até chegarem à camada de saída, gerando um resultado. Já na segunda e terceira etapas, o resultado obtido pela rede é comparado com a saída desejada e o erro gerado é computado para as unidades de saída. Os pesos

conectados às unidades de saída são então ajustados para reduzir esse erro. Em seguida, o erro da camada de saída é utilizado para derivar estimativas de erro para as unidades da(s) camada(s) oculta(s), para que o erro seja então propagado para trás até a conexão da camada e entrada. O fluxo de informação desse processo é ilustrado de uma forma resumida na Figura 9.

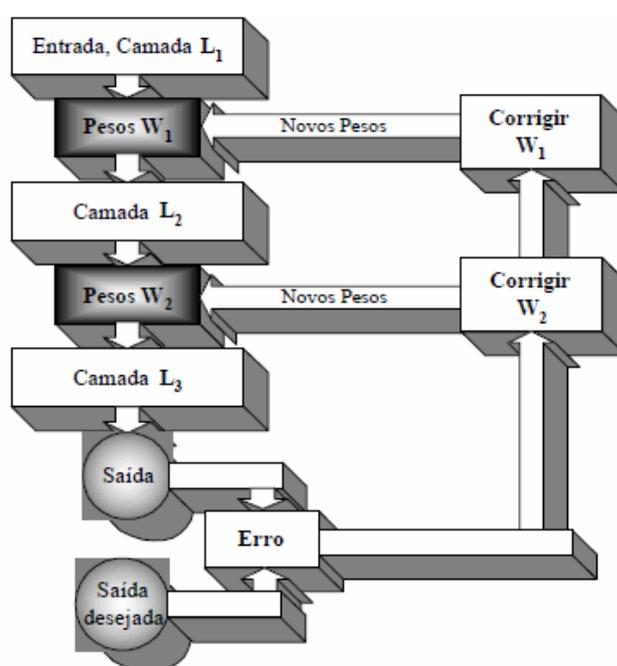


Figura 9 Correção dos pesos por *backpropagation*

Fonte: Lawrence (2010)

O método *backpropagation* atualiza os pesos incrementalmente, depois de analisar cada par entrada-saída. Depois da apresentação de todos os pares entrada-saída diz-se que uma época foi concluída (RICH; KNIGHT, 1994). Esse treinamento, em geral, requer muitas épocas.

2.4.1.3 Ajustes dos pesos

Uma regra de aprendizagem por correção de erro, a regra delta, é onde está baseado o ajuste dos pesos realizado pelo algoritmo *backpropagation*. Esse ajuste é feito baseado na retropropagação do erro através da qual o erro gerado pelos neurônios na camada de saída é distribuído para os demais neurônios da rede.

Mesmo conhecendo o erro global da rede, não é possível determinar os pesos exatos para poder corrigi-lo. Entretanto, com base nessa informação, pode-se estabelecer a direção na qual os pesos devem ser ajustados para minimizar o erro quadrado total da saída da rede. Conhecida essa direção, é possível ajustar os pesos até que o menor erro global seja atingido. O ajuste de um peso w_{ij} que define seu valor para a próxima iteração é definido por:

$$w_{ij}(t+1) = w_{ij}(t) + \Delta w_{ij}(t) \quad (40)$$

A variação Δw_{ij} que é aplicada ao peso w_{ij} deve ser proporcional ao sinal de entrada x_j , que é definido pelos sinais de saída da camada anterior ponderados pelos pesos, e ao erro gerado na saída. Ela é dada por:

$$\Delta w_{ij}(n) = \eta \delta_j(n) x_j(n) \quad (41)$$

em que η é a taxa de aprendizagem e δ_j é o gradiente local do erro para o neurônio j .

A taxa de aprendizagem é um valor positivo, geralmente menor do que 1, que regula a intensidade com que as atualizações dos parâmetros (pesos) serão efetuadas. Taxas muito baixas, próximas de zero, tendem a fazer com que o aprendizado seja bastante lento, porém taxas muito altas, próximas de 1, podem fazer com que a rede oscile, como se estivesse aprendendo e desaprendendo, e às vezes nem consiga chegar a um patamar aceitável de aprendizado. O valor da taxa de aprendizado não precisa permanecer fixo durante todo o treinamento. Em algumas implementações, ela pode ser adaptativa e controlada pela própria rede.

O gradiente local do erro é determinado através do método gradiente descendente. Ele é o termo responsável pela distribuição do erro da camada de saída para as camadas anteriores. O ajuste dos pesos (Δw) deve ser realizado na direção contrária ao gradiente, conforme o Gráfico 6. Se o peso $w(n)$ (valor do peso na iteração n) está à esquerda do erro mínimo, o ajuste Δw deve ser positivo para que $w(n+1)$ (valor do peso da próxima iteração) esteja mais próximo do valor de w , que minimiza o erro. Por outro lado, se o peso $w(n)$ está à direita do erro mínimo, o ajuste Δw deve ser negativo.

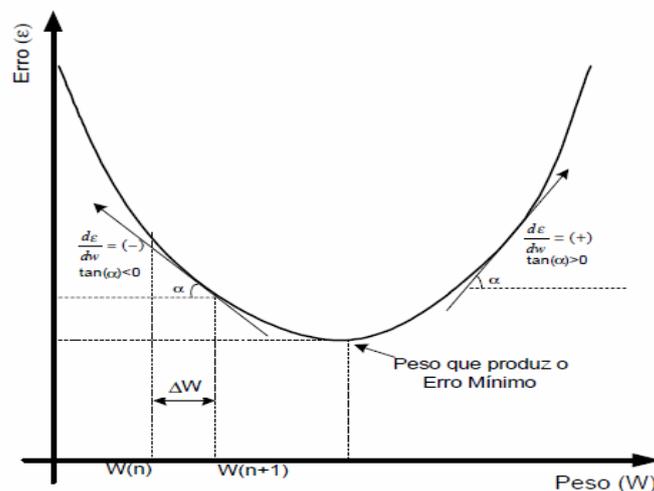


Gráfico 6 Função erro para um único peso

Fonte: Lawrence (2010)

O ajuste dos pesos para os neurônios da camada de saída em um algoritmo backpropagation é diferenciado do ajuste dos pesos para os neurônios da camada oculta. A seguir será demonstrado o processo de ajuste dos pesos para cada caso separadamente.

