

APLICAÇÃO DE REDES NEURAIAS ARTIFICIAS PARA REDUÇÃO DA VARIABILIDADE NO PROCESSO PRODUTIVO DE UMA INDÚSTRIA ALIMENTÍCIA

Lee Vinagre Monteiro (PUC)

lee_vinagre@hotmail.com

Mariana Pereira Carneiro (UEPA)

mariana_karneiro@yahoo.com.br

Fabiano Cordeiro Moreira (UFPA)

fabiano@plugplay.com.br



Resumo Este trabalho teve seu estudo focado em uma instalação industrial de médio porte de produtos alimentícios. A indústria atua na produção de produtos alimentícios do segmento snacks (salgadinhos de milho). O objetivo do trabalho foi desenvolver uma Rede Neural Artificial capaz de aprender o comportamento das variáveis estudadas e conseguir prever uma configuração de maquinário (Setup) que possa ser utilizada para reduzir a variabilidade observada no processo. Este estudo foi realizado em duas etapas, a primeira foi voltada para determinar as possíveis causas da variabilidade, com isto foi possível determinar que uma das principais causas para a variabilidade observada é elevada variação do Setup, desta forma foi possível a aplicação de uma rede neural artificial e a segunda etapa foi voltada para o desenvolvimento da rede neural artificial em si, no entanto por fatores desconhecidos não foi possível determinar a configuração necessária. ABSTRACT This research was focused in a food factory industrial installation of medium size. This industry is actuating in the snacks segment. The main objective of this research was to develop an Artificial Neural Network able to learn the behavior of the studied variables and with that predict the best machinery setup in order to prevent variability effects. This study was divided in two steps: one focused in the study of the possible main causes to variability in the process, with that was possible to verify that one of the main causes for the variability was the high variations on the machinery setup witch make able the application of the artificial neural network. The second step was the development of the artificial neural network and its application. However for unknown causes was not possible to determinate the necessary setup configuration.

Palavras-chaves: Palavras-chave: Variabilidade, Controle de Qualidade, Redes Neurais Artificiais.

1. Introdução

Garantir a qualidade de seus produtos é um desafio constante no dia a dia das empresas, pois a qualidade é agora um requisito básico para a sobrevivência de uma organização. Assim é necessário controlar e garantir a conformidade de seus produtos, no entanto existem fatores que dificultam a prática destas atividades. Um destes fatores é a variabilidade.

A variabilidade gera uma grande falta na padronização nos produtos, ela pode ser gerada por diversas causas e dependendo do tipo de variabilidade ela pode ou não ser prevista por técnicas matemáticas. Definido o comportamento da variabilidade será possível tomar ações que garantam a conformidade dos produtos. Garantir a conformidade dos produtos não só irá conferir um novo padrão de qualidade a empresa, mas também diminuir os custos acarretados pela produção de produtos fora dos padrões especificados.

O estudo deste trabalho é voltado para a aplicação de uma técnica que consiga descobrir o comportamento da variabilidade no processo produtivo de um determinado produto de uma indústria do ramo alimentício, especificamente os salgadinhos sabor queijo e gramatura de 160 gramas. A técnica aplicada será uma rede neural artificial.

Por questões até mesmo de segurança ao consumidor, existe uma grande necessidade de controlar a variabilidade dos produtos. Em uma empresa do ramo alimentício, a existência mesmo em quantidade moderada de produtos fora de especificação pode acabar gerando complicações ao bem estar dos consumidores. Assim foi possível determinar a questão norteadora do trabalho: A aplicação de uma rede neural artificial é capaz de reduzir a variabilidade nos produtos e, por conseguinte gerar um novo padrão de qualidade?

A rede neural deverá, a partir de dados históricos arquivados pelo setor de controle de qualidade, aprender o comportamento das variáveis de controle e assim definir qual o ajuste que deve ser feito às máquinas do processo produtivo, no caso o SETUP adequado, para assim minimizar a variabilidade dos salgadinhos de sabor queijo e gramatura de 160 gramas.

Com esta aplicação se visa encontrar um ajuste no maquinário que permita com que os produtos finais sejam produzidos de uma forma mais padronizada e o mais próximo possível às especificações internas e dos clientes. Assim será conferido um novo padrão de qualidade dentro da empresa, além de gerar uma redução considerável ao tempo de SETUP das máquinas e diminuir o valor de custos gerados por produtos fora de conformidade.

