



## RELATÓRIO TÉCNICO

# REDES NEURAIS ARTIFICIAIS APLICADAS AO AUXÍLIO À TOMADA DE DECISÃO EM PROCESSO ESPECÍFICO DE CORTE DE VIDROS PLANOS

Walma Lucy Maciel Vieira

Prof. Dr. Luis Fernando de Almeida



## 1 | Introdução

Estudos apontam que a maior ocorrência de perdas totais da área produtiva na produção de vidro planos ocorre no setor de corte (Carvalho e Mattos, 2022). Portanto, na produção do vidro plano, é preciso que operadores, principalmente aqueles atuantes em pontos principais do processo, como o sistema de corte, adquiram experiência e sensibilidade para perceber que, baseado na qualidade do vidro, a programação deve ser alterada para que se torne adequada com relação aos produtos a serem obtidos. Muitas vezes, somente após uma produção com alta geração de sucata e baixo aproveitamento na realização de produtos do vidro, leva os operadores a corrigir a programação dos sistemas de corte, para melhores ajustes em função da qualidade desse vidro.

Neste contexto referente ao processo de corte, incluem-se a pesquisa e o desenvolvimento de sistemas de auxílio à tomada de decisão que, em função da qualidade do vidro e das possibilidades de programação de produção, indiquem as respectivas expectativas de sucata. Estes sistemas podem contribuir para automatização do sistema de corte, bem como, para o treinamento de operadores. Assim sendo, este trabalho aborda as áreas de Inteligência Artificial (IA) e Redes Neurais Artificiais (RNA) aplicadas ao auxílio à tomada de decisão em processo específico de corte de vidros planos. A propriedade que é de importância primordial para uma RNA é a sua habilidade de aprender a partir de seu ambiente e de melhorar o seu desempenho por meio da aprendizagem. Uma rede neural aprende acerca de seu ambiente por meio de um processo iterativo de ajustes aplicados a seus pesos sinápticos e níveis de bias (Haykin, 2001).



## 1.1 | Objetivo geral

Este trabalho teve como objetivo principal o desenvolvimento de uma Rede Neural Artificial, do tipo *Multi-Layer Perceptron*, voltada para o auxílio à tomada de decisão para a definição de produção em um sistema específico de corte de folhas de vidro plano, tendo por entrada a qualidade do vidro e a programação de produção e como saída a indicação da respectiva expectativa de sucata, visando oferecer informações que contribuam para uma produção com baixa geração de sucata e alto aproveitamento do vidro. De forma correlata a esse objetivo, a Rede Neural Artificial (RNA) também poderá ser aplicada como auxílio ao treinamento de recursos humanos que realizarão tomada de decisão para a definição de produção.

## 2 | Método

Para o desenvolvimento desta dissertação foram realizadas as seguintes etapas: pré-processamento dos dados; modelagem e implementação da RNA; e análise de resultados.

O formato do arquivo com os dados brutos é apresentado nas Figuras 1 e 2 e a Figura 3 ilustra um exemplo de arquivo de dados de corte transversal. Nas Figuras 1 e 2 tem-se:

- Item 1: corresponde ao registro de horário informado pelo sistema.
- Item 2: corresponde ao registro de horário de um alarme ou evento informado pelo sistema.
- Item 3: corresponde ao registro de ativação da programação de produto principal e/ou alternativo.
- Item 4: corresponde à mensagem de cadastro de produto.
- Item 5: corresponde ao complemento da mensagem de cadastro de produto.
- DATA: dia, mês e ano da mensagem no formato DD-MMM-AA.
- HORA: hora, minuto e segundo da mensagem no formato HH:MM:SS.
- TEXTO1: constante definida pelos caracteres "AUDIT-CAP#".
- N: "Número de Ordem de Cadastramento".
- TEXTO2: constante definida pelos caracteres "PROD#".
- P: "Classe Máxima de Defeitos".
- TEXTO3: constante definida pelos caracteres "LNGTH".
- COMP: comprimento, em milímetros, do produto realizado no formato "0000.00".
- TEXTO4: constante definida pelos caracteres "WIDTH".
- LARG: largura, em milímetros, do produto realizado no formato "0000.00".
- TEXTO5: constante definida pelos caracteres "#LITE X".
- TP: indica o tipo do produto realizado entre principal e alternativo, ou sucata.
- TEXTO6: constante definida pelos caracteres "'X' POS", que identifica a coluna referente à posição vertical do defeito.
- TEXTO7: constante definida pelos caracteres "'Y' POS", que identifica a coluna referente à posição horizontal do defeito.
- TEXTO8: constante definida pelos caracteres "LENGTH", que identifica a coluna referente ao comprimento do defeito.
- TEXTO9: constante definida pelos caracteres "CLASS", que identifica a coluna referente à "Classe Máxima de Defeitos".
- TEXTO10: constante definida pelos caracteres "TYPE", que identifica a coluna referente ao tipo do defeito.