2.4.1.4 Ajustes dos pesos da camada de saída

Devido ao fato da aprendizagem ser do tipo supervisionada, o resultado desejado para a camada de saída l é fornecido para a rede. Com isso, pode-se fazer uma comparação deste com o resultado obtido pela rede nessa camada, gerando um sinal de erro, que é utilizado para realizar o ajuste dos pesos dos neurônios desta camada:

$$\varepsilon_{l,j}(n) = d_{l,j}(n) - y_{l,j}(n) \quad (42)$$

Tendo o valor do erro, seu gradiente local é definido como:

$$\delta_{l,j}(n) = \varepsilon_{l,j}(n) \frac{\partial y_{l,j}(n)}{\partial x_{l,j}(n)} \quad (43)$$

A expressão para o ajuste dos pesos entre a camada de saída l e a camada $l-1$ é então determinada como:

$$\Delta w_{l-1,i,j}(n) = \eta \delta_{l,j}(n) y_{l-1,i}(n) \quad (44)$$

2.4.2 Projeto de uma rede neural

Diante de um projeto de uma rede neural, não se pensa mais em procedimentos, regras ou fórmulas algorítmicas de processamento de dados, mas sim em tipos de dados de entrada, dados de saída e tratamento de dados (TAFNER et al., 1995). “O projeto de uma rede neural é baseado diretamente nos dados do mundo real, permitindo-se que o conjunto de dados fale por si mesmo” (HAYKIN, 2001, p. 386).

O projeto de um sistema neural consiste de diversas etapas que devem ser executadas em sequência, de forma interativa e até mesmo com diversos ciclos de repetição. A construção do sistema começa pela identificação e coleta dos dados históricos relevantes para o problema. O passo seguinte é a preparação e adequação dos dados ao formato requerido pela rede neural, ou seja, a formatação dos dados. Nesse processo, cria-se uma escala, estabelecendo um novo intervalo válido dentro do qual todos os dados são colocados. Os intervalos mais utilizados são $[-1,1]$ ou $[0,1]$. Esse processo também é conhecido como normalização dos dados.

Após a escolha de uma representação para os dados do problema, deve-se separar os dados em dois conjuntos: o conjunto de treinamento o qual é gerado a partir de dados históricos, ou seja, a partir de experiências e fatos ocorridos no passado; e o conjunto de teste com o qual o funcionamento da rede é testado. Cada dado do conjunto de teste é apresentado uma única vez ao sistema.

O próximo passo é realizar a escolha do modelo neural a ser adotado e definir a topologia da rede. Em seguida, realiza-se o desenvolvimento, treinamento e otimização do modelo, seguidos pela validação do mesmo. Na etapa de validação, faz-se uma comparação do resultado obtido pela rede com o resultado desejado.

Por fim, após a validação do modelo, realiza-se a aplicação do mesmo.

2.4.3 Aplicações

Mesmo com algumas restrições, a área de redes neurais tem demonstrado sua potencialidade em diversas aplicações, superando expectativas e gerando resultados até então não alcançados com qualquer outra técnica, seja computacional ou convencional.

As redes neurais artificiais podem ser treinadas para encontrar soluções, interpretar e classificar dados, reconhecer padrões, aproximar funções e prever eventos futuros. Atualmente, são inúmeras as áreas nas quais as redes neurais têm sido aplicadas, e os bons desempenhos alcançados têm incentivado pesquisadores a fazer das redes neurais uma alternativa de solução para problemas nas mais diversas áreas de atuação. Os principais domínios de aplicação das redes neurais são: processamento de imagens, setor militar, robótica, biologia e medicina, telecomunicações e o setor financeiro.

3 MATERIAIS E MÉTODOS

A seguir, serão citados e descritos os passos adotados neste trabalho. Como citado anteriormente, o objetivo é modelar as ações atuantes nos silos, desenvolvendo um sistema computacional usando redes neurais artificiais.

3.1 Levantamento dos dados

A primeira etapa para o desenvolvimento do projeto foi fazer o levantamento do maior número possível de produtos armazenados em silos com suas respectivas propriedades físicas, obtidas em estudos experimentais. Para esse levantamento dos produtos, considerou-se a classificação dos produtos de acordo com sua granelização e aspectos físicos, tais como: teor de umidade, peso específico, ângulo de atrito interno e ângulo de atrito externo. Assim, esse levantamento aborda todas as características acerca dos produtos, tanto para produtos agrícolas (Tabela 5), como para produtos sólidos (Tabela 6), propiciando uma rede neural mais genérica.

Tabela 5 Propriedades físicas de diversos produtos agrícolas

Produtos Agrícolas	Aço Liso					
	$\gamma_i(\text{kN/m}^3)$	$\gamma_s(\text{kN/m}^3)$	$\phi_{ii}(\text{°})$	$\phi_{is}(\text{°})$	$\phi_{wi}(\text{°})$	$\phi_{ws}(\text{°})$
Amendoim	-	6,16	36,96	45,21	13,27	14,95
Amido de Milho	6,3	7,4	34	42,3	13,2	17,7
Arroz com casca	5,8	6,2	43,5	52,7	8,8	10
Café	6,75	6,88	27	37	14	16
Fécula de Mandioca	6,8	7,5	29,7	36,9	11,7	13,4
Feijão	7,5	8	-	31	15,3	15,73
Farinha de Milho	7,1	7,6	41,7	48,4	8,7	11,5
Farinha de Trigo	7,5	7,9	36,8	42,4	10,4	13,2
Milho	7,53	8	32	35	9,88	10,66
Soja	5,1	5,7	28	38,3	8,31	13,35

Tabela 6 Propriedades físicas dos produtos sólidos

Produtos	Aço Liso					
	$\gamma_i(\text{kN/m}^3)$	$\gamma_s(\text{kN/m}^3)$	$\phi_{ii}(\text{°})$	$\phi_{is}(\text{°})$	$\phi_{wi}(\text{°})$	$\phi_{ws}(\text{°})$
Alumina	-	10	-	40	-	33
Areia	-	16	-	40	-	22
Calcário	-	10	-	27	-	33
Carvão	-	10	-	60	-	24
Cimento	-	16	-	50	-	24
Cinzas	-	14	-	45	-	24
Ferro	-	16	-	40	-	19
Fosfato	-	13	-	55	-	27

De acordo com as Tabelas 5 e 6, estabeleceram-se faixas entre os valores limites das propriedades físicas dos produtos armazenados em silos. A Tabela 7 apresenta esses limites para cada propriedade física.