Como em todo processo produtivo, o processo de produção de salgadinhos apresenta certo nível de variabilidade. Esta variabilidade é resultante de fatores até então desconhecidos e, portanto até então não foi controlado de forma eficiente. Com este baixo nível de controle não é possível produzir produtos com um nível adequado de padronização. O baixo índice de padronização dos produtos acaba por gerar desperdícios no processo produtivo e insatisfação por parte dos clientes, pois os produtos nem sempre estarão de acordo com o padrão de aceitação dos clientes. Como um produto não é igual ao outro não é possível conquistar o consumidor.

2. Empresa X

Iniciada suas atividades em 1993 em Brasília, a empresa X estabeleceu o público infantil como alvo principal para a comercialização de seus produtos no segmento de *snacks*

(Salgadinhos de milho). Porém devido ao considerável crescimento de sua marca, sentiu-se a necessidade de expandir tanto suas instalações e sua variedade de produtos. Para suprir as necessidades mercadológicas, a empresa X inaugurou outras fábricas em pontos estratégicos do País: Goiás, Pará e Bahia.

Este estudo foi realizado na fábrica localizada no Pará. A fábrica é uma instalação de médio porte, com 322 funcionários. Os setores da empresa onde foram realizados os estudos foram os seguintes: Setor de produção de Salgadinhos e o setor de Controle de Qualidade. Para este estudo o produto selecionado como objeto de estudo será o salgadinho de milho sabor queijo de gramatura 160 gramas. Para melhor entendimento deste trabalho será explicado como funciona o processo de fabricação do produto estudado.

O processo de fabricação de salgadinhos é dividido basicamente em quatro etapas: o processo de extrusão, de aromatização, de aquecimento e de empacotamento.

Durante o processo de extrusão, a farinha de milho é combinada a outras substâncias como gordura, sal entre outras. Estas substâncias combinadas formam o que é denominado Mescla e durante o processo de extrusão é ajustado o percentual de Mescla do produto, ou seja, a quantidade destas substâncias presentes no produto. Neste processo a matéria prima é aquecida em conjuntos de fôrmas e depois cortada em pequenas unidades, durante este processo a matéria prima ganha forma característica do salgadinho.

Após o processo de extrusão o salgadinho vai para uma esteira onde ocorre o processo de aromatização, durante este processo o salgadinho recebe a substância responsável pelo odor e pelo sabor específico do produto, que no caso em estudo é o flavorizante de queijo. Neste processo é controlada a velocidade da esteira e a frequência de um equipamento denominado Dosador de Aroma, este equipamento é responsável pelo despejo da substância aromatizante.

No processo seguinte, o salgadinho passa por um processo de aquecimento, este processo é necessário para fixar a substância aromatizante ao produto. Neste processo o produto passa por esteira acoplada a um forno, esta esteira possui velocidade igual à esteira anterior, portanto a única variável que deve ser controlada durante este processo é a temperatura do forno.

Com o processo de aquecimento finalizado o produto está pronto para o processo de empacotamento, após o produto ser empacotado são coletadas amostras para serem estudadas pelo setor de controle de qualidade. Durante esta análise são verificados: o peso do pacote em gramas, o teor de umidade do produto e o teor de sal. Estando o produto de acordo com as especificações, o lote da amostra é liberado para ser comercializado.

Se o produto não estiver dentro das especificações a máquina é reajustada e o processo é reiniciado. Neste ponto se caracteriza a problemática deste trabalho, devido à alta variabilidade do processo nem sempre as especificações são alcançadas e o produto final acaba não sendo padronizado gerando custos e até mesmo um grau de insatisfação dos clientes.

3. Revisão teórica

3.1 Variabilidade

Desde a revolução industrial, preocupou-se em estudar a variabilidade dos processos. Segundo Shewart (1986), todo e qualquer processo, por mais bem projetado e por mais bem

controlado que seja, possui em sua variabilidade um componente impossível de ser eliminado, que é fruto de uma série de pequenas perturbações denominadas causas aleatórias.

De acordo com Montgomery (2004) há certa quantidade de variabilidade em cada produto. Dependendo do nível de variabilidade o produto ou até mesmo lotes inteiros de produção podem ser perdidos, gerando altos custos na produção. Conceitualmente existem dois tipos de variabilidade a primeira é denominada de variação devido a causas naturais, ou seja, são variações relacionadas a diversos fatores e são consideradas incontroláveis. O segundo tipo é denominado de variação gerada por causas especiais, normalmente relacionados a apenas um determinado fator.