Figura 1 | Exemplo de histórico de alarmes e eventos do sistema FloatScan-Advanced (Rocwell, 2011).

item 1

Item 2

Item 2

Item 3

Item 3

Item 4

Item 4

Item 4

Item 5

```

**A 06:00
06:01 46A BERTH BACKUP
06:04 18A GAP PHOTO OFF
06:05 18A
**A 06:15
**A 06:30
ACTIVE CAP#[1..10] 12..... 12 DEFECT CAP#[0..10] ..... 67 **
06:46 53A L2 LINK FAIL
06:48 53A
CAP DATA#[0=TEST] 21 PROD# 54 #ALLOWED DEFECT 00
LENGTH 2400.00 #LITES/CAP 1
YCUT# 1 HD#[1..11](X 2) 1.....1
TRIM#[1..6] 123456
PWDR#[0..2] 12 ROUTE#[0-5] 1 UNLD#[0..2] FOR LITE# 1 12 **
    
```

Figura 2 | Exemplo de estrutura de arquivo histórico de corte transversal do vidro (Rockwell, 2011).

| DATA | HORA | TEXT01 | N | TEXT02 | P | TEXT03 | COMP | TEXT04 | LARG | TEXT05  | TP |
|------|------|--------|---|--------|---|--------|------|--------|------|---------|----|
|      |      | TEXT06 |   | TEXT07 |   | TEXT08 |      | TEXT09 |      | TEXT010 |    |
|      |      | POS_H  |   | POS_V  |   | COMP_D |      | CLASSE |      | TIPO    |    |

**Figura 3** | Exemplo de conteúdo de arquivo de histórico de corte transversal (Rockwell, 2011).

06-MAY-13 00:00:51 AUDIT - CAP# 1 PROD# 3 LNTH 2000.00 WIDTH 3210.00 #LITE 1 ACT CAP

| 'X' POS | 'Y' POS | LENGTH | CLASS | TYPE |
|---------|---------|--------|-------|------|
| 868.00  | 311.75  | 810    | 4     | 3    |
| 108.50  | 2219.50 | 400    | 3     | 2    |
| 219.25  | 169.75  | 350    | 2     | 2    |
| 544.50  | 262.75  | 360    | 2     | 2    |
| 1546.25 | 200.00  | 240    | 2     | 2    |
| 1645.00 | 2576.25 | 350    | 2     | 2    |

LITE ZEBRAS = 58

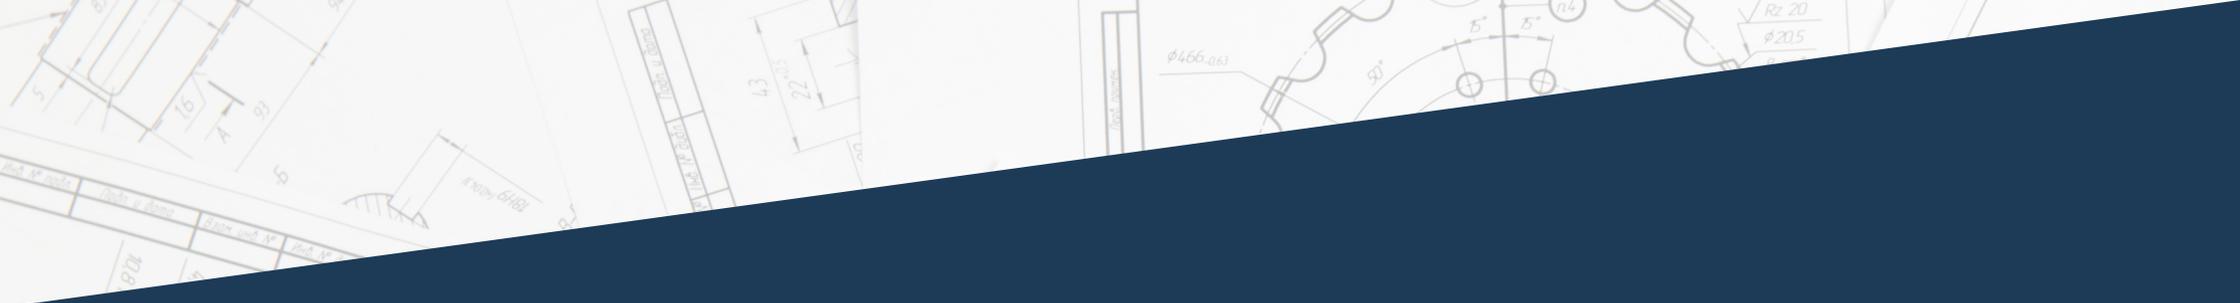
A partir dos dados arquivos apresentados, anteriormente, são criados os arquivos contendo as informações sobre cada folha recortada (produto final) as informações sobre a folha contínua virtualmente reconstituída, ilustrados, respectivamente, pelas Figuras 4 e 5, com os arquivos dados1.txt e dados2.txt.

