

UNIVERSIDADE METODISTA DE PIRACICABA
FACULDADE DE ENGENHARIA ARQUITETURA E URBANISMO
PROGRAMA DE PÓS GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

MODELO PARA A PREDIÇÃO DO DESGASTE EROSIVO DE
REVESTIMENTOS UTILIZANDO REDES NEURAIS E
TENACIDADE À FRATURA

JOEL ALVES BATISTA

ORIENTADOR: PROF. DR. CARLOS ROBERTO CAMELLO LIMA

SANTA BÁRBARA D'OESTE

Fevereiro / 2016

UNIVERSIDADE METODISTA DE PIRACICABA
FACULDADE DE ENGENHARIA ARQUITETURA E URBANISMO
PROGRAMA DE PÓS GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

**MODELO PARA A PREDIÇÃO DO DESGASTE EROSIVO DE
REVESTIMENTOS UTILIZANDO REDES NEURAIS E
TENACIDADE À FRATURA**

JOEL ALVES BATISTA

ORIENTADOR: PROF. DR. CARLOS ROBERTO CAMELLO LIMA

Tese apresentada ao Programa de Pós-Graduação em Engenharia de Produção da Faculdade de Engenharia, Arquitetura e Urbanismo da Universidade Metodista de Piracicaba UNIMEP, como requisito para obtenção do título de Doutor em Engenharia de Produção.

SANTA BÁRBARA D'OESTE

Fevereiro / 2016

**MODELO PARA A PREDIÇÃO DO DESGASTE EROSIVO DE
REVESTIMENTOS UTILIZANDO REDES NEURAIS E
TENACIDADE À FRATURA**

JOEL ALVES BATISTA

Tese de Doutorado defendida e aprovada em 26 de fevereiro de 2016 pela banca examinadora, constituída pelos professores:

Prof. Dr. Carlos Roberto Camello Lima-Orientador
PPGEP – UNIMEP

Prof. Dr. Aparecido dos Reis Coutinho
PPGEP – UNIMEP

Prof^a. Dr^a. Claudia Hespanholo Nascimento
PPGEP – UNIMEP

Prof. Dr. Hipólito D. Carvajal Fals
UO - Universidade de Oriente – Cuba

Prof. Dr. Paulo Villani Marques
UFMG – Universidade Federal de Minas Gerais

Ficha Catalográfica elaborada pelo Sistema de Bibliotecas da UNIMEP
Bibliotecária: Marjory Harumi Barbosa Hito CRB-8/9128

Batista, Joel Alves

B333m Modelo para a predição do desgaste erosivo de revestimentos
utilizando redes neurais e tenacidade à fratura/ Joel Alves Batista. –
2016.

123 f.:il ;30cm

Orientador: Prof. Dr. Carlos Roberto Camello Lima
Tese (doutorado) – Universidade Metodista de Piracicaba,
Engenharia de Produção, Santa Bárbara d'Oeste, 2016.

1 Industrias. 2 Desgaste. I. Lima, Carlos Roberto Camello. II.

Título.

DOU – 621.004.62

AGRADECIMENTOS

A Deus, pelo infinito amor e cuidados dispensados a mim em toda minha vida.

A minha família, pelo incentivo, apoio, amor e paciência.

Ao Professor Doutor Carlos Roberto Camello Lima, pela oportunidade de trabalho, incentivo, orientação, liberdade, compreensão e paciência em todos os momentos do projeto, bem como pelo conhecimento compartilhado e apoio dispensado.

Aos demais professores da UNIMEP, que contribuíram decisivamente com conhecimentos valiosos para que este trabalho pudesse ser realizado.

À Universidade Estadual do Maranhão – UEMA, pela liberação e apoio para execução do trabalho em outra unidade da federação.

Ao Professor Doutor Hipólito Domingo Clavajal Fals, ao Professor Doutor Angel Sanchez Rocca, ao Professor Doutor Mario César Sánchez Orozco, ao Professor Mestre Miguel Angel Reyes Mojena e aos demais professores e funcionários da Faculdade de Engenharia Mecânica da Universidade de Oriente - UO, em Cuba, que contribuíram com oportunidade de trabalho de pesquisa, a despeito de todas as dificuldades.

Em nome de Osbel Gutierrez Pillar, Mirelys Gutierrez e toda família Betel, agradeço a fabulosa experiência que me propiciaram em Santiago de Cuba, em Cuba.

À CAPES, pela bolsa concedida no doutorado (PROSUP) e pela bolsa concedida no projeto 131/11 - MES/Cuba.

A todos aqueles que, direta ou indiretamente, contribuíram para a conclusão deste trabalho.

**Para Yolanda Gomes de Oliveira Batista, Lucas Gomes de Oliveira Batista,
Rebeca Gomes de Oliveira Batista e Deborah Gome de Oliveira Batista.**

**O sábio é mais poderoso do que o forte e o inteligente do que o que
possui a força.**

Provérbio de Salomão.

LISTA DE FIGURAS

Figura1– Esquema da camada aspergida sobre o substrato.....	24
Figura 2 - Pistola de aspersão térmica.....	27
Figura 3 -Esquema da deposição das partículas por aspersão térmica.....	27
Figura 4- Imagem da pistola do processo HVOF.....	33
Figura 5 -Imagem de uma pistola HVOF em operação.....	33
Figura 6 – Modelo de um neurônio artificial de McCulloch.....	39
Figura 7– Esquema do aprendizado supervisionado.....	43
Figura 8 – Esquema do aprendizado não supervisionado.....	44
Figura 9 – Neurônio com função de ativação não linear.....	47
Figura 10 – Esquema de uma rede neural MLP.....	48
Figura 11- Linhas de curvas de uma rede RBF.....	50
Figura 12 – Arquitetura de uma rede neural de função de base radial.....	51
Figura 13 – Representação de uma rede <i>feedforward</i>	58
Figura 14 – Imagens de microscopia electrónica de varredura (MEV) do pó usado no processo HVOF.....	67
Figura 15 - Materiais para depositados na forma de cordões flexíveis.....	68
Figura 16 – Micrografia da seção transversal dos cordões flexíveis dos materiais aspergidos pelo processo de aspersão FS/FC.....	69
Figura 17– Metodologia de desenvolvimento da rede neural do modelo proposto.....	77

Figura 18 - Topologia da rede neural.....	94
Figura 19 - Curvas do erro durante o treinamento com o algoritmo de Levenberg-Marquardt.....	95
Figura 20- Análise comparativa entre os valores reais e os obtidos pela RNA.....	97
Figura 21- Recobrimento com RocDur62: a) antes do processo de erosão; b) depois do processo de erosão.....	98
Figura 22- Mostra a superfície de resposta da eficiência de desgaste para o modelo da literatura e o proposto por redes neurais e o processo HVOF.....	99
Figura 23- Mostra a superfície de resposta da eficiência de desgaste para o modelo da literatura e o proposto por redes neurais e o processo FS/FC.....	101
Figura 24- Gráfico mostra a superfície de resposta da eficiência de desgaste em função da velocidade e do ângulo de impacto.....	103
Figura 25- Superfície de resposta da eficiência de desgaste com ângulo de impacto	104
Figura 26- mostra a superfície de resposta da eficiência de desgaste em função da velocidade das partículas.....	104

LISTA DE QUADROS

Quadro 1- Relaciona a tipos de desgaste com descrição dos mesmos.....	15
Quadro 2 - Relaciona os principais mecanismos de desgaste erosivo.....	16
Quadro 3 - Processo de aspersão e fontes de calor.....	25
Quadro 4 - Tipos de função de ativação mais utilizadas em modelos de RNA.....	46
Quadro 5- Fatores experimentais para o planejamento de experimentos.....	71

LISTA DE GRÁFICOS

Gráfico 1- Influência do ângulo de impacto na taxa de erosão do alumínio e da alumina com partículas de SiC a $152ms^{-1}$	09
Gráfico 2 – Influência da taxa de erosão do cobre em função da velocidade de impacto das partículas.....	10
Gráfico 3 – relação da concentração de partículas com a taxa de desgaste...	14
Gráfico 4 Mostra o comportamento do desgaste, com ângulo de 30° , velocidade de 3,61m/s e 9,33m/s dos materiais 88HV, aplicados com o processo HVOF e 15HC aplicados com o processo FS/FC, correspondente à Tabela 7.....	80
Gráfico 5 - Gráfico mostra o comportamento do desgaste, correspondente à Tabela	81
Gráfico 6 - Gráfico com o comportamento do desgaste, da tabela 9 a um ângulo de 30°	82
Gráfico 7 - Gráfico com o comportamento do desgaste, da tabela 10 a um ângulo de 30°	83
Gráfico 8- Gráfico com o comportamento do desgaste, correspondente à tabela 11 a um ângulo de 30°	84
Gráfico 9 – Mostra o comportamento de desgaste erosivo por meio da comparação dos processos velocidade e materiais.....	85

Gráfico 10 - Gráfico com o comportamento do desgaste, correspondente à tabela 13 a um ângulo de 90°.....	86
Gráfico11- Gráfico com o comportamento do desgaste, correspondente à tabela 14 a um ângulo de 90°.....	86
Gráfico12 - Gráfico com o comportamento do desgaste, correspondente à tabela 15, com ângulo de 90°, aplicados com os processos HVOF e FS/FC....	87
Gráfico13 - Gráfico com o comportamento do desgaste, correspondente à tabela 16 com ângulo de 90°, aplicados com os processos HVOF e FS/FC.....	88
Gráfico14 - Gráfico com o comportamento do desgaste, correspondente à tabela 17 a um ângulo de 90°.....	89
Gráfico 15 - Valores de perda de massa de amostras para as condições estudadas e velocidade 3,61m/s e ângulo de partículas 30°.....	90
Gráfico 16 - Valores de perda de massa das amostras para as condições do experimento com velocidade 3,61 e partículas com ângulo de impacto 90°....	91
Gráfico 17- Valores de perda de massa das amostras para as condições experimentais com ângulo de impacto de partículas com 30° e velocidade de 9,33 m/s.....	91
Gráfico 18 - Valores de perda de massa das amostras para as condições experimentais com ângulo de impacto de partículas com 90° e velocidade de 9,33 m/s.....	92