Tabela 7 Faixas entre os valores limites dos produtos

	γ (kN/m ³)	ϕ_i (°)	ϕ_w (°)
Produtos Agrícolas	5,1 ----- 8,0	27,0 ----- 52,7	8,70 ----- 22,0
Produtos Sólidos	10 ----- 16	40,0 ----- 60,0	19,0 ----- 33,0

A próxima etapa foi a formulação da base de dados de entrada para o treinamento da rede neural, composto pelas propriedades físicas, que são valores de entradas para o cálculo das ações atuantes. Para isso, elaborou-se uma base de dados de entrada com diversas combinações entre os valores pertencentes aos limites inferiores e superiores de cada propriedade física (Tabela 7), de acordo com sua distribuição normal.

Após a obtenção do conjunto de entradas para o treinamento da rede neural, foi necessário calcular os resultados desejados para cada conjunto de entrada. Os resultados foram determinados a partir das teorias existentes para as ações atuantes nos silos, adotadas pelas principais normas internacionais. Assim, foi possível estabelecer uma média entre os valores obtidos pelas teorias e normas existentes, definindo uma saída desejada que melhor atenda aquele conjunto de entradas, de acordo com conhecimentos advindos de memoriais de cálculos e experiências.

3.2 Ferramentas de desenvolvimento

O trabalho foi desenvolvido através de uma linguagem de programação conhecida como *Scilab*, que é uma linguagem de alto nível orientada à análise numérica. O *Scilab* é um software científico para computação numérica que fornece um poderoso ambiente computacional para aplicações científicas. A linguagem provê um ambiente para interpretação, com diversas ferramentas numéricas. O uso dessa ferramenta facilita a codificação de algoritmos

complexos em comparação com outras linguagens. Outra grande vantagem do *Scilab* está na possibilidade de adicionar programas de outras linguagens, além de fornecer várias bibliotecas com funcionalidades específicas.

Para o desenvolvimento da rede neural, o *Scilab* fornece um biblioteca chamada ANN (*Artificial Neural Network Toolbox*), que contém algumas funções prontas para a criação da rede neural, principalmente na sua estrutura em camadas e treinamento da rede neural.

3.3 Sistema computacional

O sistema computacional desenvolvido é constituído de duas partes principais: módulo de aprendizagem e módulo de cálculo.

O módulo de aprendizagem é utilizado para o treinamento da rede neural, cuja base de dados é apresentado exaustivamente ao programa para que os pesos das conexões entre os nós sejam ajustados, até que a rede apresente uma taxa de erro aceitável.

O módulo de cálculo é o programa efetivamente apresentado ao usuário final, com os pesos das conexões já fixadas, em que o usuário entra com os dados de um determinado produto e o programa faz os cálculos das ações atuantes na estrutura do silo.

3.3.1 Construção e configuração da rede neural

O sistema computacional desenvolvido neste trabalho baseou-se na técnica de redes neurais artificiais do tipo *perceptron* multicamadas (*MLP – Multi-Layer Perceptron*), que consiste em uma série de elementos de processamento denominados neurônios artificiais, ou nós, interligados entre si, com um determinado peso associado a cada conexão.

Para o treinamento da rede, utilizou-se o paradigma da aprendizagem supervisionada, através do algoritmo de *backpropagation*, que é baseado em uma análise dos erros de resposta do sistema para os ajustes necessários na rede.

Vários testes para diferentes configurações das redes foram realizados. Mantendo-se sempre o mesmo número de elementos nas camadas de entrada e de saída, realizou-se apenas, uma série de variações quanto ao número de elementos nas camadas ocultas.

Dentre todas as configurações testadas, a que apresentou o melhor resultado e, portanto, a escolhida foi:

- a) camada de entrada: propriedades físicas do produto e geométricas do silo;
- b) camada intermediária: 2 camadas ocultas, sendo a primeira com 50 nós e a segunda com 21 nós;
- c) camada de saída: pressões nas paredes e fundo do silo, pressões na tremonha e flexibilidade do produto.

3.3.2 Treinamento do sistema e testes de desempenho

O treinamento do sistema se deu através do algoritmo de *backpropagation*. Para os testes de desempenho, foram realizadas duas formas de treinamento distintas.

A primeira consistiu em treinar as redes neurais com todos os registros da matriz de entradas e efetuar testes com 10% dos registros escolhidos aleatoriamente dessa mesma base, ou seja, os testes eram realizados com amostras já conhecidas pela rede desde o treinamento.

Na segunda forma, antes de se realizar o treinamento, foram separados registros que não participaram do treinamento da rede neural. Assim, os testes eram realizados com amostras totalmente desconhecidas da rede de treinamento.

3.4 Desenvolvimento da rede neural artificial

Para o desenvolvimento da rede neural, foram implementados algoritmos para cada fase do projeto. A primeira fase, que foi a pesquisa e elaboração da base de dados de entradas para o treinamento da rede neural, desenvolveu-se um algoritmo, para a formulação da matriz de entradas (Anexo E), de acordo com as faixas de valores limites das propriedades físicas dos produtos levantados. Esse algoritmo gera diversas combinações entre os valores pertencentes aos limites, de acordo com sua distribuição normal, e forma uma matriz ($n \times m$), na qual, n representa o número de amostras e m representa o número de propriedades físicas.

Com a matriz de entradas elaborada, partiu-se para o cálculo das respostas desejadas para o treinamento da rede neural (Anexo A). Essas saídas desejadas foram determinadas a partir dos valores médios obtidos pelas teorias existentes, adequando sempre para a melhor solução para o problema. Após a determinação das respostas desejadas, os dados foram armazenados num conjunto de saídas (Anexo F) dispostos numa matriz ($n \times m$), na qual, n representa o número de amostras e m o número de saídas.

Com a matriz de entradas composta e suas saídas desejadas calculadas, o próximo passo foi o treinamento da rede neural, que se deu através do algoritmo do *Backpropagation* (Anexo G).

O fluxograma que descreve as etapas do código para o cálculo do modelo neural é descrito na Figura 10.