**Figura 4** | Exemplo de arquivo dados1.txt

```
1;23-SEP-14;23:50:21;1;4;1900.00;3600.00;1;ACT CAP
2;23-SEP-14;23:50:44;2;4;1900.00;3600.00;1;ACT CAP
3;23-SEP-14;23:51:06;1;4;1900.00;3600.00;1;ACT CAP
4;23-SEP-14;23:51:29;2;4;1900.00;3600.00;1;ACT CAP
5;23-SEP-14;23:51:51;1;4;1900.00;3600.00;1;ACT CAP
6;23-SEP-14;23:52:14;2;4;1900.00;3600.00;1;ACT CAP
7;23-SEP-14;23:52:52;11;0;1460.00;3600.00;1;SCRP CAP-DEFECTS
8;23-SEP-14;23:52:54;1;4;1900.00;3600.00;1;ACT CAP
9;23-SEP-14;23:53:16;2;4;1900.00;3600.00;1;ACT CAP
10;23-SEP-14;23:53:39;4;5;1900.00;3600.00;1;ALT CAP-DEFECTS
11;23-SEP-14;23:54:01;1;4;1900.00;3600.00;1;ACT CAP
12;23-SEP-14;23:54:24;2;4;1900.00;3600.00;1;ACT CAP
13;23-SEP-14;23:54:46;1;4;1900.00;3600.00;1;ACT CAP
```

**Figura 5** | Exemplo de arquivo dados2.txt

```
2;2877,5;3553.50;1850;4;1
7;11713,25;141.25;710;3;3
7;12745,75;3366.00;6550;6;3
8;13612,25;3179.00;400;3;2
9;15180,75;3555.25;870;4;1
10;17469,75;2122.25;4060;5;2
10;17480,25;2106.50;3020;5;3
13;22852,75;3447.75;430;3;2
15;26805,25;1966.75;500;3;2
19;34305;3554.75;1210;4;1
```



Com os dados pré-processados são gerados os atributos para treinamento e teste da RNA, sendo eles:

Programação de produção: indica o tipo de restrição associado ao plano de produção, sendo a programação de produção “Restritiva” aquela na qual os produtos possuem requisitos de qualidade mais restritos que outros, havendo restrição quanto ao comprimento máximo dos defeitos, e a programação “Flexível” aquela, que de forma oposta, os produtos possuem requisitos de qualidade menos restritos que outros.

Desvio padrão posição-defeitos classe máxima: cálculo do desvio padrão sobre a posição horizontal de todos os defeitos, na folha contínua de vidro virtualmente reconstituída do produto principal.

Desvio padrão posição-defeitos classe máxima + 1: cálculo do desvio padrão sobre a posição horizontal dos defeitos, na folha contínua de vidro virtualmente reconstituída acrescido de mais 1.