LISTA DE TABELAS

Tabela 1 – Materiais utilizados nos processos FS/FC e HVOF.....	06
Tabela 2 - mostra os materiais e os processos utilizados para aquisição de dados na pesquisa.....	66
Tabela 3 – Materiais, composição química e densidade dos pós depositados pelo processo HVOF.....	67
Tabela 4 - Composição química e densidade dos materiais depositados pelo processo FC/FS.	69
Tabela 5: Saída do <i>Past</i> com a contribuição dos fatores para a variação das médias na ANOVA.....	78
Tabela 6 – Dados dos ensaios de desgaste erosivo dos materiais 88HV e 15HC com ângulo de 30°, velocidade de 3,61m/s e 9,33m/s, aplicados com o processo HVOF e FS/FC.....	79
Tabela 7 – Dados dos ensaios de desgaste erosivo dos materiais 1350, com ângulo de 30°, velocidade de 3,61m/s e 9,33m/s, aplicados com o processo HVOF e FS/FC.....	80
Tabela 8 – Dados de desgaste dos materiais 7525 a velocidade de 3,61m/s e 9,33m/s, aplicados com os processos HVOF e FS/FC.....	81

Tabela 9. Dados dos ensaios de desgaste erosivo dos materiais 8812 com ângulo de 30°, velocidade de 3,61m/s e 9,33m/s, aplicados com os processos HVOF e FS/FC.....	82
Tabela 10. Dados dos ensaios de desgaste erosivo dos materiais Durmat com ângulo de 30° velocidade de 3,61m/s e 9,33m/s, aplicados com os processos HVOF e FS/FC.....	83
Tabela 11 – Dados de desgaste dos materiais 88HV, aplicados com o processo HVOF e 15HC, aplicados com o processo FS/FC, aplicados com a velocidade de 9,33m/s, com ângulo de 90°.....	85
Tabela 12- Dados de desgaste dos materiais 1350 com velocidade 9,33 m/s..	86
Tabela 13- Dados de desgaste dos materiais 7525 com velocidade 9,33m/s...	87
Tabela 14–Dados de desgaste dos materiais 8812 com velocidade 9,33m/s..	88
Tabela 15 – Dados de desgaste dos materiais Durmat, a uma velocidade de 3,61m/s e 9,33m/s com os processos HVOF e FS/FC.....	89
Tabela16 – Mostra os dados da eficiência de desgaste obtida pelo modelo proposto na literatura e pelo modelo de redes neurais, a partir dos dados experimentais, para os processos HVOF.....	99
Tabela17 – Mostra os dados da eficiência de desgaste obtida pelo modelo proposto na literatura e pelo modelo de redes neurais, a partir dos dados experimentais, para os processos FS/FC.....	101

LISTA DE ABREVIATURAS E SIGLAS

Al – Alumínio

ASTM – *American Society for Testing and Materials*

AWS - *American Welding Society*

CAPES – Coordenação de Aperfeiçoamento de Pessoal de Nível Superior

CERMET – Carbonetos cerâmicos em matrizes metálicas

DFV - Deposição Física de Vapor

DQV - Deposição Química de Vapor

E_r = Taxa de Desgaste

FS/FC – *Flame Spray/FlexiCord*

HVOF - *High Velocity Oxygen Fuel*

K_c = Tenacidade à Fratura

LMBP - Levenberg – Marquardt *Back – Propagation*

MATLAB – Laboratório de Matriz

MEV - Microscopia Eletrônica de Varredura

MLP – *Mult Layer Perceptron*

RBF – *Radial Basis Function*

R^2 – Coeficiente de Determinação

RGNN – *Generalized Regression Neural Network*

RNA – Rede Neural Artificial

SiC – Carboneto de Silício

UO – Universidade de Oriente

UEMA – Universidade Estadual do Maranhão

UNIMEP – Universidade Metodista de Piracicaba

UNICAMP – Universidade Estadual de Campinas

WC-CoCr - Carboneto de Tungstênio Cobalto Cromo

BATISTA, Joel Alves. **MODELO PARA A PREDIÇÃO DO DESGASTE EROSIVO DE REVESTIMENTOS UTILIZANDO REDES NEURAIS E TENACIDADE À FRATURA**. 2016. Tese (Doutorado em Engenharia de Produção) – Faculdade de Engenharia, Arquitetura e Urbanismo, Universidade Metodista de Piracicaba, Santa Bárbara d'Oeste (SP).

RESUMO

Na indústria metal mecânica, muitos componentes estão submetidos a processos de desgaste superficial. O desgaste é um dos principais problemas industriais que levam à substituição de componentes e equipamentos em engenharia, sendo o desgaste erosivo uma de suas mais comuns manifestações. Encontrar condições de operações e propriedades dos materiais contra o desgaste é de suma importância para a indústria. Uma das propriedades mecânicas mais importantes de um material é a sua dureza. Mas, ela é incapaz de, isoladamente, fornecer proteção contra o desgaste. Por isso, a tenacidade à fratura tem sido utilizada e tem se revelado adequada, e a combinação dela com a dureza deverá refletir a eficiência com a qual o volume de desgaste erosivo é determinado. A taxa de desgaste erosivo depende de vários parâmetros e determinar a influência de cada um deles na taxa de desgaste é uma tarefa desafiadora, o que tem exigido uma abordagem por meio de métodos numéricos, dentre eles as redes neurais artificiais-RNA. Neste sentido, este trabalho propôs um modelo matemático, baseado em redes neurais artificiais, para prever a evolução da eficiência de desgaste erosivo em revestimentos aplicados por aspersão térmica a chama convencional (FS/FC) e a chama oxi-combustível de alta velocidade (HVOF). Os resultados

demonstram que existe uma relação quase linear entre os valores do modelo proposto e os valores reais da proposta de eficiência do modelo da literatura. Portanto, o modelo proposto pode determinar a eficiência de desgaste e, assim, determinar o comportamento do desgaste erosivo.

Palavras-chave: Aspersão Térmica; Modelagem; Desgaste erosivo; Processo de desgaste; Redes Neurais Artificiais.

BATISTA, Joel Alves, *Model for the Prediction of Erosive Wear of Coatings Using Artificial Neural Networks and Fracture Toughness*. 2016. Tese (Doutorado em Engenharia de Produção) – Faculdade de Engenharia, Arquitetura e Urbanismo, Universidade Metodista de Piracicaba, Santa Bárbara D'oeste (SP).

ABSTRACT

In the metalworking industry, many components are subjected to surface wear processes. Wear is one of the major industrial problems that lead to replacement components and equipment engineering, and the erosive wear one of its most common manifestations. Find operating conditions and material properties against wear is very important for the industry. One of the most important mechanical properties of a material is its hardness. But she is unable to alone provide protection against wear. Therefore, the fracture toughness has been used and has proved suitable and combining it with the hardness should reflect the efficiency with which the volume of erosive wear is determined. The erosive wear rate depends on various parameters and determining the influence of each one on the wear rate is a challenging task, which has required an approach by means of numerical methods, including artificial neural networks. Thus, this work proposes a mathematical model based on artificial neural networks to predict the evolution of erosive wear efficiency of coatings applied by flame spray (FSFC) and High Velocity Oxygen Fuel (HVOF) spray. The results demonstrate that there is an almost linear relationship between the model and actual values of efficiency in literature model. Therefore, the

proposed model can determine the efficiency and wear, thereby determining the behavior of erosive wear.

Keywords: Thermal Spraying; Modeling; Erosive wear; Process wear; Artificial neural networks.

SUMÁRIO

LISTA DE FIGURAS.....	VI
LISTA DE QUADROS.....	XIII
LISTA DE GRÁFICOS.....	IX
LISTA DE TABELAS.....	XI
LISTA DE ABREVIATURAS SIGLAS.....	XIII
RESUMO.....	XV
ABSTRACT.....	XVI
SUMÁRIO.....	XVII
1. INTRODUÇÃO.....	1
1.1. CONTEXTUALIZAÇÃO.....	1
1.2. PROBLEMA DE PESQUISA	3
1.3. OBJETIVO DA PESQUISA.....	4
1.4. JUSTIFICATIVA DA PESQUISA.....	4
1.5. RESULTADOS ESPERADOS.....	5
1.6. MÉTODO DE PESQUISA.....	5
1.7. DELIMITAÇÃO DA PESQUISA.....	6
1.8. ESTRUTURA GERAL DA TESE.....	7
2. DESGASTE	8
2.1. REVISÃO DA LITERATURA.....	8
2.2. DEFINIÇÃO DE DESGASTE.....	8
2.2.1. DESGASTE ABRASIVO.....	11
2.2.2. DESGASTE CORROSIVO.....	11
2.2.3. DESGASTE ADESIVO.....	12
2.2.4. DESGASTE POR FADIGA SUPERFICIAL.....	12
2.2.5. DESGASTE EROSIVO.....	12
2.3. MECANISMOS DE DESGASTE EROSIVO.....	16