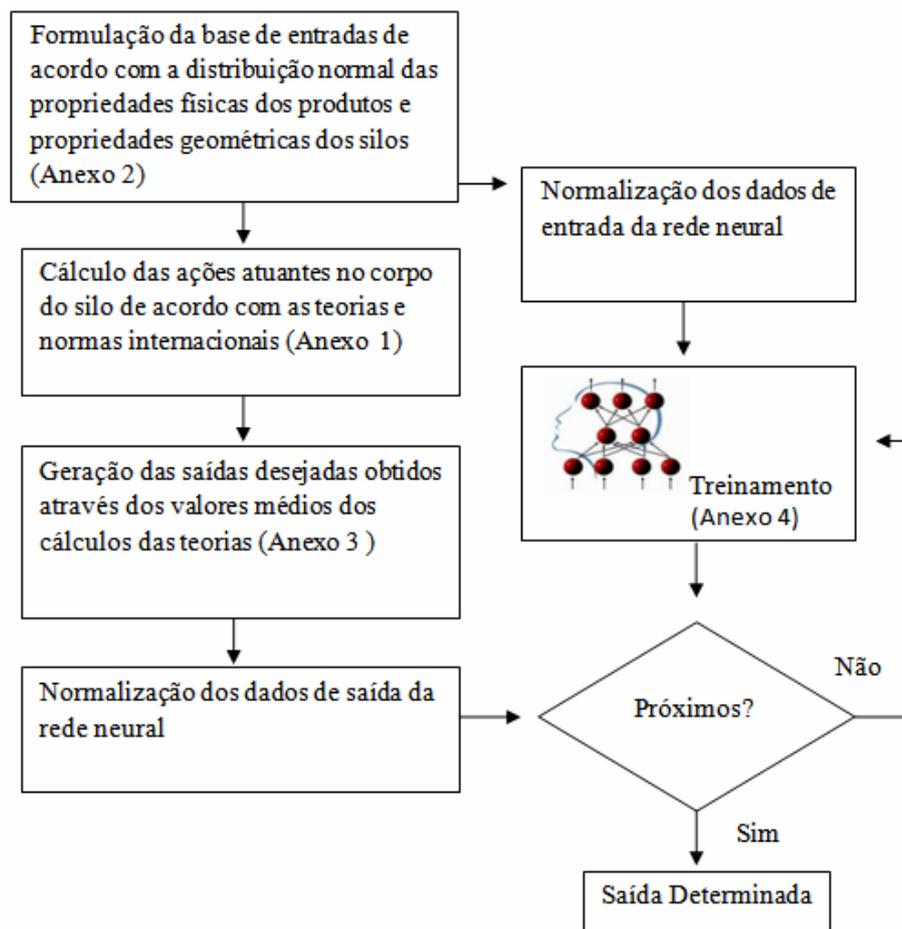


Figura 10 Fluxograma do cálculo neural

4 RESULTADOS E DISCUSSÕES

São apresentados a seguir os resultados obtidos nas diversas fases da pesquisa, discutindo alguns de seus aspectos mais relevantes.

4.1 Dados obtidos

Um dos maiores problemas encontrados durante a realização da pesquisa foi com relação à coleta de dados e à determinação das propriedades físicas para efetuação do treinamento do sistema.

O primeiro grande problema relacionado à coleta de dados foi na forma como adquirir a melhor base de dados possível que atenda a todos os casos possíveis de produtos que possam ser armazenados em silos. Além disso, havia a necessidade de determinar suas respectivas propriedades físicas e calcular suas saídas desejadas de acordo com as teorias existentes para o cálculo das ações atuantes nos silos.

4.2 Configuração da rede neural

Com relação ao número de camadas ocultas e de elementos nessas camadas, não foi encontrada na literatura nenhuma regra básica que defina os melhores valores. Em todos os trabalhos pesquisados, essas quantidades são bem variadas, não apresentando muita relação entre si.

Na maioria das publicações verificadas, obteve-se, como sugestão, iniciar os trabalhos com uma configuração de uma ou duas camadas ocultas com um pequeno número de elementos e ir aumentando essa quantidade para se verificar diferenças.

Neste trabalho, partiu-se de uma configuração inicial com 15 elementos na primeira camada oculta e 8 elementos na segunda camada oculta. Na camada de entrada, têm-se as propriedades físicas dos produtos armazenados para o cálculo das ações atuantes, e na camada de saída os seus respectivos resultados. Conforme os testes foram realizados, aumentava-se gradativamente o número de elementos na camada oculta.

Trabalhando-se com configurações inferiores, o tempo de treinamento aumentava, tornando os índices de acertos insatisfatórios. Já com uma configuração maior no número de elementos nas camadas ocultas, o tempo de treinamento diminuía, possibilitando resultados mais precisos em relação aos desejados.

O número de camada ocultas também é alvo de intensas pesquisas para se tentar alcançar os valores mais adequados. Optou-se, neste trabalho, pela configuração de duas camadas ocultas para garantir a convergência aos resultados.

Estabeleceu-se, portanto, como configuração ideal para a rede neural, 50 elementos na primeira camada oculta e 21 elementos na segunda camada oculta, sendo na camada de entrada as propriedades físicas dos produtos e na camada de saída as respostas das ações atuantes.

4.3 Treinamento da rede neural

Como visto anteriormente, o processo de elaboração do conjunto de treinamento da rede neural baseou-se na distribuição normal da variabilidade das propriedades físicas dos produtos armazenáveis em silos, conforme visto na Tabela 7. Essa base de dados com as propriedades físicas dos produtos, juntamente com seus resultados desejados, foram apresentadas à rede neural na forma de iterações para o processo de aprendizagem da rede. Assim, os gráficos

do erro médio foram calculados para cada época do treinamento. No Gráfico 7, é mostrado o gráfico do erro médio obtido após 10000 épocas de treinamento. Observe que o erro médio tende sempre a um valor mínimo, estabilizando-se depois de certo número de épocas.

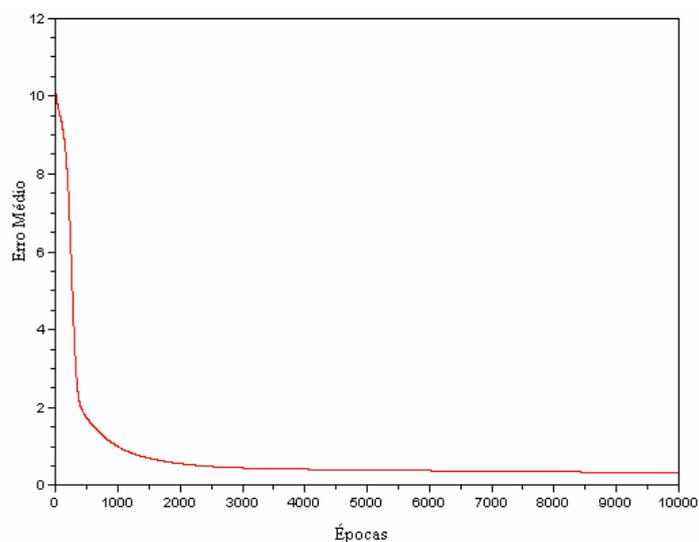


Gráfico 7 Gráfico do erro médio a cada época (10000)

Com o intuito de verificar se o aumento do número de épocas de treinamento diminuiria ainda mais esse erro médio, realizaram-se também, treinamentos com mais épocas. O Gráfico 8 mostra que a diminuição pode existir, porém com uma taxa muito pequena, o que não justificaria o aumento no número de épocas e de processamento. Nesse treinamento, a rede neural foi treinada com 20000 épocas com as mesmas configurações.