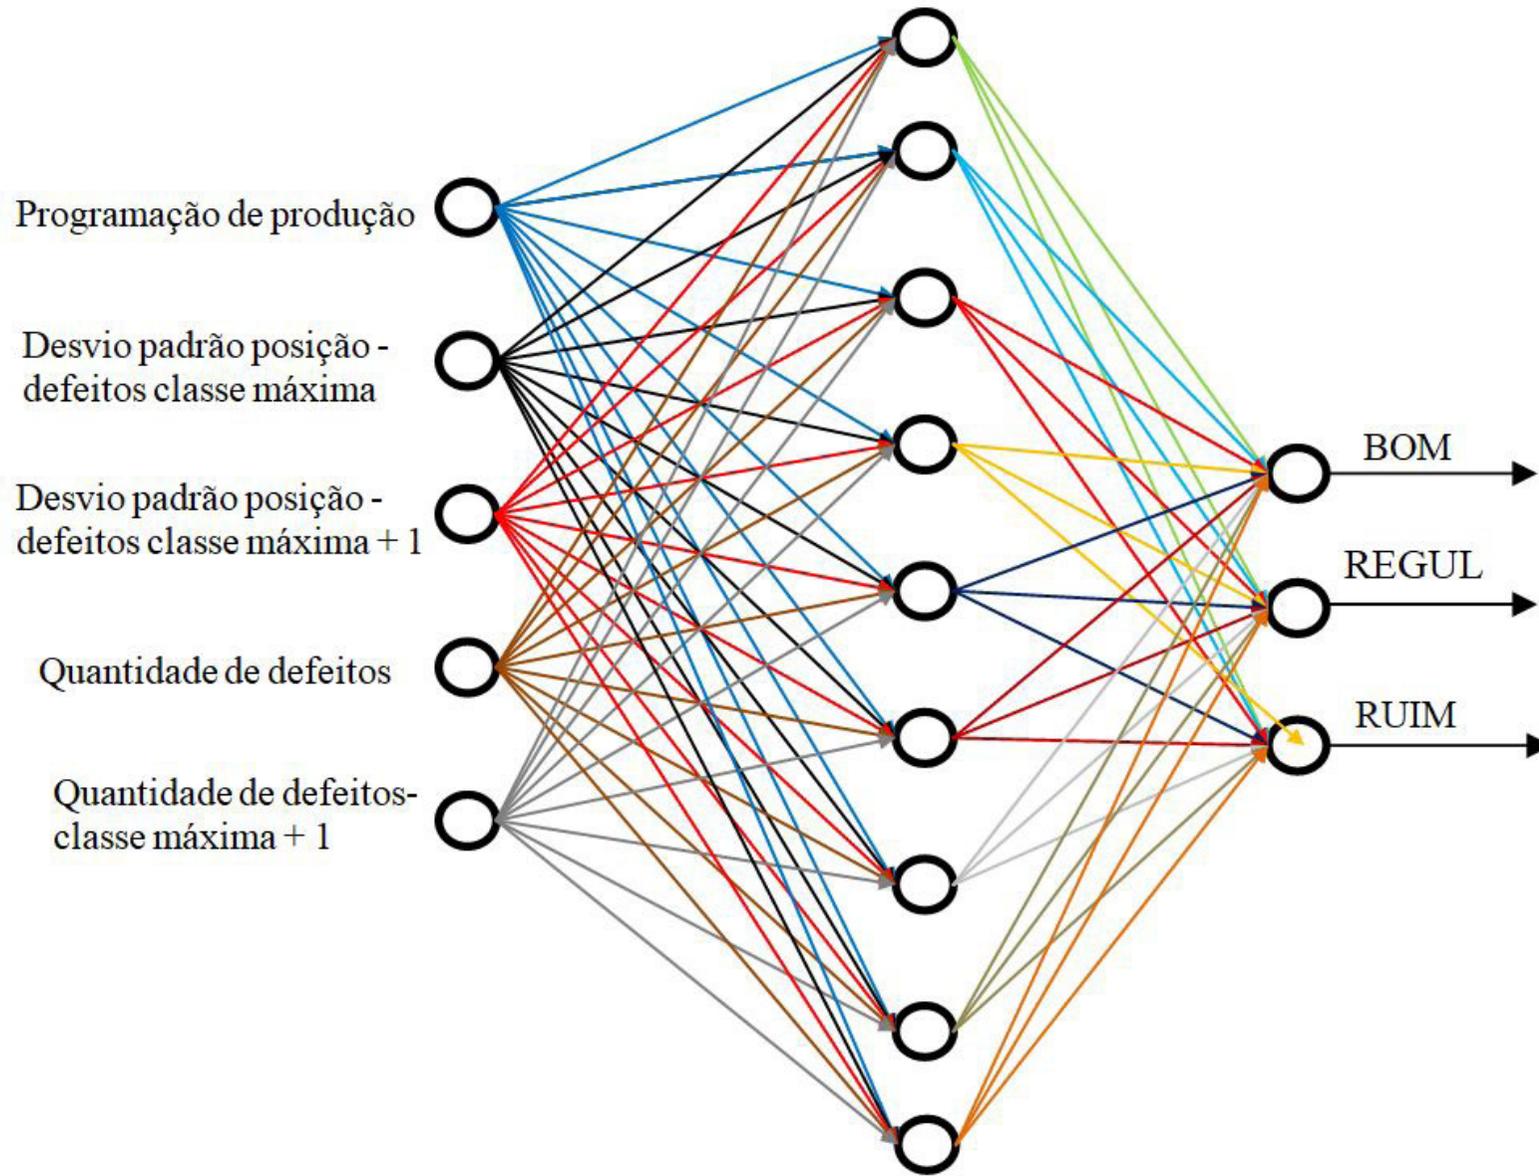
Quantidade de defeitos-classe máxima: cálculo da quantidade de defeitos, na folha contínua de vidro reconstituída do produto principal.