3.2 Controle de Qualidade

Controle de qualidade, de acordo com Werkema (1995), é um sistema de técnicas que permitem a produção econômica de bens e serviços que satisfaçam as necessidades do consumidor. Diferentemente da inspeção tradicional que verifica do produto acabado, o moderno controle de qualidade atua em todas as fases do processo produtivo, sua diretriz é evitar a produção de qualidade insatisfatória, em lugar de somente separá-los ao final da produção.

Segundo Albertazzi e Sousa (2008), o controle de qualidade seria um conjunto de operações de medição desenhado para assegurar que apenas os produtos que atendam plenamente as especificações técnicas sejam comercializados. A qualidade de produtos ou serviços é um requisito fundamental para a sobrevivência de qualquer organização. Para tanto são necessárias a aplicações de determinadas ferramentas ou, um grupo de técnicas para a realização deste controle estas técnicas são denominadas ferramentas da qualidade.

3.3 Diagrama de Causa e Efeito

As ferramentas da qualidade são técnicas utilizadas para dar suporte ao desenvolvimento da qualidade ao apoio de decisão na solução de determinadas problemáticas recorrentes a processos de produção e de serviços. As ferramentas da qualidade, segundo Werkema (1995), são utilizadas para a coleta e processamento das informações necessárias as conduções de um processo de controle da qualidade.

Utilizado para apresentar a relação existente entre um resultado de um processo, ou seja, um efeito e os fatores que causam tais efeitos. Esta técnica também é denominada de “digrama espinha de peixe” ou “diagrama de Ishikawa”. Segundo Falconi (1992), o primeiro passo no entendimento do controle de processo é a compreensão do relacionamento causa/efeito.

O diagrama analisa as causas que podem gerar as variações dentro de um processo, e essas causas são agrupadas por afinidades, que são as seguintes: matéria-prima, máquinas e equipamentos, mão de obra, materiais, métodos, meio ambiente e medidas.

De acordo com Martins (2010), estes grupos são denominados 6M. O controle destas características tanto na entrada quanto na saída do processo proporciona o conhecimento da “voz do processo”, ou seja, por meio deste controle é possível definir as saídas de um processo e, por conseguinte adquirir um *feedback* sobre o desempenho do processo para mantê-lo como vem operando ou para alterar sua configuração, caso seja necessário.

3.4 Redes Neurais Artificiais

RNAs são, de acordo com Haykin (2001), sistemas que manipulam a informação pela interação de unidades básicas de processamento conhecidas como neurônios artificiais. O sistema recebe sinais externos, denominados de entradas, que são processados gerando saídas. Os neurônios enviam sinais entre si que conseqüentemente fazem com que a informação seja transmitida por toda a rede.

Neurônios Artificiais são as unidades básicas de processamento de uma RNA, sendo também unidades fundamentais para o funcionamento da rede, ou seja, sem neurônios artificiais não existe RNA. Cada neurônio recebe entradas, as processa e transfere os resultados por meio de uma ou mais saídas. A figura a seguir representa um modelo de neurônio artificial:




Figura 1 - Modelo de Neurônio Artificial

Fonte: Adaptado de Haykin (2001)

Segundo Haykin (2001) um neurônio artificial é formado por três elementos básicos: (i) Um conjunto de sinapses ou elos de conexão, cada uma caracterizado por um peso. Ao contrário de uma sinapse do cérebro, o peso sináptico de um neurônio artificial pode estar em um intervalo que inclui valores negativos e positivos; (ii) Um somador para somar os sinais de entrada, ponderando pelas respectivas sinapses do neurônio; (iii) Uma função de ativação para restringir a amplitude da saída de um neurônio. As funções de ativação comumente usadas são as funções: logísticas, linear e tangente hiperbólica.

O número de neurônios de uma RNA varia de acordo com o tipo de problema que se deseja resolver o número de neurônios é definido de forma heurística. Assim como os neurônios a função de ativação também depende do tipo problema que se tenta resolver. Para a aplicação de uma RNA, é necessário que a rede passe por duas etapas de processamento: a fase de aprendizado ou treinamento e a fase de teste. Após estas fases a RNA pode ser utilizada para a resolução da problemática para a qual esta foi desenvolvida.

O processo de treinamento ou aprendizado é o primeiro passo para a aplicação de uma RNA a um determinado problema. As RNAs se caracterizam pelo aprendizado por meio de exemplos (BRAGA et al., 2007). Tais exemplos são utilizados para que a rede consiga identificar o padrão do fenômeno estudado. Para uma RNA aprender, significa que irá passar por um processo em que os neurônios possam armazenar as características dos dados de entrada.