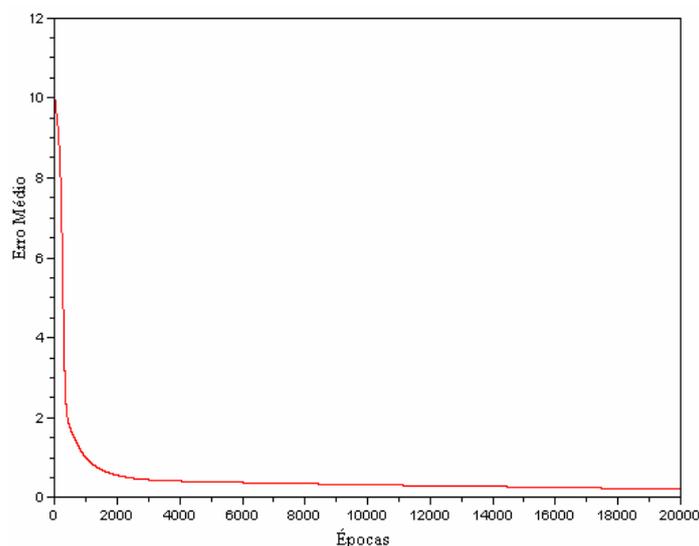


Gráfico 8 Gráfico do erro médio a cada época (20.000)

4.4 Resultados alcançados

Para o comparativo entre os resultados, utilizaram-se dados usados tanto no treinamento da rede neural, como dados que não pertenceram ao conjunto treinamento. Assim, foi possível mensurar a eficiência da rede neural para os dados desconhecidos, ou seja, dados que não fizeram parte do conjunto treinamento da rede neural. Nessa fase, usaram-se 10% dos dados treinados para comparar os resultados.

No Gráfico 9, são ilustrados os gráficos comparativos entre os resultados obtidos pela rede neural e os valores médios obtidos pelas teorias existentes para o cálculo das pressões no corpo do silo, tanto para produtos agrícolas, como para produtos sólidos.

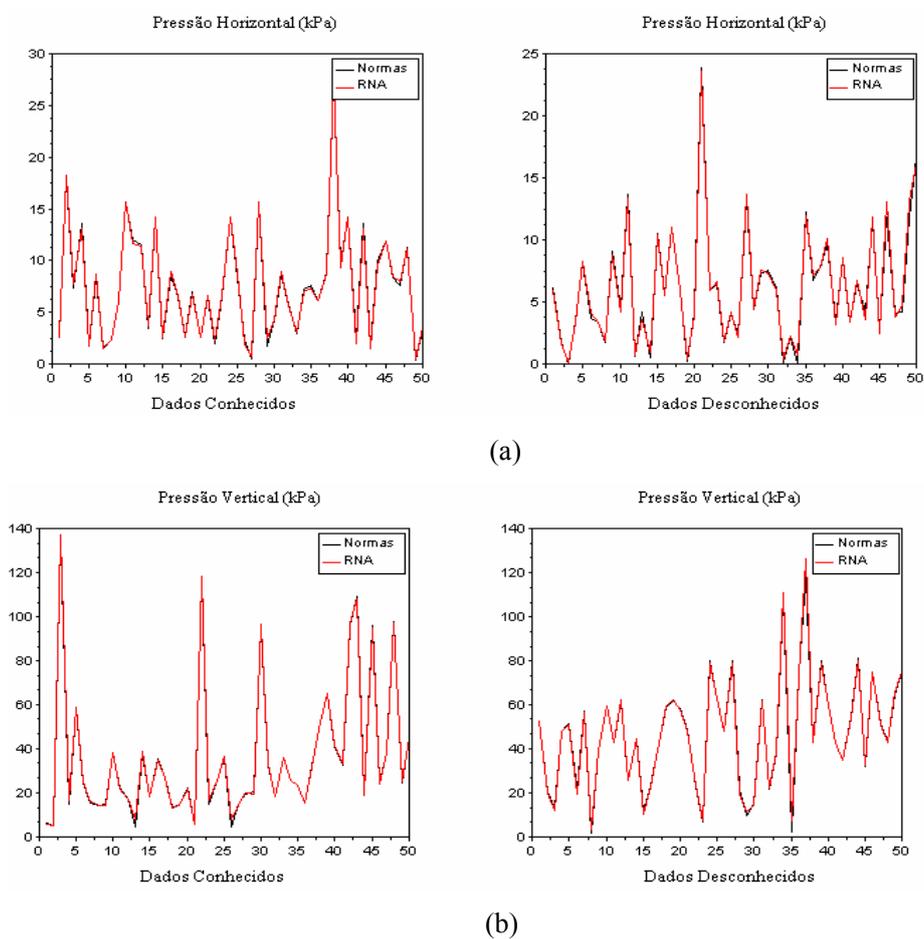
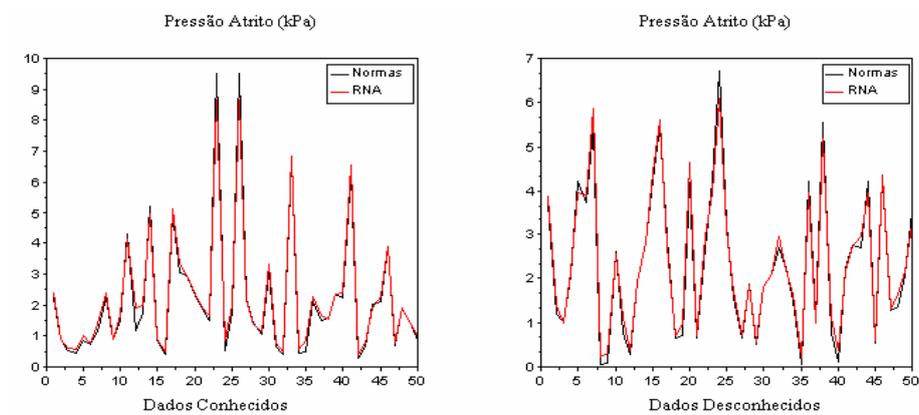


Gráfico 9 Gráficos comparativos entre as ações atuantes no corpo do silo para armazenamento de produtos: (a) Pressão Horizontal (b) Pressão Vertical (c) Pressão de Atrito

(...continua...)