Quantidade de defeitos-classe máxima + 1: cálculo da quantidade de defeitos, na folha contínua de vidro virtualmente reconstituída do produto principal acrescido de 1.

Produção: expressa o rendimento da produção, representando a qualidade referente às folhas produzidas, sendo “BOM”, “REGULAR”, “RUIM”. Geralmente, esse rendimento está relacionado com a maior quantidade de produtos principais produzidos e menor quantidade de sucata gerada. Baseada na porcentagem encontrada e na realidade observada nas indústrias de vidros planos (ISRA, 2015), definiu-se para essas classes o que segue: BOM, quando a quantidade de produto principal produzido for maior ou igual a 80% dos cortes realizados; RUIM, quando a quantidade de sucata produzida for maior ou igual a 10% dos cortes realizados; REGULAR, quando quantidade de sucata produzida for menor que 10%, produto principal for menor que 80% e produto alternativo maior ou igual a 10%.

A Figura 6 apresenta a arquitetura da RNA do tipo Multilayer Perceptron (MLP) implementada. Nesse caso, considera-se: para a camada de entrada, 5 (cinco) neurônios que correspondem aos atributos: “Programação de produção”, “Desvio padrão posição-defeitos classe máxima”, “Desvio padrão posição-defeitos classe máxima + 1”, “Quantidade de defeitos-classe máxima” e “Quantidade de defeitos-classe máxima + 1”; para a camada de saída, 3 (três) neurônios, em função do número de classes referentes ao atributo “Produção”, “BOM”, “REGULAR” e “RUIM”.

Figura 6 | Arquitetura da MLP implementada.



### 3 | Resultados e Discussões

Para realização dos testes nesse trabalho foram utilizados dados referentes à produção de vidro de uma indústria do setor com espessura de 8 milímetros e no tom fumê. A tonalidade do vidro não influencia o funcionamento do sistema, mas a espessura influencia diretamente na velocidade da folha contínua do vidro, determinando o intervalo entre folhas cortadas. Foi escolhida a espessura de 8 milímetros, para qual sabe-se que a velocidade da linha de produção que contém folha contínua de vidro, é de 560 centímetros/minuto. Assim, em um intervalo de 5 minutos pode-se determinar, aproximadamente, 28 metros de comprimento para a folha contínua de vidro (ISRA, 2015). Se essa folha for cortada na direção Y (corte transversal) a cada 2,4 metros, obtém-se, aproximadamente, 11 folhas, que um número expressivo para o intervalo de interesse para a análise da MLP.

Para a realização dos testes, considerou-se para a classificação do rendimento o que segue:

- Durante um período de, aproximadamente, 5 minutos foi contabilizado o total de folhas produzidas para cada tipo de resultado: produto principal, produto alternativo e sucata.
- Para cada total contabilizado foi calculado a sua porcentagem com relação à produção total durante o período.
- Baseada na porcentagem encontrada definiu-se a classe considerando o atributo “Produção”: BOM, RUIM e REGULAR.