2.4. PARÂMETROS QUE AFETAM O DESGASTE EROSIVO.....	16
2.4.1 ÂNGULO DE IMPACTO.....	17
2.4.2. VELOCIDADE DAS PARTÍCULAS SÓLIDAS.....	17
2.4.3. TAMANHO E FORMA DA PARTÍCULA.....	17
2.4.4. CONCENTRAÇÃO DAS PARTÍCULAS SÓLIDAS.....	18
2.4.5. DUREZA	18
2.4.6. TENACIDADE À FRATURA.....	18
2.5. MODIFICAÇÃO DE SUPERFÍCIE.....	20
2.5.1 DEPOSIÇÃO FÍSICA DE VAPOR.....	22
2.5.2. DEPOSIÇÃO QUÍMICA DE VAPOR.....	22
2.5.3. GALVANOPLASTIA.....	22
2.5.4. ASPERSÃO TÉRMICA	23
2.5.4.1. PROCESSOS DE ASPERSÃO TÉRMICA.....	26
2.5.4.1.1. CHAMA CONVENCIONAL OU FLAME SPRAY- FS.....	26
2.5.4.1.2. ASPERSÃO A CHAMA FLEXICORDS – FC.....	28
2.5.4.1.3. ASPERSÃO <i>HIGH VELOCITY OXYGEN FUEL</i> (HVOF).....	31
3. REDES NEURAIS ARTIFICIAIS – RNA.....	36
3.1. CONCEITOS E DEFINIÇÕES	37
3.2. HISTÓRICO DAS REDES NEURAIS ARTIFICIAIS.....	38
3.3. APRENDIZADO.....	42
3.3.1. APRENDIZADO SUPERVISIONADO.....	42
3.3.2. APRENDIZADO NÃO SUPERVISIONADO.....	43
3.4. REDES PERCEPTRON MULTICAMADAS – MLP.....	46
3.5. REDES NEURAIS DE FUNÇÃO DE BASE RADIAL - RBF.....	48
3.6. TREINAMENTO DE UMA REDE NEURAL.....	55
3.6.1. TREINAMENTO DE REDES <i>FEEDFORWARD</i>	56
3.6.2. TREINAMENTO COM ALGORITMO DE RETRO PROPAGAÇÃO..	58
3.6.3. TREINAMENTO COM ALGORITMO MÍNIMOS QUADRADOS	62

3.7. REDES NEURAS PARA À PREDIÇÃO DO COMPORTAMENTO DO DESGASTE EROSIVO.....	63
4. MATERIAIS E MÉTODOS	66
4.1 MATERIAIS UTILIZADOS NA PESQUISA.....	66
4.2 O PROCESSO DE ASPERSÃO HVOF E MATERIAL DE RECOBRIMENTO.....	67
4.3 O PROCESSO DE ASPERSÃO A CHAMA -FC / FLEXICORDS -FS E MATERIAL DE RECOBRIMENTO.....	68
4.4 PROCEDIMENTOS EXPERIMENTAL PARA O PLANEJAMENTO...70	
4.5. ANÁLISE ESTATÍSTICA	72
4.6. REDES NEURAS – RNA.....	72
5. RESULTADOS E DISCUSSÃO.....	78
5.1 RESULTADOS DO PROJETO EXPERIMENTAL.....	78
5.2 MODELO COM APLICAÇÃO DAS REDES NEURAS	93
6. CONCLUSÃO E SUGESTÕES PARA TRABALHO FUTURO...106	
6.1. CONCLUSÃO.....	106
6.2. SUGESTÕES PARA TRABALHOS FUTUROS.....	108
7. REFERÊNCIAS.....	110

1. INTRODUÇÃO

O capítulo de introdução apresenta a contextualização do trabalho, o problema de pesquisa, o objetivo, a justificativa, a relevância de se pesquisar o tema e a estrutura geral da tese.

1.1. CONTEXTUALIZAÇÃO

Nos processos industriais, as condições de operação estão sujeitas às variações ao longo do tempo. Controlar um processo significa atuar sobre ele, ou sobre as condições na qual ele está inserido, de modo a atingir um objetivo. As condições de operações a que estão submetidas peças e equipamentos exigem proteção contra o desgaste, a fadiga e a corrosão, que são três dos principais problemas no setor industrial. Dentro desse contexto, a capacidade de prever as condições ótimas de operação e a duração da vida de peças e equipamento é de grande utilidade para a indústria e tem atraído a atenção de muitos pesquisadores (PONTES, 2006; CONTRUCCI, 2012).

Nas indústrias, peças e equipamentos são afetados pelo desgaste. O desgaste é a perda progressiva de material devido ao movimento relativo, está relacionado com interações entre as superfícies e, mais especificamente, com a remoção e deformação do material de uma superfície como resultado da ação mecânica da superfície oposta (FLEICHER, 1988; SHARMA *et al.*, 2015).

Componentes metálicos ou não metálicos que estejam sujeitos ao desgaste podem ser protegidos pela modificação de sua superfície. A modificação de superfície é um termo genérico de um grande campo de tecnologias, que podem ser aplicadas para alcançar maior confiabilidade em programas de manutenção, incrementar o desempenho de componentes industriais, com o intuito de aumentar sua disponibilidade e o tempo de vida em operação (LIMA e TREVISAN, 2007).

Avanços consideráveis no campo da tecnologia de revestimentos têm acompanhado o crescente potencial da engenharia de superfície no mundo industrial moderno. Como consequência, há um número considerável de processos para o desenvolvimento de uma ampla variedade de revestimentos protetores, tanto em termos de encontrar as melhores soluções, quanto oferecer qualidade e custo competitivos, aumentando, assim, a disponibilidade de processos capazes de depositar uma grande variedade de revestimentos em componentes nas mais diversas geometrias (ZOIS *et al.*, 2013; NGUYEN *et al.*, 2014).

Dentre os muitos processos disponíveis para revestir e proteger superfícies de peças e componentes, encontram-se os processos de aspensão térmica *Flame Spray/FlexiCord* (FS/FC) e *High Velocity Oxygen Fuel* (HVOF). A utilização destes processos visa a modificar a superfície de um componente pela aplicação de uma camada de material metálico ou não metálico, sobre sua superfície, para conferir melhoria em suas propriedades, como, por exemplo, maior capacidade térmica, dureza ou aumento da tenacidade (WANG *et al.*, 2013).

A dureza é uma das propriedades mecânicas mais importantes de um material. Mesmo assim, ela é incapaz de isoladamente fornecer proteção contra o desgaste. Por isso, outra propriedade deve ser utilizada para conferir esta proteção. A tenacidade à fratura tem se revelado adequada e a combinação dela com a dureza deverá refletir a eficiência com a qual o volume de desgaste erosivo é determinado (SUNDARARAJAN *et al.*, 1990; ZHONG *et al.*, 2014).

Compreender o comportamento dos materiais quanto ao desgaste erosivo, permite escolher, adequadamente, processos de revestimento, materiais para proteção de superfície de peças e, assim, melhorar a expectativa de vida de equipamentos, otimizar sistemas de produção com vistas a suprir as exigências de operação em um mercado cada vez mais exigente.

1.2. PROBLEMA DE PESQUISA

Existem modelos para determinar o comportamento do desgaste erosivo, como o proposto por Hitchings (1981), no qual a taxa de erosão de metais por partículas sólidas depende fortemente do ângulo com o qual as partículas incidem na superfície do substrato; o proposto por Sundararajan *et al.* (1990), que introduz o conceito de eficiência de desgaste, com o propósito de fazer a classificação de materiais em dúcteis e frágeis; o proposto por Zhang *et al.* (2015), que investigou os efeitos de parâmetros de processamento, condições de temperatura de deformação, tensão residual, velocidade de resfriamento e estabeleceu um modelo baseado na análise de regressão múltipla, a fim de desenvolver o modelo da relação entre microestrutura e propriedades dos materiais aspergidos.

Para Siddhartha (2013), no entanto, a compreensão plena dos mecanismos responsáveis pelo desgaste erosivo está longe de ser completamente alcançada.

Os modelos mencionados não fornecem uma compreensão definitiva dos mecanismos de desgaste, mas induzem ao cenário de pesquisa em que:

- Os trabalhos sobre modelos matemáticos para apoiar a modificação de superfície estão aumentando ano a ano, envolvendo parâmetros do processo e variáveis cada vez mais complexas (KHALAJ, 2013);
- Poucos trabalhos correlacionam investigações experimentais com a modelagem matemática sobre o comportamento dinâmico dos processos de aspersão térmica (ALAVI *et al.*, 2012);

Neste sentido, a hipótese que se impõe é a de que a modelagem matemática pode contribuir para entendimento do comportamento do processo de desgaste erosivo e, assim, permitir a aplicação de revestimentos feitos pelos processos de aspersão térmica *High Velocity Oxygen Fuel* (HVOF) e *Flame Spray/FlexiCord* (FS/FC).

1.3. OBJETIVO DA PESQUISA

Este trabalho tem como objetivo geral propor um modelo para a predição do desgaste erosivo de revestimentos aplicados por aspersão térmica, utilizando redes neurais artificiais e tenacidade à fratura.

Para atingir o objetivo geral, os seguintes objetivos específicos foram identificados:

- Formular um modelo matemático usando redes neurais artificiais, para ajustar os dados experimentais, por meio da inclusão da tenacidade à fratura K_c , do fator tempo de ensaio t , dos processos HVOF e FS/FC e exclusão da taxa de desgaste E_r , no modelo de eficiência de desgaste, consolidado na literatura, proposto por Patnaik *et al.* (2010).
- Utilizar os dados experimentais de desgaste erosivo de revestimentos aplicados por aspersão a chama convencional com cordões flexíveis (FS/FC), e por aspersão a chama de alta velocidade (HVOF), utilizando pós, para a construção do modelo.
- Comparar a resposta do modelo matemático proposto por redes neurais com a resposta do modelo de eficiência de desgaste erosivo, proposto por Patnaik *et al.* (2010), com o propósito de validá-lo.