(c)

O mesmo procedimento para o cálculo das ações no corpo do silo foi adotado para o cálculo das pressões na tremonha. O Gráfico 10 mostra o comparativo entre os resultados obtidos pela rede neural e os valores médios obtidos pelas teorias existentes para cálculo das ações na tremonha, tanto para produtos agrícolas, como para produtos sólidos.

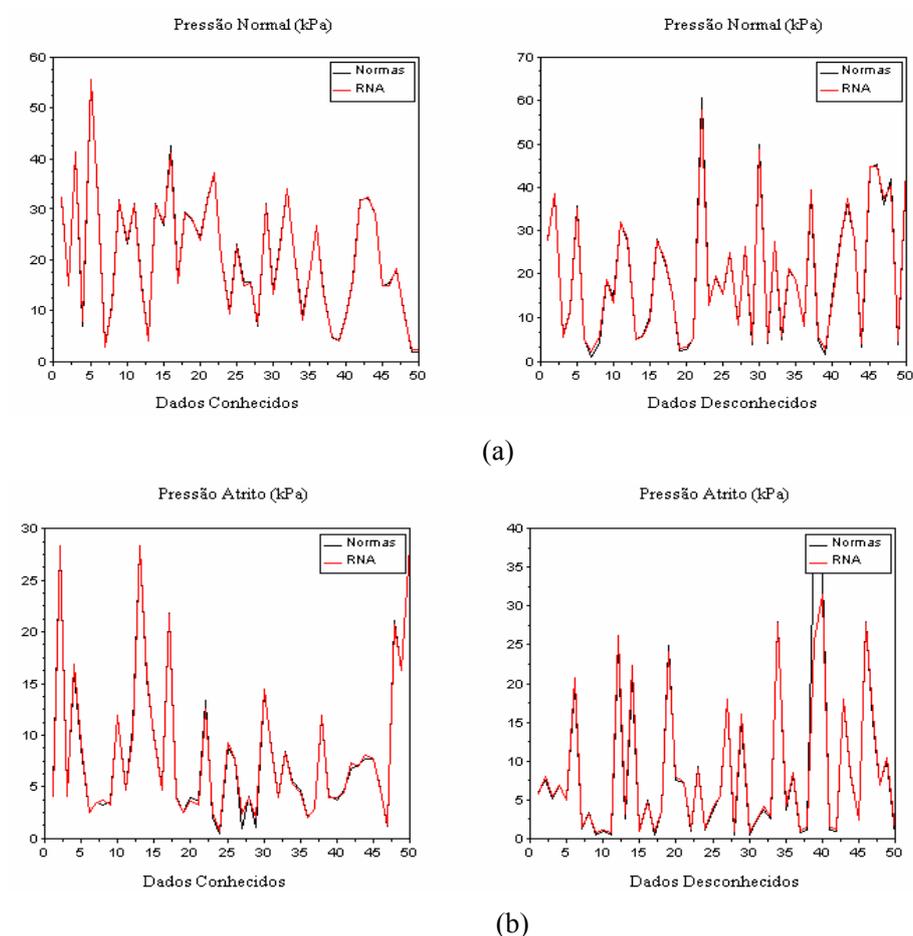


Gráfico 10 Gráficos comparativos entre as ações atuantes na tremonha para armazenamento de produtos: (a) Pressão Normal (b) Pressão de Atrito

Determinou-se também o fator fluxo, que é uma propriedade para se determinar o escoamento do produto. O Gráfico 11 mostra o comparativo dos resultados obtidos entre a rede neural e a teoria de existente para cálculo do escoamento do produto (teoria de Enstad).

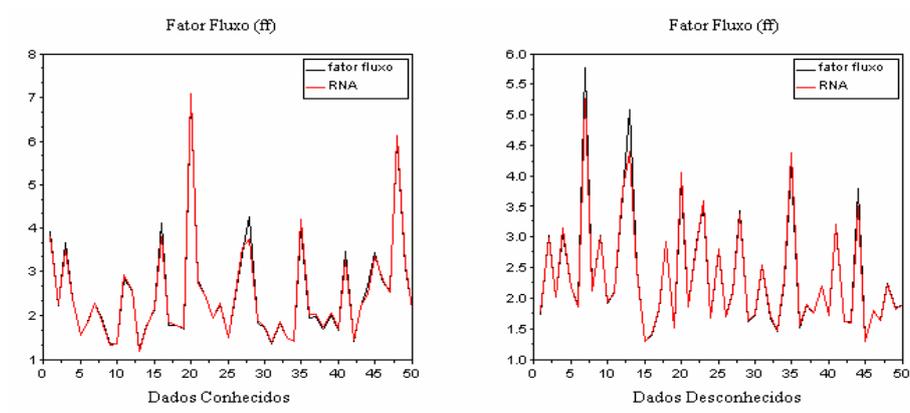


Gráfico 11 Gráfico comparativo para a escoabilidade do produto

5 CONCLUSÕES

Nas condições em que foi treinada a rede neural, pode-se concluir que:

- a) os resultados obtidos pela rede neural estão suficientemente dentro dos limites de confiabilidade para o cálculo das ações atuantes nos silos;
- b) a base de dados atendeu com eficácia à variabilidade de possibilidades de produtos armazenáveis em silos sob as mais diversas condições, possibilitando uma rede neural genérica a qualquer situação;
- c) a rede neural construída fornece resultados mais adequados ao problema, propiciando um dimensionamento mais seguro e econômico para os projetos de silos;
- d) o sistema construído possibilita absorver outras variáveis que influenciam no comportamento das ações atuantes, caracterizada pelo dinamismo das redes neurais em aprender novas situações que as teorias existentes não contemplam.
- e) as redes neurais artificiais cumprem bem o seu papel de aproximador de funções não lineares;
- f) pode-se afirmar que um sistema como o construído pode representar uma nova modelagem para o auxílio dos cálculos em ações atuantes no silo.

Com perspectivas para continuidade dos trabalhos, pretende-se desenvolver um sistema mais completo, incorporando às redes neurais outras variáveis que influenciam no comportamento das ações atuantes nos silos.