Outro ponto importante a respeito das RNAs é a arquitetura, ou seja, a forma como seus neurônios estão organizados, esta estruturação contribui significativamente no desempenho de uma RNA em diversas aplicações. De acordo com Braga et al (2007) a arquitetura de uma RN

pode ser definida quanto ao seu número de camadas, quanto a conectividade e quanto ao tipo de alimentação.

Para este estudo foi utilizado um modelo específico de RNA: redes do tipo Perceptron de Múltiplas camadas (MLP). As redes MLP podem ser definidas como uma rede de múltiplas camadas, totalmente conectada, ou seja, todos os neurônios de uma camada estão conectados ao neurônio da próxima camada e assim por diante. Redes MLP são treinadas com o algoritmo de Retro propagação, este algoritmo é uma generalização da regra Delta. A regra Delta é utilizada para treinar RNAs de apenas uma camada. Ambos são algoritmos de treinamento por correção de erro, ou seja, o treinamento é do tipo supervisionado. A figura abaixo mostra um modelo de MLP:

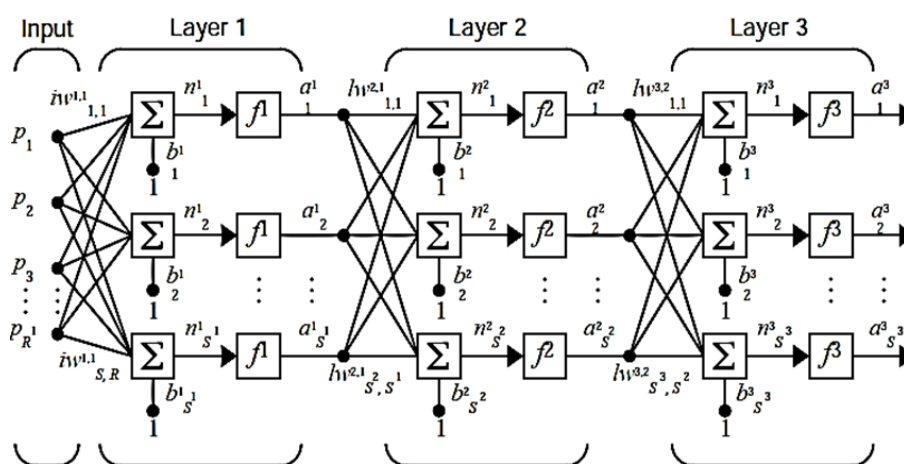


Figura 2 – Modelo de Rede MLP

Fonte: Adaptado de Demuth e Beale (2000)

O algoritmo de Retro propagação funciona basicamente em dois estágios: o estágio de propagação ou *forward* e o estágio de retro propagação ou *backward*.

Na fase de propagação ou *forward*, primeiramente uma entrada é aplicada à rede e este valor de entrada se propaga pela rede camada por camada, até ser produzida uma saída (ou um conjunto de saídas); durante a propagação *forward* os pesos sinápticos ficam fixos. Esta fase é utilizada para definir a saída da rede para um dado padrão de entrada. Durante a fase *forward*, segundo Moreira (2010), ocorre a propagação do vetor de treinamento e é durante este estágio que ocorre o cálculo do erro entre a saída obtida pela rede e a saída desejada.

A resposta produzida pela rede durante a propagação é subtraída de uma resposta desejada para o problema, assim é gerado um valor de erro. Durante a fase *backward* esse erro é retro propagado pela rede gerando uma atualização dos pesos sinápticos fazendo com que a resposta gerada fique o mais próximo possível da resposta desejada.

Terminado o ajuste dos pesos, o processo reinicia, assim fazendo com que o erro mínimo tenda a diminuir até que chegue ao valor especificado. O nome dado a este ciclo é época, toda vez que a rede completa um ciclo passando por todas as fases do algoritmo é dito que a rede completou uma época. O número de épocas é definido nas especificações da rede.

4. Materiais e Métodos

O estudo de caso desenvolvido abordou o setor de controle de qualidade da empresa X, onde foi observado controle de qualidade do produto específico. O estudo que será exposto a seguir se utilizou de um conjunto universo de 4142 amostras, sendo que destas 100 foram utilizadas para a criação de gráficos de controle. Esses dados foram coletados dos arquivos do setor de controle de qualidade e das planilhas de controle do setor de produção de salgadinhos da empresa X, esse conjunto de dados é referente às produções dos meses de julho, agosto e setembro de 2010. A manipulação dos dados foi feita a partir do software EXCEL e o desenvolvimento da RNA foi desenvolvido no software MATLAB.