1.4. JUSTIFICATIVA DA PESQUISA

Há, na literatura, a concordância de que é necessária uma compreensão mais profunda dos processos de aspersão térmica, de seus parâmetros, das propriedades dos materiais e interações partícula-substrato para aplicação dos revestimentos com qualidade e desempenho para aplicações específicas (LYPHOUT, 2013; THIRUVIKRAMAN *et al.*, 2014).

Uma das razões que justifica este trabalho reside, portanto, na proposta de um novo modelo para calcular a eficiência de desgaste por meio da modificação de

modelo consolidado na literatura, proposto por Patnaik *et al.*, (2010) e validá-la com uma rede neural artificial.

Este trabalho também se justifica pela necessidade de gerar conhecimento em uma área promissora como a engenharia de superfície, apesar da difícil tarefa de estabelecer uma correlação entre o comportamento não linear dos processos de aspersão térmica, de modo a conduzir a aplicações práticas que levem ao desenvolvimento de soluções eficientes.

1.5. RESULTADOS ESPERADOS

Espera-se formular a expressão do modelo matemático usando inteligência artificial, para ajustar os dados experimentais de desgaste substituindo a taxa de desgaste E_r , pela tenacidade à fratura K_c , o fator tempo t e o processo HVOF e FS/FC, usando os dados de tenacidade e desgaste obtidos de trabalho experimental realizado em uma pesquisa simultânea, dentro do mesmo projeto mãe, coordenada por outro pesquisador, que possa oferecer uma previsão da eficiência de desgaste, possibilitando entendimento necessário ao desenvolvimento de aplicações adequadas em situação real de produção.

1.6. MÉTODO DE PESQUISA

A pesquisa é um conjunto de ações, propostas para encontrar a solução de um problema, que têm por base procedimentos racionais e sistemáticos e podem ser classificados quanto a sua **natureza, abordagem, objetivos e procedimentos técnicos** (CAUCHICK, 2011).

De acordo com esta classificação, este trabalho se enquadra nos seguintes aspectos: quanto à natureza, trata-se de uma pesquisa **aplicada**; quanto à

abordagem, **quantitativa**; quanto aos objetivos, **explicativa**; quanto aos procedimentos técnicos, **experimental e exploratória**.

1.7. DELIMITAÇÃO DA PESQUISA

Os dados experimentais do desgaste erosivo, utilizados nesta pesquisa, foram propostos por Reyes (2015) e os dados de tenacidade à fratura foram os propostos por Orozco (2015). Os materiais utilizados nos experimentos de desgaste e de tenacidade à fratura estão relacionados na Tabela 1, tendo sido escolhidos em função da importância que desempenham em aplicações industriais. Os processos de aspersão térmica ali utilizados foram HVOF e FS/FC.

Tabela 1. Materiais utilizados nos revestimentos aplicados pelos processos HVOF e FS/FC

HVOF			FS/FC	
Material (pó)	Tamanho (μm)	Densidade g/cm^3	Material (cordão flexível)	Densidade g/cm^3
Colmonoy 88HV (Hasteloy)	5/10	4,78	HardKarb 15HC D4.75 (Hasteloy)	13,30
1350VM/WC-731-1	-45/+15	5,02	HardKarb 1350	13,30
Amperit Cr ₃ C ₂ NiCr75-25	-45/+15	2,90	KhromKarb Fine (75CrCo/25NiCr)	7,10
Amperit WC-Co88-12	-45/+15	3,90	HardKarb 12Co-F D4.75	13,70
Durmat 135.015	-25/+10	5,46	Roc Dur 62	8,20

1.8. ESTRUTURA GERAL DA TESE

Na introdução, é apresentado o trabalho de pesquisa, composto pela contextualização, objetivo, justificativa, resultado esperado, procedimento metodológico e estrutura do trabalho.

O Capítulo 2 apresenta a revisão da literatura concernente ao desgaste e desgaste erosivo;

O Capítulo 3 apresenta a revisão da literatura sobre redes neurais artificiais;

No Capítulo 4, são descritos os materiais e métodos utilizados na pesquisa;

O Capítulo 5 é destinado à apresentação do modelo e análise dos resultados e discussão dos mesmos;

No Capítulo 6, são apresentadas as conclusões e sugestões para trabalhos futuros;

No Capítulo 7, está relacionada a bibliografia utilizada no trabalho.

2. DESGASTE

2.1. REVISÃO DA LITERATURA

Na revisão bibliográfica, abordam-se os principais tópicos que dão subsídio ao trabalho, e que fundamentam a metodologia aplicada durante os ensaios, as discussões apresentadas e a conclusão final do trabalho.

Também é apresentada a importância do trabalho para fins industriais e os benefícios da utilização de redes neurais artificiais na predição de características de processo de desgaste erosivo de materiais duros aplicados por aspersão térmica. Destaca-se uma revisão dos tipos de desgaste, as técnicas de aspersão e a descrição dos processos de revestimento, com ênfase em *Flame Spray/FlexiCord* – FS/FC e *High Velocity Oxygen Fuel* – HVOF e do processo de desgaste, destacando a eficiência de desgaste e a tenacidade à fratura.

2.2. DEFINIÇÃO DE DESGASTE

O desgaste é a perda progressiva de material da superfície de um corpo sólido, causado por ação mecânica e movimento relativo de um contra corpo sólido, líquido ou gasoso. Está relacionado com interações entre superfícies e, mais especificamente, com a remoção e deformação do material sobre uma superfície, como resultado da ação mecânica da superfície oposta (RABINOWICZ, 1995; KUDRYAKOV E VARAVKA, 2015).

O desgaste não é uma propriedade intrínseca dos materiais, mas uma característica dos sistemas de engenharia e depende de parâmetros como: carga aplicada; temperatura em que se dá o contato; velocidade das partículas; dureza do substrato; tenacidade à fratura das partículas e do substrato; condições ambientais e da presença de um terceiro corpo. Está relacionado com suas características microestruturais, que têm ampla influência durante o

processo de desgaste e, por isso, as pesquisas dos mecanismos de desgaste tendem a dar ênfase a microestrutura dos materiais de aspersão (WANG *et al.*, 2013; LINDGREN *et al.*, 2015).

Dentre os parâmetros que determinam o comportamento do mecanismo de desgaste erosivo, o ângulo de impacto exerce forte influência, como mostra o Gráfico 1.

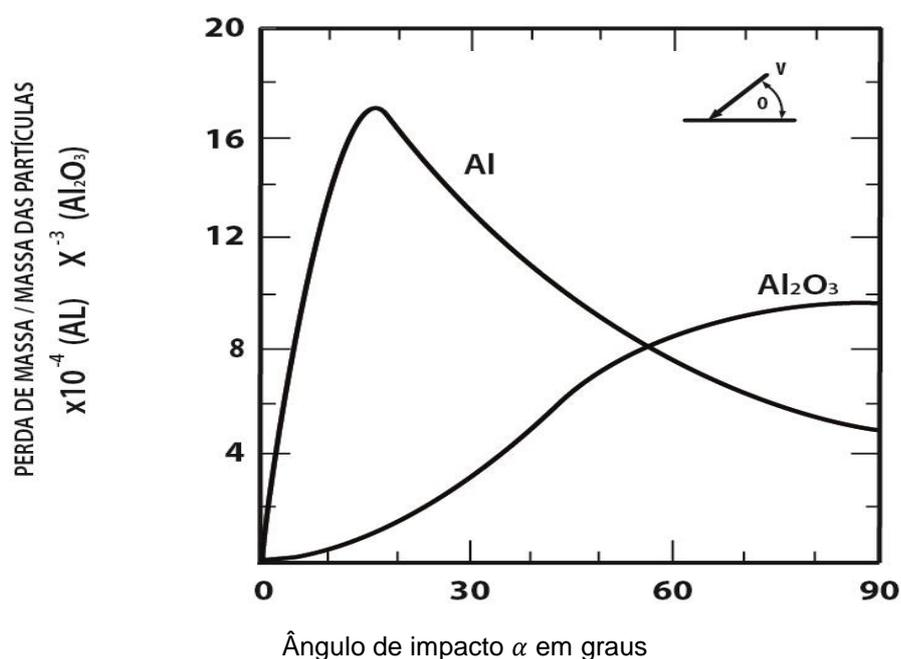


Gráfico 1 - Influência do ângulo de impacto na taxa de erosão do alumínio e da alumina com partículas de SiC a 152m s^{-1} . Fonte: Finnie (1960).

O Gráfico 1 apresenta as curvas experimentais da taxa de desgaste erosivo em função do ângulo de impacto e tem servido para classificar os materiais com comportamento dúctil ou frágil em ensaios de erosão. O alumínio, Al, apresenta máximo desgaste ao redor do ângulo de 20° e por isso é classificado como dúctil, enquanto a Alumina (Al_2O_3) apresenta máximo desgaste com ângulo de impacto normal e, por isso, é classificado como comportamento frágil (FINNIE, 1960).

Outro parâmetro fundamental no comportamento de erosão é a velocidade de impacto das partículas, pois determina a quantidade de movimento trocado entre as partículas e a superfície do substrato durante o impacto. Observa-se que a taxa de desgaste erosivo cresce com aumento da velocidade de impacto, segundo a equação 1 a seguir:

$$E_r = KV^n \quad (1)$$

Em que E_r é a taxa de erosão, K uma constante, V a velocidade das partículas e n é um expoente que pode variar entre 2 e 3 (SURESH, 2009).