REFERÊNCIAS

- ALVES, C. A. M. **Uma ferramenta de extração de regras de redes neurais**. 2001. 68 p. Dissertação (Mestrado em Engenharia Civil) - Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2001.
- ARBIB, M. A. **The handbook of brain theory and neural networks**. Boston: Massachusetts Institute of Technology, 2003. 1309 p.
- AUSTRALIAN STANDART. **AS 3774**: loads on bulk containers. Sydney, 1996. 62 p.
- CALIL JUNIOR, C.; NASCIMENTO, J. W. B.; ARAÚJO, E. E. **Silos metálicos multicelulares**. São Carlos: EESC/USP, 1997. 175 p.
- CYBENKO, G. **Approximation by superpositions of a sigmoidal function, math**: control signals systems. New York: Spring-Verlag, 1989. 314 p.
- DANDOLINI, G. A. **Um procedimento para avaliação da saúde financeira de pequenas empresas**: estudo de um caso usando redes neurais artificiais. 1997. 168 f. Dissertação (Mestrado em Engenharia de Produção) - Universidade Federal de Santa Catarina, Florianópolis, 1997.
- DEUTSCHE NORM. **DIN 1055-6**: basis of design and actions on structures, part 6, design loads for buildings and loads in silo bins. Berlin, 2000. 5 p.
- ENSTAD, G. On the theory of arching in mass flow hoppers. **Chemical Engineering Science**, New York, v. 30, p. 1273-1283, Oct. 1975.
- FAUSETT, L. **Fundamentals of neural networks**: architecture, algorithms, and applications. New York: Prentice Hall Internacional, 1994. 461 p.
- GOMES, F. C. **Estudo teórico e experimental das ações em silos horizontais**. 2000. 205 p. Tese (Doutorado em Engenharia de Estruturas) - Universidade de São Paulo, São Carlos, 2000.
- HAYKIN, S. **Redes neurais**: princípios e prática. 2. ed. Porto Alegre: Bookman, 2001. 900 p.
- INTERNACIONAL STANDART. **ISO 11697**: bases for design of structures: loads due to bulk materials. Geneva, 1995. 15 p.

JACKSON, J. Data mining: a conceptual overview. **Communications of the Association for Information Systems**, Claremont, v. 8, n. 15, p. 267-296, Mar. 2002.

JANSSEN, H. A. Versuche über getreidedruck in silozellen. **Zeitschrift/Verein Deutscher Ingenieure**, Dusseldorf, v. 39, p. 1045-1049, Aug. 1895.

JENIKE, A. W. **Storage and flow of silos**. Salt Lake City: University of Utah, 1964. 197 p. (Utah Engineering Experiment Station. Bolletin, 123).

LAWRENCE, R. **Using neural networks to forecast stock market prices**. Disponível em: <<http://www.cs.uiowa.edu/~rlawrenc/research/Papers/nn.pdf>>. Acesso em: 10 dez. 2010.

NASCIMENTO, J. W. **Estudo de silos metálicos prismáticos para fábricas de ração**. 1996. 152 f. Tese (Doutorado em Engenharia de Estruturas) - Universidade de São Paulo, São Carlos, 1996.

PALMA, G. **Pressões e fluxo em silos esbeltos**. 2005. 109 p. Dissertação (Mestrado em Engenharia de Estruturas) - Universidade de São Paulo, São Carlos, 2005.

RAVENET, J. **Silos**. Barcelona: Laser Fotocomposicion, 1992. 508 p.

RICH, E.; KNIGHT, K. **Inteligência artificial**. 2. ed. São Paulo: Makron Books do Brasil, 1994. 362 p.

SILVA, E. T. **Elementos pré moldados para silos quadrados de concreto armado**. 1998. 178 f. Tese (Doutorado em Engenharia Agrícola) - Universidade Estadual de Campinas, Campinas, 1998.

SILVA, J. S. **Secagem e armazenagem de produtos agrícolas**. 2. ed. Viçosa, MG: Aprenda Fácil, 2008. 560 p.

TAFNER, M. A.; XEREZ, M.; RODRIGUES FILHO, I. **Redes neurais artificiais: introdução e princípios de neurocomputação**. Blumenau: EKO, 1995. 199 p.

ANEXOS

ANEXO A – Algoritmo para determinação das pressões na parede do corpo do silo, de acordo com a teoria Janssen e as normas Din e As

```

function [Ph,Pv,Pw] = Preest(Fiw,Fii,y,r,H);

A = %pi*r^2;
U = 2*%pi*r;
Mi = tan(Fiw*%pi/180);

// Teoria de Janssen
//K = ( 1 - sin(Fii*%pi/180) ) / ( 1 + sin(Fii*%pi/180) );

// Teoria da Norma Din
//K = 1.1*(1 - sin(Fii*%pi/180));

// Teoria da Norma AS
//K = ( 1 + (sin(Fii*%pi/180))^2 - 2*sqrt( (sin(Fii*%pi/180))^2 - (Mi^2)*(cos(Fii*%pi/180))^2 ) ) / (4*(Mi)^2 + (cos(Fii*%pi/180))^2 );

Ph = (y/Mi)*(A/U)*( 1 - %e^(-H*K*Mi*(U/A))); // Pressão horizontal
Pv = Ph/K; // Pressão vertical
Pw = Mi*Ph; // Pressão de atrito

endfunction

```

ANEXO B – Algoritmo para determinação das pressões na tremonha do silo, de acordo com as normas As, Din e Iso

```

function [Pt_Iso,Pt_Din,Pt_As,Pn_Iso,Pn_Din,Pn_As] =
    Preest(Fiw,Fii,y,r,H,alfa,Ph,Pv,x,ln);

A = %pi*r^2;
U = 2*%pi*r;
Mi = tan(Fiw*%pi/180);
ang = 90 - alfa;
n = 0.5*( Fiw + 180*asin( sin(Fiw*%pi/180) / sin(Fii*%pi/180) ) )/%pi);

K = ( 1 + sin(Fii*%pi/180)*cos((2*n)*%pi/180) ) / ( 1 -
    sin(Fii*%pi/180)*cos( (2*(alfa + n))*%pi/180 ) );

Pn1 = (1.5*Ph) * ( (1/K)*(cos(ang*%pi/180))^2 + (sin(ang*%pi/180))^2 );
Pn2 = (1.5/K)*Ph*(cos(ang*%pi/180))^2;
Pn3 = 3 * (A/U) * ( (y*K)/sqrt(Mi) ) * (sin(ang*%pi/180))^2 ;
Pn4 = 1.2 * Pv * (cos(ang*%pi/180))^2;
Pn5 = Pv * (1.2*(cos(ang*%pi/180))^2 + K*(sin(ang*%pi/180))^2);

Pn_Iso = Pn1 + Pn2 + Pn3; // Teoria Iso
Pn_As = K*Pv; // Teoria As
Pn_Din = Pn3 + Pn4 + (Pn5 - Pn4)*(x/ln); // Teoria Din

Pt_Iso = Mi*Pn_Iso; // Teoria Iso
Pt_As = Mi*Pn_As; // Teoria As
Pt_Din = Mi*Pn_Din; // Teoria Din

endfunction