A metodologia desta pesquisa foi desenvolvida em três etapas: a primeira voltada para o estudo das possíveis causas de variabilidade, o segundo para o desenvolvimento da RNA. A terceira etapa será destinada ao comparativo dos resultados alcançados com o desenvolvimento da rede neural artificial.

4.1 Estudo da variabilidade

Como qualquer processo produtivo, o processo de produção de salgadinhos sofre interferências do ambiente entre outros fatores que acabam por ocasionar certo nível de variabilidade, esta variabilidade é gerada por causas naturais e, portanto denominada variabilidade aleatória. Pequenas variações em diversas variáveis do processo que acabam por gerar pequenas variações no resultado deste.

No entanto o processo em estudo não se encaixa dentro deste perfil, pois a variabilidade dentro deste é considerada muito alta e pode ser causada por alterações em apenas uma ou mais variáveis inerentes ao processo. Este tipo de variabilidade é, portanto caracterizada como variabilidade gerada por causas especiais. Assim para tentar compreender as causas para a alta variação nos produtos foi feito um diagrama de causa e efeito, vulgo espinha de peixe, como pode ser observado a seguir:

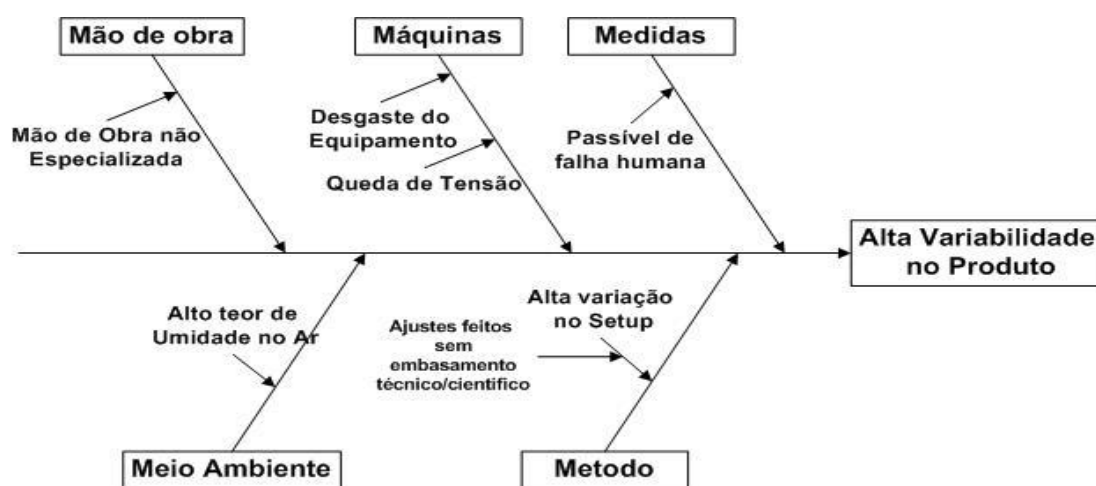


Figura 3 – Diagrama de Causa e Efeito.

Cada uma dessas causas será explicada a seguir:

Mão de Obra: A mão de obra utilizada não é especializada, não esta treinada para a resolução de problemas que podem gerar variabilidade na produção de forma eficiente. As praticas são voltadas apenas para o objetivo de produzir o produto e não produzir o produto da melhor

forma possível. Este fator é muito importante, pois demonstra que a mão de obra necessita de um conhecimento mais esclarecido a respeito processo em si. Esta pode ser considerada uma causa de grande influencia no estudo sobre a variabilidade observada.

A falta de especialização da mão de obra é uma grande fonte de incertezas nos processos de medição e coleta de dados, o fator humano se torna fundamental para a presença de dados incorretos, também denominados *outlayers* e também para a realização de ajustes indevidos no equipamento.

Matéria prima: Para este estudo foi selecionado apenas um tipo de produto, portanto não existe variação na matéria prima utilizada para a fabricação.

Medidas: As medidas podem ser consideradas como fontes de variabilidade devido ao fato de mão de obra não ser especializada, portanto as variáveis podem não ser medidas da forma correta ou mesmo devido à fadiga ou falta de atenção não serem coletadas de forma correta.

Meio Ambiente: O meio ambiente também é um fator decisivo para a variabilidade, o teor de umidade do ar na região norte do Brasil é muito alto e isso acaba interferindo no processo de fabricação, pois a área de fabricação não é um ambiente controlado. Esta variável acaba influenciando na variabilidade do teor de umidade do produto.