O Gráfico 2 mostra a variação da taxa de desgaste do cobre em função da variação da velocidade dada em m/s, quando impactado por partículas de SiC com ângulos de incidência de 20° e 90° (HUTCHINGS, 1992).

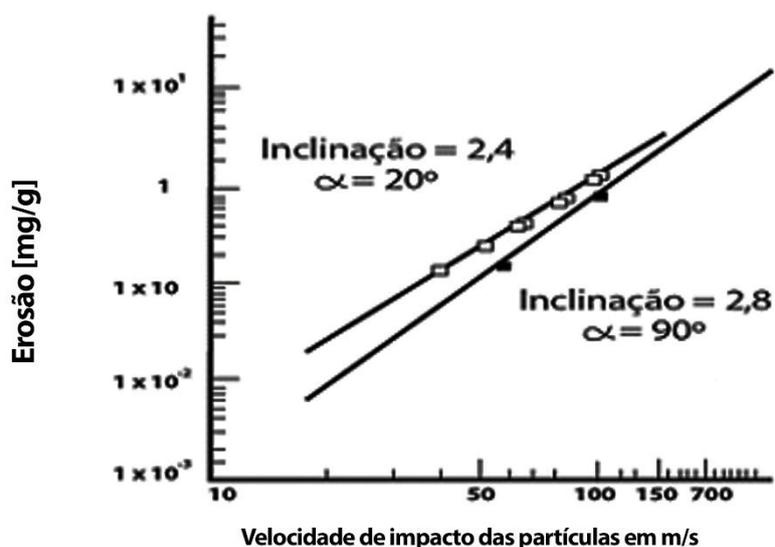


Gráfico 2 – Influência da taxa de erosão do cobre em função da velocidade de impacto das partículas. Fonte: Hutchings (1992).

Outras variáveis importantes sob as condições de interação entre superfícies em movimento relativo são as propriedades mecânicas e físicas do material desgastado como: a dureza, tenacidade à fratura, ductilidade e a condutividade

térmica; as propriedades e características das partículas como: tamanho e forma, dureza, tenacidade; a natureza do fluido propulsor como: a temperatura, viscosidade, se gasoso ou líquido. As propriedades mecânicas do material, como fadiga de contato e resistência ao impacto, têm recebido especial atenção nos estudos de erosão, por serem mais representativas do estado de esforços a que são submetidos os materiais durante o desgaste erosivo (OCHOA, 2007; SHARMA *et al.*, 2015).

O dinamismo do processo de desgaste com a influência de cada um de seus parâmetros e propriedades, com suas interações são, essencialmente, de natureza não linear e, por isso, torna-se desafiadora a determinação da influência de cada um deles na taxa de desgaste, e para facilitar o seu entendimento são, geralmente, classificados em cinco tipos, a saber (KATO, 2001):

- Abrasivo
- Corrosivo
- Adesivo
- Fadiga superficial
- Erosivo

2.2.1. DESGASTE ABRASIVO

O desgaste abrasivo ou abrasão é responsável pela maioria das falhas em equipamentos e pela maior perda de material na indústria. É originado pelo deslizamento entre duas ou mais superfícies em contato, que gera fragmentos que são repetidamente deformados e endurecidos (YUE E ZHANG, 2015; BEHERA, 2012).

2.2.2. DESGASTE CORROSIVO

O desgaste por corrosão é o resultado de reações eletroquímicas de um metal com o meio. Assim o processo de corrosão é caracterizado pela existência de processos anódicos e catódicos ocorrendo na interface do metal; é encontrado

em muitas áreas, desde em articulações humanas até em equipamentos de manuseio de licor cáustico na indústria de alumínio e pode comprometer o seu funcionamento (WOOD, 2014; SZYMAŃSKI *et al.*, 2015).

2.2.3. DESGASTE ADESIVO

É o desgaste que ocorre devido à pressão entre duas superfícies que travam entre si. Este tipo de desgaste ocorre devido à falta de lubrificantes, o que permite a ligação entre as asperezas. Isto também conduz à remoção das partículas da superfície, chegando a destruí-la. O problema de desgaste adesivo pode ser superado pela utilização de um lubrificante adequado (KHULLAR, 2014).

2.2.4. DESGASTE POR FADIGA SUPERFICIAL

O desgaste por fadiga é o fenômeno de ruptura progressiva de materiais sujeitos a ciclos repetidos de tensão. Seu entendimento é de grande importância para o projeto de máquinas e estruturas, uma vez que a fadiga causa falhas consideráveis em máquinas, em serviço (VEINTHAL *et al.*, 2013).

2.2.5. DESGASTE EROSIVO

A erosão por partículas sólidas é a perda de material resultante do impacto repetido de partículas sólidas, líquidas ou gasosas ou a combinação delas quando impelidas a uma dada velocidade e a um certo ângulo de incidência sobre o substrato (OCHOA, 2007; SIDDHARTHA, 2013).

O desgaste erosivo é um fenômeno complexo e parte da sua complexidade deve-se ao fato de o tempo de interação partícula-fluído-superfície ser muito pequeno; é um fenômeno de natureza dinâmica. Por isso, as propriedades que normalmente são utilizadas para caracterizar o comportamento dos materiais frente a algum tipo particular de desgaste nem sempre são apropriadas para dar entendimento completo ao fenômeno; essas propriedades nem sempre correspondem ao estado real de esforços e deformação ao qual o material está submetido (OCHOA, 2007).

Mesmo assim, a maioria dos modelos propostos, que usam propriedades estáticas, tem servido para prever alguns resultados posteriormente apoiados por experimentos. No entanto, ainda não existe um modelo de desgaste erosivo universal que explique todos os fenômenos observados (OCHOA, 2007; SZYMAŃSKI *et al.*, 2015).

A desvantagem dos modelos de desgaste existentes é que eles não levam em conta que a erosão resulta de uma sequência de múltiplos impactos de partículas sobre a superfície, que levam dano à mesma; descrevem a erosão como sendo resultante de um único evento que se repete (SZYMAŃSKI *et al.*, 2015).

A grande quantidade de variáveis relacionadas com o tribo-sistema pode influenciar a taxa de perda de material; por isso, há uma grande dificuldade na construção de modelo que seja facilmente ajustado e representativo dos diversos resultados obtidos em condições experimentais. Normalmente, os modelos existentes representam somente os resultados experimentais, a partir dos quais foram construídos. A tentativa de utilizá-los para condições diferentes das experimentais, geralmente, resulta em fracasso (OCHOA, 2007; KUDRYAKOV e VARAVKA, 2015).

O desafio é construir um modelo que permita correlacionar as variáveis do processo de desgaste com as propriedades dos materiais e com os parâmetros de aspersão de revestimentos que leve a uma compreensão adequada das condições operacionais e permita aplicações em situações reais (GHOSH e KUMAR, 2014).

Embora os fatores específicos de desgaste não sejam completamente conhecidos, há a concordância de que as variáveis de influência mais importantes no desgaste erosivo sejam (FROSELL *et al.*, 2015):

- As propriedades de impacto, que incluem: a velocidade e o ângulo de impacto das partículas;

- As propriedades das partículas, que incluem: a velocidade da partícula, forma e dureza;
- As propriedades da superfície de impacto, que geralmente se concentram nas propriedades mecânicas, tais como a dureza, ductilidade, tenacidade, força de adesão;
- Propriedades do fluido, que incluem: a viscosidade do fluido e a densidade das partículas.

O desgaste erosivo depende principalmente dos parâmetros como: ângulo de impacto, velocidade, tamanho, forma e concentração das partículas sólidas (MUTAIRI *et al.*, 2015).

Muitos estudos têm discutido a influência desses parâmetros no comportamento do desgaste erosivo. Há concordância de que o aumento da concentração de partículas aumenta o desgaste e que há aumento linear com o aumento da concentração de sólidos, ela é mais lenta a ângulos maiores, como mostra a Gráfico 3 (FINNIE, 1960).

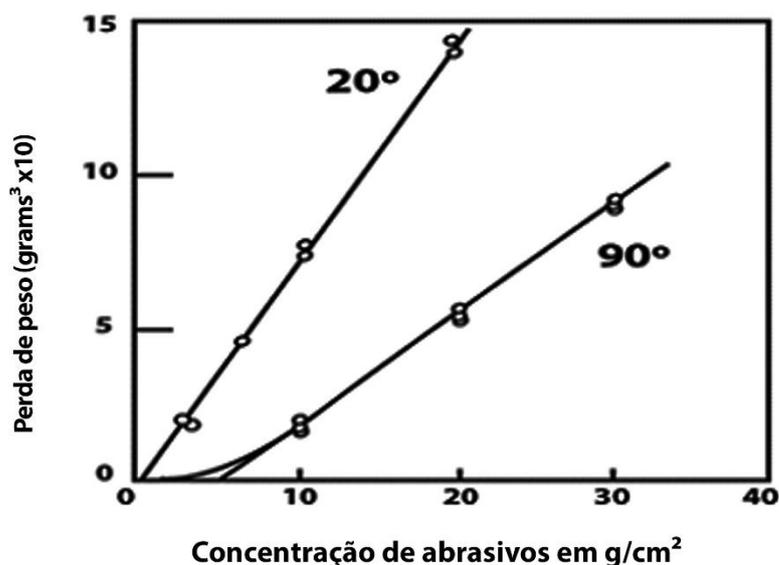


Gráfico 3: Relação da concentração de partículas com a taxa de desgaste.