```

ANEXO C – Algoritmo para determinação das pressões na tremonha, de acordo com a teoria de Walker

```

function [Pn,Pt] = Trem(Fiw,Fie,alfa,y,H);
    m = tan(Fiw*%pi/180);

    if sin(Fie*%pi/180) >= sin(Fiw*%pi/180) / sin( (Fiw + 2*alfa)*%pi/180)

        Pn = (y*H) * ( tan(alfa*%pi/180) / ( tan(alfa*%pi/180) +
            tan(Fiw*%pi/180) ) );
        Pt = Pn*m;

    else

        Pn = (y*H) * ( (1 - sin(Fie*%pi/180) * cos( (2*alfa)*%pi/180 )) / ((1 +
            sin(Fie*%pi/180))) );
        Pt = (y*H) * ( sin(Fie*%pi/180)*sin((2*alfa)*%pi/180) ) / ( 1 +
            sin(Fie*%pi/180) );

    end

endfunction

```

ANEXO D – Algoritmo para determinação do escoamento do produto, de acordo com a teoria de Enstad

function [FF,ff] = Fluxo(Fiw,Fie,ang);

m = 1;

F = (65 / (130 + ang))^m * (200 / (200 + ang))^(1 - m) ;

B = (Fiw + 180*asin(sin(Fiw*%pi/180) / sin(Fie*%pi/180))/%pi) / 2;

O = B + ang;

aux1 = (2^m * sin(Fie*%pi/180)) / (1 - sin(Fie*%pi/180));

aux2 = (sin((B + O)*%pi/180) / cos((90 - ang)*%pi/180)) + 1;

X = aux1 * aux2;

aux3 = (2*(1 - cos(O*%pi/180)))^m * O^(1 - m) * cos((90 - ang)*%pi/180) + sin((B*(sin(O*%pi/180))^(1+m)) * %pi/180);

aux4 = (1 - sin(Fie*%pi/180)) * (sin(O*%pi/180))^(2+m);

Y = aux3 / aux4;

FF = (Y*(1 + sin(Fie*%pi/180))) / (2*(X + 1)*F*cos((90 - ang)*%pi/180));

ff = 180*atan(1/FF)/%pi;

endfunction

ANEXO E – Algoritmo para geração da base de entradas composta pelas combinações entre a variabilidade dos dados, de acordo com sua distribuição normal

```
loadmatfile('\Limites.txt','-ascii'); // Abrindo o arquivo dos valores limites

n = 500; // Número de combinações entre os valores limites

// Gerando a matriz de entradas
DadosEntradas = zeros(n,5,3); // Inicializando uma matriz de zeros
for i=1:5

    // Entradas para cálculo das ações no corpo do silo
    DadosEntradas(:,i,1) = grand(n,1,'unf',Limites(1,i,1),Limites(1,i,2));

    // Entradas para cálculo das ações na tremonha
    DadosEntradas(:,i,2) = grand(n,1,'unf',Limites(2,i,1),Limites(2,i,2));

    // Entradas para cálculo do escoamento do produto
    DadosEntradas(:,i,3) = grand(n,1,'unf',Limites(3,i,1),Limites(3,i,2));

end

// Salvando a matriz de entradas
savematfile('\DadosEntradas.txt','-ascii','DadosEntradas');
```

ANEXO F – Algoritmo para gerar as saídas desejadas de acordo com as teorias e normas internacionais

```
// Abrindo o arquivo de entradas  
loadmatfile('DadosEntradas.txt','-ascii');  
  
D = DadoEntradas;  
  
// Gerando os resultados esperados  
for i=1:500  
  
    [Ph,Pv,Pw] = Preest(D(i,1,1),D(i,2,1),D(i,3,1),D(i,4,1),D(i,5,1));  
    [Pn,Pt] = Trem(D(i,1,2),D(i,2,2),D(i,3,2),D(i,4,2),D(i,5,2));  
    [FF,ff] = Fluxo(D(i,1,3),D(i,2,3),D(i,3,3),0,0);  
    DadosSaidas(i,1) = [Ph,Pv,Pw];  
    DadosSaidas(i,2) = [Pn,Pt,0];  
    DadosSaidas(i,3) = [FF,ff,0];  
  
end  
  
// Salvando a matriz saída  
savematfile('DadosSaidas.txt','-ascii','DadosSaidas');
```

ANEXO G – Algoritmo Backpropagation para treinamento da rede neural:

```

// Função Erro
function E = erro(saida,ym)
    E = 0;
    for i=1:size(saida,1)
        for j=1:size(saida,2)
            e = y(i,j) - saida(i,j);
            E = E + e^2;
        end
    end
endfunction

// abrindo a base de dados
loadmatfile('\DadosEntradas.txt','-ascii');
loadmatfile('\DadosSaidas.txt','-ascii');

rand('seed',0); // inicializar o gerador de aleatórios

// Normalizando os dados para treinamento
x = DadosEntradas' / 1000;
y = DadosSaidas' / 1000;
N = [5,50,21,3]; // Descrição da arquitetura da rede
lp = [0.05 0 0.05 0]; // Parâmetros de treinamento: taxa de aprendizagem

Epocas = 1; // Inicializando número de épocas
tol = 0.001; // Taxa de tolerância

W = ann_FF_init(N); // Inicializa uma matriz de pesos
Delta_W_old = hypermat(size(W));

i = 1;
Ec = 10;

// Backpropagation
while (i<=10000)&(Ec>tol)

    W = ann_FF_Mom_online(x,y,N,W,lp,Epocas,Delta_W_old); // Treina

    saida = ann_FF_run(x,N,W) ; // Gerando a saída
    E(i) = erro(saida,y); // Gerando o erro

```

```
Ec = E(i); // Função erro  
i = i + 1;
```

```
end;
```

```
save('W.dat',W); // Salvando os valores dos pesos
```