Máquinas: O equipamento pode ser considerado uma fonte de variabilidade, devido a falhas no processo ocasionadas pela quebra do equipamento e a quedas de tensão. A variabilidade causada por essas paradas é normalmente gerada pelo reajuste que deve ser feito no equipamento para dar continuidade à produção, no entanto esta fonte de variabilidade não é considerada um fator de alto impacto, pois os defeitos do equipamento e pela queda de tensão são aleatórias e, portanto incapazes de gerar uma variabilidade tão alarmante como a observada nos gráficos de controle.

Método: A principal causa para a variabilidade do produto final é o excesso de ajustes no SETUP do maquinário sem um embasamento técnico/científico. Esse excesso de ajustes é causado por diversos fatores como por exemplos as falhas mecânicas e queda de tensão, a necessidade de acelerar a produção, tentar diminuir o efeito da umidade no ar sob o produto entre outros, no entanto sem o entendimento do comportamento real de cada variável ajustada não é possível gerar um produto dentro das especificações.

4.2 Aplicação de RNAS

A princípio a rede neural foi aplicada como uma técnica de previsão, ou seja, a partir de dados passados se buscou descobrir qual seria o ajuste no maquinário adequado para a garantia do padrão de qualidade no produto escolhido. Como variável de controle foi utilizada o peso do produto em gramas, ou seja, a RNA será utilizada para prever o peso do produto.

A arquitetura de rede utilizada foi o Perceptron de Camada múltipla ou *Multilayer Perceptron*, ou seja, a rede utilizada é uma rede de camada múltipla totalmente conectada do tipo *Feedforward*. A função de ativação utilizada foi a função logística. O algoritmo de aprendizado utilizado foi o algoritmo de Retro Propagação, portanto o aprendizado foi do tipo supervisionado por correção de erro.

A aplicação de redes neurais artificiais foi feita seguindo os seguintes passos: desenvolvimento do grupo de treinamento, treinamento da rede neural e por fim o teste da rede. Assim cada fase do processo de desenvolvimento da rede neural artificial será explicada a seguir.

4.2.1 Criação dos Conjuntos de treinamento e Treinamento

Para a criação do conjunto de treinamento, primeiramente foram selecionadas as variáveis relacionadas ao SETUP e as variáveis de controle. As variáveis relacionadas ao SETUP são: Frequência do Dosador (Hz), Mescla apurada (%), Velocidade da esteira (RPM) e Temperatura do forno (°C). Estas variáveis serão consideradas entradas para a rede neural artificial. Como variável de saída será utilizada a variável PESO(g) como já foi dito.

Como dito anteriormente o número total de amostras coletadas para os testes foram de 4142. Para a rede T1 e T2 foram utilizados 4100 exemplos, 3800 compondo o conjunto de treinamento e 300 compondo o conjunto de teste. Este número de elementos foi escolhido devido a maior facilidade no processo de verificação dos resultados. Assim as redes utilizadas possuíam os seguintes parâmetros:

Rede T1:

- Número de elemento do conjunto de treinamento = 3800;
- Número de elemento do conjunto de teste = 300;
- Número de neurônios na camada intermediária = 400 (duas camadas de 200);
- Taxa de aprendizado = 0,1;
- Mínimo Erro Médio Quadrático = 0,001;
- Número de épocas = 1000.

Esta foi o primeiro modelo de rede utilizado, das redes criadas esta foi a que possuía o maior número de neurônios nas camadas intermediárias.

Rede T2:

- Variáveis de saída e entrada padronizadas;
- Número de elemento do conjunto de treinamento = 3800;
- Número de elemento do conjunto de teste = 300;
- Número de neurônios na camada intermediária = 300 (duas camadas de 150);
- Taxa de aprendizado = 0,1;
- Mínimo Erro Médio Quadrático = 0,001;
- Número de épocas = 1000.

Na arquitetura de rede T2, foi realizado um processo diferente. Nesta rede todas as variáveis tanto de entrada quanto de saída foram padronizadas utilizando a seguinte formulação matemática:

$$V_{\text{ajustado}} = \frac{V_i - V_{\min}}{V_{\max} - V_{\min}}$$

Onde:

- V_i é o valor observado;
- V_{\min} é o valor mínimo da matriz;
- V_{\max} é o valor máximo da matriz.

Rede T3:

- Variáveis de saída e entrada padronizadas;
- Numero de elemento do conjunto de treinamento =1000;
- Numero de elemento do conjunto de teste = 300;
- Numero de neurônios na camada intermediária =200;
- Taxa de aprendizado = 0,1;
- Mínimo Erro Médio Quadrático = 0, 0001;
- Numero de épocas = 20000.