Fonte: Finnie (1960).

Em situação real, as partículas podem ser aceleradas ou desaceleradas e o fluido pode mudar o seu sentido de movimento. Esse é um problema em muitos sistemas de engenharia, incluindo turbinas a jato, a vapor, tubulações e válvulas que transportam material particulado. Sua complexidade reside no fato de envolver diversas variáveis, além do que os tipos de desgaste não acontecem separadamente; às vezes o efeito da sua interação pode ser mais importante do que a sua atuação sozinha. O Quadro 1 mostra uma classificação dos tipos de desgaste erosivo e sua descrição.

Quadro 1- Tipos de desgaste erosivo com descrição dos mesmos.

Tipo	Descrição
Erosão por cavitação	Ocorre quando um sólido e um líquido estão em movimento relativo, e resulta na formação de bolhas quando o fluido se torna instável e implode contra a superfície do material. Ocorre principalmente em aplicações marítimas, como hélices, turbinas.
Erosão por impacto de líquido	É causada devido a impactos repetidos entre a superfície e pequenos corpos líquidos de naturezas distintas que geram pressões de contato sobre a superfície e termina por destruir o substrato
Erosão por partículas sólidas	Ocorre quando partículas sólidas suspensas em um fluido são projetadas com alta velocidade e se chocam contra as paredes do substrato e promovem desgaste em sua superfície.
Erosão por lodo	Ocorre quando uma lama de partículas de sólidos e líquidos flui sobre a superfície de um material a alta velocidade e, como resultado, remove o material da superfície.

Fonte: KHULLAR, (2014).

2.3. MECANISMOS DE DESGASTE EROSIVO

O Quadro 2 apresenta os diversos mecanismos de desgaste erosivo.

Quadro 2 - Principais mecanismos de desgaste erosivo.

Mecanismos	Descrição
Erosão por corte	Ocorre quando as partículas erodentes são muito afiadas e, ao se chocar com a superfície do substrato, ocorre micro cortes sobre ela e o material é removido. Este mecanismo é recorrente em quase todos os casos de desgaste erosivo
Erosão por raspagem	Este processo acontece em duas etapas. Na primeira, há deformação plástica da superfície, devido ao impacto das partículas, que se deformam o substrato formando bordas de corte. Na segunda etapa, devido ao impacto repetido das partículas sobre estas bordas, elas se rompem e se quebram, devido à fadiga
Erosão por decapagem ou Plaquetas	Neste processo, as partículas sólidas impactam a superfície alvo, o material é achatado e estende-se até formar uma plaqueta. Este mecanismo é também conhecido como extrusão
Erosão por deformação superficial ou rachaduras	Quando uma partícula atinge a superfície alvo, leva a uma deformação plástica localizada e desenvolve rachaduras na superfície, provocando a ruptura frágil do material

Fonte: Khullar (2014).

2.4. PARÂMETROS QUE AFETAM O DESGASTE EROSIVO

Os parâmetros que desempenham influência sobre a taxa de desgaste erosivo são:

- Ângulo de impacto das partículas
- Velocidade de partículas sólidas erodentes
- Tamanho e forma da partícula
- Concentração das partículas sólidas
- Dureza das partículas aspergidas
- Tenacidade à fratura das partículas e do substrato

2.4.1 ÂNGULO DE IMPACTO

Ângulo de impacto é o ângulo de incidência entre a direção das partículas sólidas e o plano da superfície do substrato. É um fator importante que afeta a taxa de desgaste (TILLMANN *et al.*, 2013).

Yildiran (2014) estudou a taxa de erosão da liga de alumínio em função do ângulo de impacto, da aceleração de partículas e da carga aplicada. Concluiu que o ângulo da partícula desempenha papel crucial no comportamento de erosão da liga de alumínio. A taxa máxima de erosão foi observada a um ângulo de impacto de 15°.

2.4.2. VELOCIDADE DAS PARTÍCULAS SÓLIDAS

A deposição das partículas depende da velocidade de impacto e apenas as partículas com velocidade mais elevada do que uma velocidade crítica pode ser depositada para formar a camada aspergida (HUTCHINGS, 1981). A velocidade crítica é dependente do tamanho das partículas, geometria, temperatura, concentração e das propriedades físicas e químicas do material das partículas (SHARMA, *et al.*, 2015).

2.4.3. TAMANHO E FORMA DA PARTÍCULA

O tamanho e a forma das partículas também são fatores importantes na determinação da taxa de erosão. O desgaste aumenta com o aumento no tamanho das partículas (BOUSSER, 2014).

O efeito da forma das partículas, sobre a taxa de erosão, não tem sido estudado com a mesma frequência que o tamanho das mesmas. As partículas frágeis tendem causar maior taxa de erosão pelo fato das partículas fragmentadas conter bordas afiadas que provocam microcortes mais facilmente na superfície do substrato. As partículas irregulares proporcionam maior taxa de erosão do que as partículas esféricas (SUNDARARAJAN e MANISH, 1997).

2.4.4. CONCENTRAÇÃO DAS PARTÍCULAS SÓLIDAS

À medida que a concentração das partículas sólidas aumenta, a taxa de desgaste também aumenta; à medida que mais partículas sólidas entram em contato com a superfície alvo, as concentrações podem variar de 2% a 50%, em volume, dependendo da natureza da suspensão. Em concentrações muito elevadas, a velocidade das partículas diminui como resultado do aumento da interação entre elas (PADHY e SAINI, 2009).

2.4.5. DUREZA

O desgaste erosivo é dependente da dureza da superfície do substrato e da dureza das partículas sólidas que colidem contra ela. A dureza está relacionada com a força de ligação dos átomos; pode ser avaliada pela capacidade de um material riscar o outro e penetrá-lo, é definida como a capacidade com que o material pode resistir à penetração por outro material (OZDEMIR *et al.*, 2014).

2.4.6. TENACIDADE À FRATURA

Através da aplicação da mecânica da fratura, é possível determinar um parâmetro de resistência que permite o cálculo da tensão de ruptura na presença de uma fissura. Esse parâmetro, indicado como tenacidade à fratura K_{Ic} , é uma propriedade mensurável, e quando as medições feitas por técnicas convencionais da ASTM D-5045, indicado com padrão de ensaio, são reconhecidas por produzir resultados confiáveis se devidamente aplicáveis (BESHISH *et al.*, 1993, SHI *et al.*, 2015).

A tenacidade à fratura é a habilidade de um material absorver energia até o início da sua ruptura. Fatores importantes para definir esta propriedade são a forma geométrica do corpo de prova, bem como a maneira com que a carga é aplicada. Os procedimentos padrões para a medição de tenacidade à fratura são restritivos a revestimentos com pequenas espessuras, como pode ocorrer

com os materiais aplicados por aspersão térmica (HOUDKOVA E KAŠPAROVA, 2013).

A tenacidade é um dos mais importantes parâmetros que influenciam a classificação dos materiais quanto a resistência ao desgaste. Nos últimos anos, o aumento da disponibilidade de métodos tem contribuído para a multiplicação de técnicas para a quantificação da tenacidade à fratura de filmes finos. No entanto, ainda não foi proposto, a partir da literatura, como um método padrão (BOUSSER *et al.*, 2014).

Com o intuito de determinar o comportamento do desgaste de superfícies, Sundararajan *et al.* (1990) propuseram um modelo, onde introduziram um termo denominado de eficiência de erosão, designado por η , definido como sendo a razão entre o material da superfície do substrato que foi afetado pelo choque das partículas sólidas no processo de desgaste erosivo, com relação ao material que, tendo sido afetado, foi deslocado da cratera formada pela indentação das partículas sólidas na superfície do substrato. No caso de um fluxo de partículas de impacto normal, isto é: $\alpha = 90^\circ$, a eficiência de erosão (η_{Normal}), é dada por:

$$\eta_{normal} = \frac{2E_r H_v}{\rho V^2}, \quad (2)$$

Patnaik *et al.* (2010) propuseram uma modificação no modelo de Sundararajan *et al.* (1990), indicado na equação (3), admitindo que o volume de material removido é diferente do volume da indentação. Na prática, as partículas podem colidir com a superfície do substrato a qualquer ângulo ($0^\circ \leq \alpha \leq 90^\circ$), ficando a equação (2) modificada para:

$$\eta = \frac{2E_r H_v}{\rho V^2 \sin^2 \alpha} \quad (3)$$

em que:

α ângulo de impacto (graus);

V velocidade de impacto (m/s);

H_v dureza (N/m^2);

ρ densidade da partícula erodente (kg/m^3);

η eficiência de erosão, termo adimensional;

E_r taxa de erosão atual (kg/kg).

O presente trabalho propõe uma modificação no modelo de Patnaik *et al.* (2010), adotando uma rede neural artificial para prever o comportamento do desgaste erosivo. Para isso, faz a introdução da tenacidade à fratura e a exclusão da taxa de erosão no novo modelo. Considera, assim, que o modelo pode determinar com precisão os esforços sob os quais o substrato está submetido e expressar o comportamento não linear, próprio dos processos dinâmicos, como é o caso do processo de desgaste erosivo por partículas sólidas.