Nos testes realizados, a obteve índice de acerto máximo de 91,27%, índice de acerto médio de 89% e desvio padrão do índice de acerto de 2.17%, conforme ilustrado na Figura 7.

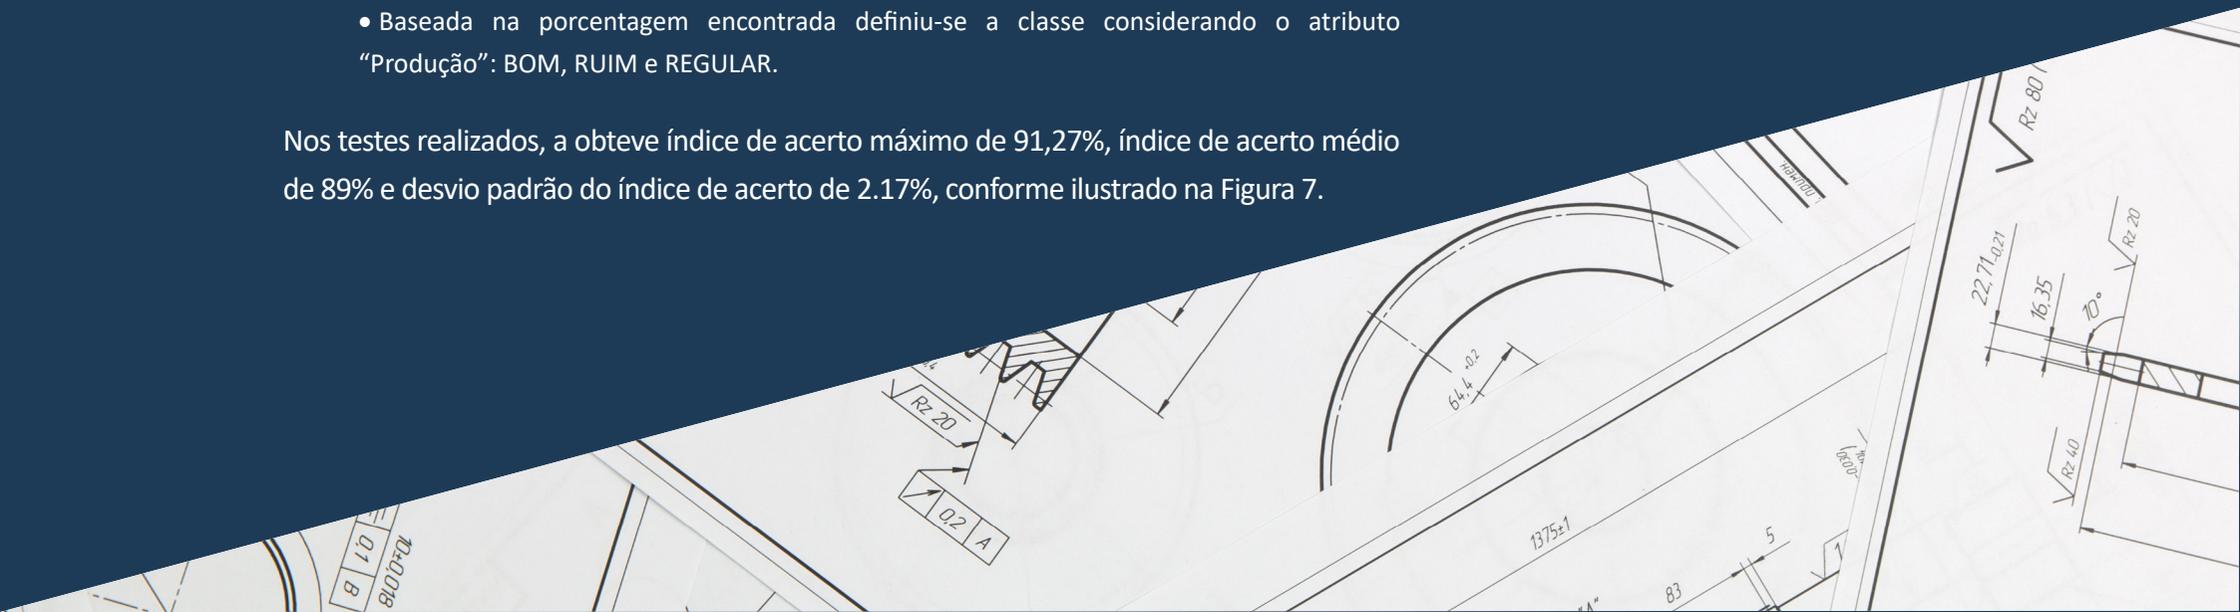
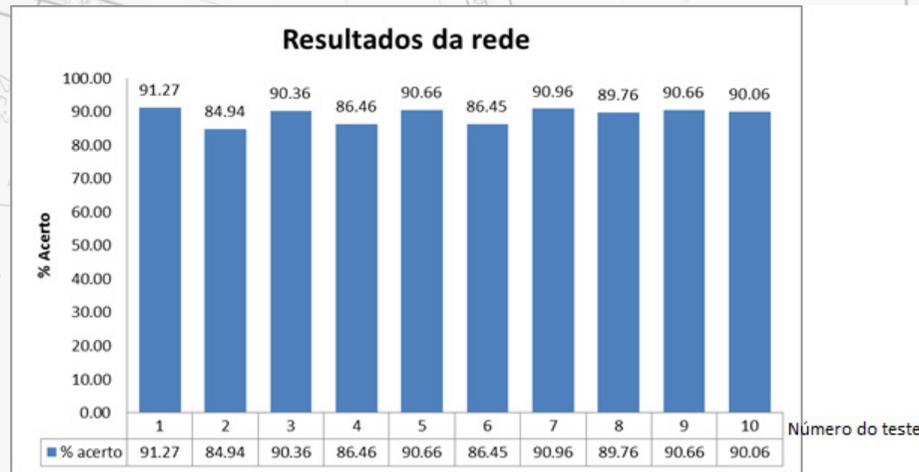