Para o desenvolvimento desta rede foi necessário a utilização de um parâmetro para tratamento dos dados visto que as outras duas arquiteturas apresentavam uma dificuldade grande para o desenvolvimento do aprendizado. Esta dificuldade se deve presença de inúmeros *outlayers*. Para Corrar et. al, (2007) *outlayers* são anomalias geradas por falhas na coleta de dados, essas anomalias acabam gerando dados incorretos. Para minimizar o efeito dessas anomalias foi feito o seguinte:

Primeiramente o conjunto de 4000 amostras utilizado para os treinamento foi dividido em quatro subconjuntos de 1000 amostras, denominados conjuntos A, B, C e D. Após dividir os subconjuntos, cada conjunto foi treinado como uma rede com as mesmas especificações. Após treinar os quatro subconjuntos, foi possível observar que a rede gerada pelo subconjunto C foi a que possuía a alcançou o pior erro mínimo médio quadrático próximo a 0,01. As redes geradas pelos conjuntos B e D tiveram um desempenho semelhante ao da rede T2.

Como pode ser observada esta rede neural apresentou a melhor taxa de minimização de erro em comparação às demais, alcançando um erro mínimo médio quadrático próximo a 0,0001. Para testá-la foi utilizado um conjunto de 300 elementos formados da seguinte forma: 150 amostras provenientes do subconjunto B e 150 amostras provenientes do grupo D.

4.2.2 Resultados

Após a realização do treinamento as redes foram testadas, os testes foram realizados utilizando conjuntos denominados conjuntos de teste. Este conjunto de teste é formado por elementos que não foram utilizados no treinamento da rede neural, para testar a capacidade de generalização da rede.

Para realizar esta comparação é necessário que os elementos gerados pela rede sejam transformados de volta no seu valor original para tanto será utilizado a solução reversa da utilizada para padronizar a variável, sendo esta a seguinte:

$$V_{rev} = [V_i * (V_{max} - V_{min})] + V_{min}$$

Onde:

- V_i é o valor observado;
- V_{min} é o valor mínimo da matriz;
- V_{max} é o valor máximo da matriz.

Foram comparadas as taxas de acerto da rede neural com o conjunto de teste e como conjunto de treinamento utilizado. Assim foram encontrados os seguintes resultados:

Rede T1:

- Percentual de acerto da rede neural/ conjunto de teste = 15%
- Percentual de acerto da rede neural/ conjunto de treinamento = 48%

Como dito anteriormente esta rede foi a que apresentou a menor taxa de minimização de erro e também foi a que teve o pior desempenho. O baixo desempenho teve duas causas primárias a primeira foi a existência de *outlayers*. Esta rede neural não foi capaz de aprender o padrão ensinado.

Rede T2:

- Percentual de acerto da rede neural/ conjunto de teste = 35%
- Percentual de acerto da rede neural/ conjunto de treinamento = 65%

Esta rede apresentou um comportamento melhor que a de seu predecessor, pois apesar de apresentar uma taxa de minimização de erro semelhante esta rede neural foi capaz de generalizar. No entanto sua taxa de acerto foi prejudicada pela presença de *outlayers*.

Rede T3:

- Percentual de acerto da rede neural/ conjunto de teste = 60%
- Percentual de acerto da rede neural/ conjunto de treinamento = 95%

Esta rede apresentou o melhor comportamento em relação a todas as outras tendo uma taxa de acerto superior às demais, esta rede foi capaz de generalizar, porém esta ainda esta sujeita a presença de *outlayers* o que acaba interferindo na sua capacidade de acerto. A presença de dados incorretos acaba interferindo de forma decisiva no desempenho das redes desenvolvidas neste trabalho.

O gráfico abaixo mostra uma comparação entre as taxas de acerto das redes neurais:




Figura 4 – comparativo de Percentual de acerto entre as redes neurais em relação ao conjunto de teste.

5. Conclusão

Este trabalho teve seu estudo focado em uma instalação industrial de médio porte de produtos alimentícios. A indústria é responsável pela produção de produtos alimentícios do segmento *snacks* (salgadinhos de milho), de diversas gramaturas e sabores. Para este estudo foi selecionado o processo produtivo de salgadinhos de milho sabor queijo e gramatura 160 gramas. O objetivo do trabalho é desenvolver uma rede neural artificial capaz de aprender o comportamento das variáveis estudadas e conseguir prever um SETUP, ou seja, a configuração de maquinário que possa ser utilizado para a produção de um produto mais padronizado.