2.5. MODIFICAÇÃO DE SUPERFÍCIE

A engenharia de superfícies é a área de conhecimento e o conjunto de técnicas de modificação de superfície, e sua finalidade é (PAWLOWSKI, 2008):

- Melhorar a resistência ao desgaste erosivo em superfícies de desgaste em máquinas-ferramentas;
- Controlar o atrito em superfícies deslizantes em ferramentas;
- Reduzir a adesão em contatos elétricos;
- Melhorar o isolamento térmico;
- Melhorar a resistência à oxidação de chapas para utilização em veículos automóveis, componentes de turbinas a gás e dispositivos médicos;

- Melhorar a rigidez e resistência à fadiga de rolamentos e eixos de vários diâmetros;
- Melhorar a lubrificação pela modificação da superfície para manter os lubrificantes;
- Reconstruir superfícies de componentes desgastados e componentes de máquina;
- Melhorar a rugosidade da superfície e aparência, precisão dimensional e características de fricção;
- Transmitir elementos decorativos, cor ou textura de superfície especial;
- Aumentar a vida útil de equipamentos.

Para uma grande variedade de indústrias, os revestimentos de superfície têm sido cada vez mais importantes, pois conferem maior vida útil a peças e equipamentos (ZHONG e CLOUSER, 2014).

A engenharia de superfície visa a alterar as propriedades das superfícies, por meio da colocação de uma camada protetora sobre as mesmas, de modo a protegê-las das condições hostis do ambiente em que operam (BEHERA, 2012).

Os métodos de aplicação dos revestimentos protetores diferem na maneira pela qual os revestimentos são aplicados. No entanto, independentemente do método utilizado, devem oferecer proteção dentro de um determinado período de tempo de vida das peças e equipamentos a custo competitivo (BEHERA, 2012).

A aspersion térmica detém uma posição única no espectro de tecnologias de modificação de superfície, pois pode aplicar revestimentos finos ou espessos sobre uma grande área a uma taxa de aplicação muito elevada em comparação com outros processos de revestimento (VERA *et al.*, 2015).

As técnicas de engenharia de superfície estão sendo utilizadas para aplicação de materiais, incluindo: metais, cerâmicas, polímeros e compósitos, que podem revestir os mais variados tipos de superfície (ZHONG e CLOUSER, 2014).

2.5. TÉCNICAS DE MODIFICAÇÃO DE SUPERFÍCIE

Há um grande número de tecnologias disponíveis para modificação de superfície no cenário industrial, como:

- Deposição Física de Vapor – DFV
- Deposição Química de Vapor – DQV
- Galvanoplastia
- Aspersão Térmica

2.5.1 DEPOSIÇÃO FÍSICA DE VAPOR - DFV

DFV é um termo geral usado para descrever uma variedade de métodos de depositar filmes finos pela condensação de uma forma vaporizada do material sobre várias superfícies. O método de revestimento envolve processos puramente físicos, tais como evaporação a vácuo em alta temperatura (SUBRAMANIAN e VIJAYALAKSHMY, 2014).

2.5.2 DEPOSIÇÃO QUÍMICA DE VAPOR – DQV

DQV pode ser definido como formação de um filme fino sólido pela deposição atômica ou molecular, em uma superfície aquecida, sendo o sólido oriundo de uma reação química em que os precursores estão na fase de vapor. É um processo versátil para construção de filmes sólidos, revestimentos, fibras, componentes monolíticos, entre outros materiais. Com a técnica de DQV, é possível fazer deposição de metais, elementos não metálicos e ainda grande quantidade de compostos como carbonetos, nitretos, óxidos, compostos intermetálicos e muitos outros (VARANASI *et al.*, 2014; ILYUSCHENKO *et al.*, 2015).

2.5.3 GALVANOPLASTIA

Os termos **galvanoplastia** ou **eletrodeposição metálica** referem-se a um processo usado com a principal finalidade de proteger uma peça metálica contra a corrosão por revesti-la com outro metal. Esse metal impede a interação do metal da peça com o ar e com a umidade, evitando, assim, a corrosão. É um processo eletroquímico em que os íons de metais em uma solução são levados a partir de um campo elétrico para revestir o eletrodo. O objeto a revestir é conectado ao polo negativo de uma fonte de energia, funcionando como cátodo, no qual ocorrerá a redução do metal na forma de depósito superficial, enquanto o metal que sofre a oxidação deve ser ligado a um polo positivo, o ânodo. No processo, as reações não são espontâneas. É necessário fornecer energia elétrica para que ocorra a deposição do metal a partir dos seus íons mediante fornecimento de elétrons. Trata-se, então, de uma eletrodeposição na qual uma corrente contínua é forçada a passar pelos eletrodos e pela solução, fazendo com que o metal que promove o revestimento seja ligado ao polo positivo para promover sua oxidação, repondo na solução os cátions do metal eletro depositado no objeto condutor ligado ao polo negativo (MARQUES *et al.*, 2013).

2.5.4. ASPERSÃO TÉRMICA

Dentre as técnicas de modificação de superfície, uma das mais utilizadas atualmente é a aspersão térmica. Pelo fato da aspersão térmica ter sido a técnica escolhida para desenvolvimento deste trabalho, será detalhada neste tópico.

No início de 1900, Max Ulrich Schoop fez os primeiros experimentos de deposição de camadas de metais sobre uma superfície sem o uso de adesivos ou imersão. Ele foi o primeiro cientista a explorar uma corrente de partículas metálicas formadas a partir de metal em fusão para a produção de revestimentos. Mas, a maior expansão da técnica se deu na década de 1970 (LIMA e TREVISAN, 2007).

O processo de aspersão térmica baseia-se principalmente na projeção de partículas de um material metálico ou não-metálico sobre um substrato previamente preparado para formar o revestimento (LIMA E TREVISAN, 2007).

Em 1985, a American Welding Society – AWS (1985) definiu a aspersão térmica como: um grupo de processos em que os materiais metálicos ou não-metálicos finamente divididos são depositados num estado fundido ou semi-fundido sobre um substrato preparado, formando um depósito projetado.

O material consumível é levado a um injetor onde, com a ajuda de uma fonte de calor, devido à queima de um combustível ou um arco elétrico, é aquecido e atomizado e finalmente é acelerado pelo gás propelente contra o substrato previamente preparado. As partículas resultantes desse processo, ao atingir a superfície, são achatadas e formam uma camada aderente; a camada é resfriada e se acomoda na superfície do substrato e através de várias passadas a espessura do revestimento é finalmente alcançada, como mostrado esquematicamente na Figura 1 (LIMA e TREVISAN, 2007).

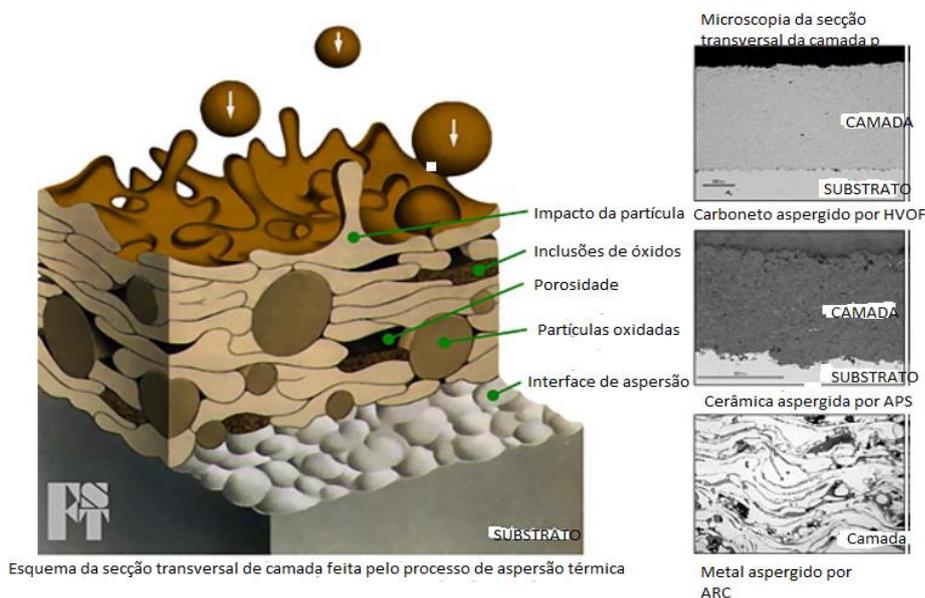


Figura 1 - Esquema da camada aspergida sobre o substrato.

Fonte: adaptado de Lima e Trevisan, 2007.

A temperatura da chama tem um forte efeito sobre os materiais a serem aspergidos. Os revestimentos cerâmicos são fabricados essencialmente usando o método de aspersão de plasma atmosférico, enquanto que materiais sensíveis à temperatura, tais como cermets, são preferencialmente aspergidos por métodos com uma temperatura mais baixa da chama (OKSA *et al.*, 2011).

Boa qualidade de revestimento com propriedades adequadas e desempenho necessário para aplicações específicas é o objetivo na produção de revestimentos de aspersão térmica. A fim de alcançar este objetivo, é necessária uma profunda compreensão do processo de aspersão como um todo. Material de aspersão, do processo de aspersão e das interações das partículas com o substrato. Todos afetam a formação do revestimento com diferentes microestruturas e, portanto, as propriedades de revestimento e, eventualmente, o desempenho do revestimento, o que exige uma escolha do processo como a temperatura adequada (RAJENDRAN *et al.*, 2015).

Há duas maneiras básicas de geração de calor para fundir os consumíveis: a primeira é combustão de um gás, e a segunda é por um arco elétrico de alta energia (HEATH *et al.*, 1989).

Os processos com as principais fontes de energia e as técnicas de aspersão estão relacionados no Quadro 3, na próxima seção (HEATH *et al.*, 1989).