Figura 7 | Resultados do teste da MLP.



Uma segunda etapa de teste consistiu na análise da RNA de prever o resultado de uma produção em face de 4 cenários de produção distintos: cenário 1 - programação de produção restritiva e índice de defeitos alto; cenário 2 - programação de produção flexível e índice de defeitos baixo; cenário 3 - programação de produção flexível e índice de defeitos alto; e cenário 4 - programação de produção restritiva e índice de defeitos alto.

Para estes cenários espera-se, respectivamente: rendimento de produção seja baixo e o resultado da MLP seja produção RUIM; rendimento de produção seja alto e o resultado da MLP seja produção BOA; rendimento de produção seja adequado e o resultado da MLP seja produção “REGULAR”; e a quantidade sucata aumente e as produções tenham tendências para “RUIM”. A Tabela 1 apresenta os resultados obtidos para cada cenário, a qual verifica-se a dificuldade da MLP somente para a classificação correta do resultado da produção para o cenário 4.

Tabela 1 | Resultado da MLP para o teste com os cenários

| Teste     | Acurácia da MLP |
|-----------|-----------------|
| Cenário 1 | 100%            |
| Cenário 2 | 100%            |
| Cenário 3 | 100%            |
| Cenário 4 | 60%             |



## Referências

CARVALHO, F. L. S.; MATTOS, T. N. Aplicação de ferramentas de gestão visando a redução de perdas no processo de produção em uma fábrica de vidros capixaba. **Brazilian Journal of Production Engineering**, v. 8, n. 2, p. 99-115, 2022.

HAYKIN, S. **Redes neurais: princípios e prática**. 2ª ed., São Paulo: Bookman, 2001.

ISRA. **Floatscan catcher & optics: user manual**, Manual do Usuário, ISRA, 2014.

ROCKWELL, **Automation. Cut system user manual**. Rockwell Automation, 2011.

**Walma Lucy Maciel Vieira | Mestre/walma.martins@hotmail.com**

**Prof. Dr. Luis Fernando de Almeida | luis.almeida@unitau.br**

**DOI: <https://doi.org/10.69609/1516-2893.2024.v30.n1.a3853>**

**Universidade de Taubaté - Julho/2015.**

---

**Área: Metodologia e Técnicas de Computação**

**Data de conclusão da pesquisa: julho/2015.**

**Link para trabalho completo: trabalho no formato impresso.**

**Curso de pós-graduação ao qual o trabalho está vinculado:**

**Mestrado Profissional em Engenharia Mecânica.**