Com a análise dos resultados observados no capítulo anterior, das três redes neurais desenvolvidas a que apresentou o melhor resultado foi a terceira rede neural (T3-A). Apesar de possuir uma melhor capacidade de aprendizado comparada às demais redes neurais utilizadas, esta rede neural ainda não foi capaz de solucionar o problema proposto. Um percentual de acerto superior a 50% comprova a existência de um padrão no processo. Mesmo tendo um percentual de acerto baixo, isso indica que o problema proposto pode ser resolvido pela técnica de redes neurais artificiais, no entanto devem ser feitos estudos para melhorar a capacidade de aprendizado e verificar as possíveis causas para o baixo desempenho das redes neurais utilizadas neste estudo inicial.

O baixo desempenho das redes neurais pode ter sido ocasionado por diversos fatores, portanto é necessário o estudo destes. Uma das principais possíveis causas para o baixo desempenho das redes neurais é a presença de *outlayers*, apesar de alguns terem sido eliminados durante o processo de desenvolvimento da rede T3-A, nada assegura que ainda existam dados contraditórios no conjunto de treinamento ou de teste desta rede. Não é possível também definir o número ou percentual destes elementos na amostra e, portanto é difícil definir se os conjuntos de teste não são afetados por um grande número destes, assim é possível que o percentual de erro também esteja sendo alterado pela presença de *outlayers*.

O grande número de *outlayers* aponta para a provável segunda causa fundamental para o baixo desempenho, a coleta de dados. A presença de um grande número de dados contraditórios indica que a coleta de dados não foi efetuada da melhor forma possível. Como dito anteriormente a mão de obra não especializada é uma fonte primária para erros de medição e coleta de dados. Para trabalhos futuros existe a necessidade de um controle mais rigoroso na coleta de dados e nos processos de medição.

Outra possível causa para o baixo desempenho da rede neural pode ser devido a sua própria arquitetura, certos parâmetros como a taxa de aprendizado não foram alterados e se mantiveram constantes em 0,1 em todas as redes neurais, assim como outros parâmetros que poderiam ser modificados. Ainda estudando as causas que podem ter origem no próprio desenvolvimento da rede está a seleção de variáveis para a criação dos grupos de treinamento e de teste.

É possível que outras técnicas de modelagem se adéquem melhor ao tipo de relação observada, como por exemplo, a regressão logística. Estas suposições poderão ser aplicadas e testadas em estudos posteriores derivados deste trabalho. Como um todo o trabalho, apesar de

não ter conseguido alcançar o objetivo principal, conseguiu comprovar as hipóteses afirmadas. A variabilidade percebida é gerada por causas especiais, esta é gerada pelos ajustes constantes no ajuste do maquinário, e apesar de não ter alcançado resultados satisfatórios uma rede neural pode aprender o padrão do processo.

Referências

ALBERTAZZI, Armando; SOUSA, André. **Fundamentos de Metrologia Científica e Industrial**. 1. ed. São Paulo: Manole, 2008.

BRAGA, A.P; CARVALHO, A.F.; LUDERMIR, T.B.. **Redes Neurais Artificiais: teorias e aplicações**. 2.ed. Rio de Janeiro: LTC, 2007.

CORRAR, L.J.; PAULO, Edilson; FILHO, J. M. **Análise Multivariada: para os cursos de administração, ciências contábeis e economia**. 1 ed. São Paulo: Atlas, 2007.

DEMUTH, H. BEALE, M. **Neural Network Toolbox**, 6.ed.Mathwork Inc,2000.

FALCONI, V.C. **Controle da Qualidade Total (no estilo japonês)**. 6 ed. Rio De janeiro: Bloch Ed, 1992.

HAYKIN, Simon. **Redes Neurais - Princípios e Práticas**. 2 ed.Porto Alegre: Bookman, 2001.

MONTGOMERY, D.C. **Introdução ao controle estatístico da qualidade**. 4. Ed., Rio de Janeiro: LTC, 2004.

MARTINS, R.A. **Conceitos básicos de controle estatístico de qualidade**. 1. Ed. São Carlos: EdUFSCar, 2010.

MOREIRA, F.C. **Redes Neurais Artificiais: Uma visão prática para Engenharia de Produção**. Belém: Centro Universitário do Pará - CESUPA, 2010. 98 slides: color.

SHEWHART, W. **Statistical method: from the viewpoint of quality control**. Washington: Dover,1986.

WERKEMA, M.C.C. **As ferramentas da qualidade no gerenciamento de processos**, 3.ed. Belo Horizonte, MG: Fundação Christiano Ottoni, Escola de Engenharia da UFMG, 1995.