2.5.4.1. PROCESSOS DE ASPERSÃO TÉRMICA

São vários os processos utilizados para a deposição de revestimentos por aspersão térmica, por exemplo (OKSA *et al.*, 2011):

- Chama convencional (*Flame Spray*)
- Detonação (Detonação ou *D-Gun*)
- Chama hipersônica (*High Velocity Oxygen Fuel* ou HVOF)
- Arco elétrico (*Arc Spraying/ASP*)
- Plasma (*Atmospheric Plasma Spraying* ou APS)
- Aspersão a frio (*Cold Gas Spraying* ou CGS)

Quadro 3 - Processo de aspersão e fontes de calor

Processos de Aspersão Térmica		Processos combustão a Gás	de	Oxi-Combustível /arame
				Oxi-Combustível /pó
				Pistola à detonação
				HVOF
		Processo a arco	Arco elétrico	
				Arco a plasma
Processos		Fonte de energia	Diferentes nomenclaturas	
Processos de baixa energia	Aspersão a Chama	Químico	Aspersão OxiCombustível a pó	
			Aspersão oxicom bustível a arame	
			Metalização	
	Aspersão a arco	Elétrico	Aspersão a arco elétrico	
			Aspersão a arco paralelo	
			Metalização	
Processos de alta energia	Aspersão a plasma	Elétrico	Aspersão a plasma atmosférico	
			Aspersão a plasma a vácuo	
			Aspersão a plasma a baixa pressão	
			Aspersão a plasma estabilizado a água	
			Aspersão a plasma indutivo	
	Aspersão a chama por detonação	Químico	Pistola a Detonação	
	Aspersão a oxigênio a alta velocidade	Químico	Aspersão HVOF	
			Aspersão a combustível oxigênio a alta velocidade	
			Aspersão a chama a alta velocidade	
			Aspersão a ar combustível a alta velocidade	

Fonte: Heath *et al.*, (1989).

Os processos utilizados neste trabalho foram os processos de aspersão a chama convencional utilizando arame flexível ou FlexiCord (FS/FC) e o processo *High Velocity Oxy Fuel* (HVOF). Por isso, serão detalhados nos tópicos seguintes.

2.5.4.1.1. ASPERSÃO A CHAMA CONVENCIONAL OU FLAME SPRAY- FS

Um dos métodos mais tradicionais e simples de aplicação por aspersão térmica é o processo de aspersão a chama convencional ou *Flame Spray* – FS. Este

processo utiliza o calor gerado pela combustão de uma mistura de gases (oxigênio-acetileno ou oxigênio-propano) para fundir o material de deposição. Os materiais são fornecidos na forma de pó, vareta ou arame. No processo FS, pode-se aspergir materiais metálicos, cerâmicos e alguns plásticos (LEE *et al.*, 2007). A Figura 2 mostra uma pistola de aspersão térmica a chama convencional.



Figura 2 - Pistola de aspersão térmica a chama utilizando arame

Fonte: LABATS/UFPR (2014)

A Figura 3 mostra o esquema do processo de aspersão a chama convencional FS.

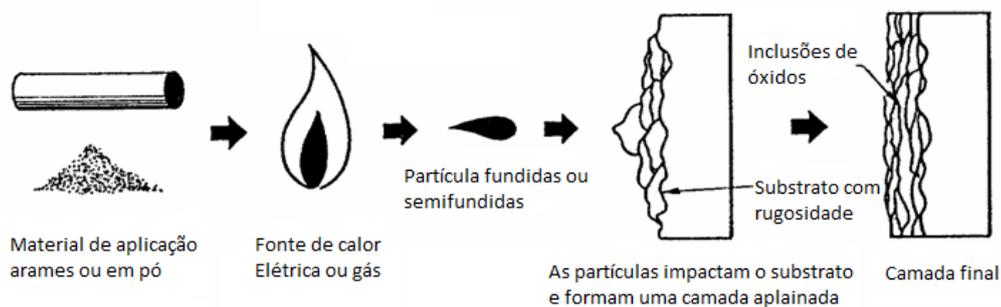


Figura 3 - Processo de deposição por aspersão térmica a chama convencional.

Fonte: Lima e Trevisan (2007)

A pistola de aspersão é simples, compacta e leve. A chama é utilizada para fundir e para acelerar o consumível contra o substrato. A velocidade das

partículas é baixa, por isso os revestimentos obtidos são, normalmente, de qualidade inferior em comparação com os obtidos por outros processos de aspersão, em termos de porosidade e da aderência da camada lamelar com o substrato. A qualidade do revestimento pode ser melhorada com o auxílio de ar comprimido para acelerar as partículas e reduzir a temperatura na periferia da chama (SINGH, 2007; JAFARI *et al.*, 2013).

As principais variáveis que devem ser controladas no processo FS são a pressão e fluxo de ar utilizado para transferir as partículas da fonte de calor até o substrato e para fornecer à turbina a pressão necessária para alimentar, com arame, o bico da pistola, e o fluxo de acetileno e oxigênio, para formar e manter a chama que permite a fusão do material (ZOIS, 2013; NISTAL *et al.*, 2015).

A combustão não é confinada, isto é, não há nenhum injetor para expansão dos gases e para aceleração das partículas. A temperatura e a velocidade mais baixas, no processo de aspersão FS, resultam em óxidos, porosidade e inclusões superiores aos revestimentos feitos por meio de outros processos de aspersão (ZHANG, 2012).

Uma ampla variedade de materiais pode ser aplicada pela tecnologia FS, mesmo os que têm alto ponto de fusão, como as cerâmicas (SOVEJA, 2010).

A aspersão FS pode ser comumente encontrada na indústria onde revestimentos com boa resistência ao desgaste e uma excelente resistência ao impacto são necessários, como os exigidos pelos componentes de colheita agrícola e peças de perfuração de petróleo e mineração (ZHANG, 2012).

2.5.4.1.2. ASPERSÃO A CHAMA FLEXICORDS – FC

O processo de aspersão térmica a chama com FlexiCords (FS/FC) é uma alternativa ao processo a chama convencional. É uma nova técnica para produzir revestimentos como cerâmica, carbonetos metálicos com alta qualidade, utilizando o mesmo equipamento e princípios do método FS. Esta técnica amplia a gama de aplicações da técnica de aspersão térmica, podendo

ser utilizada em vários setores da indústria mecânica, para recobrir superfícies internas em tubos, corpos de bombas e rolamentos (SAINT GOBAIN, 2015).

A técnica FC não compete com outras técnicas de aspersão térmica, como a aspersão a plasma, CGS ou HVOF. Ela é complementar e oferece benefícios diferentes ao revestimento com ajuste mais rápido do equipamento e aplica materiais na forma de fios metálicos flexíveis, arames tubulares e hastes de cerâmica (SAINT GOBAIN, 2015).

Com o objetivo de atender às exigências do mercado, com diferentes aplicações, a técnica FC foi projetada para atender às necessidades específicas, tais como (SAINT GOBAIN, 2015):

- Revestimento denso com baixa porosidade (3%) e revestimentos lisos com rugosidade de até $Ra = 3 \mu m$;
- Aplicações resistentes à abrasão e erosão que confere maior resistência aos revestimentos;
- Revestimentos com elevada resistência à abrasão e dureza, resistente à fricção em comparação com os aplicados por aspersão a plasma;
- Revestimentos com baixa tensão residual interna para melhor resistência ao impacto;
- Revestimentos de superfície com propriedades de atrito elevado;
- Revestimentos cerâmicos com espessuras de até 2 ou 3 mm, sem a necessidade de processamento adicional.

Os principais benefícios de aspersão térmica com FlexiCords – FC são:

- Revestimentos densos e porosidade baixa, que proporcionam maior resistência à abrasão e erosão;

- Espessura de acabamento de 2 a 3 mm, perfeita para reconstrução de partes danificadas ou peças que requerem camadas de enchimento;
- Maior espessura de revestimentos, que proporcionam maior vida útil e menos manutenção;
- O uso de *HardKarb* ou *ChromKarb FlexiCords* para aspersão em áreas que são inacessíveis para revestimento com outros materiais;
- Revestimentos para aplicações em alta temperatura e sinterização de metal como carboneto de tungstênio;

É um processo de baixo ruído e a aplicação dos revestimentos pode ser feita manualmente, as principais aplicações do processo de aspersão térmica FlexiCord são (SAINT GOBAIN, 2015):

- Obtenção de revestimentos resistentes à corrosão, abrasão e erosão. Exemplos de uso: eixos da bomba, impulsores, rotores na indústria petroquímica;
- Alcance de revestimentos secos contra a erosão e abrasão. Exemplo: aplicações em instalações de caldeiras de carvão de navios e usinas de carvão;
- Obtenção de revestimentos utilizados em barreiras de difusão. Exemplo: grafite revestida, elementos de carboneto de tungstênio;
- Utilização como revestimentos de barreira térmica. Exemplo: fornalhas, fornos, caldeiras, revestidos de cerâmica refratária;
- Revestimentos como isolante elétrico. Exemplo: bobinas de indução, soldagem de isolamento, isolamento de eletrodos em fornos elétricos, elementos de aquecimento;

- Revestimentos resistentes à oxidação. Exemplo: painéis de tubos de caldeira de água de resfriamento;
- Revestimentos utilizados na manutenção e reconstrução de componentes. Exemplo: reconstrução tridimensional do diâmetro de superfícies externas e superfícies internas.

2.5.4.1.3. PROCESSO DE ASPERSÃO TÉRMICA *HIGH VELOCITY OXYGEN FUEL* (HVOF)

O processo HVOF foi desenvolvido na década de 1980 como alternativa de baixo custo para o processo de detonação (*D-Gun*). Aparece, hoje, como opção ao processo de aspersão a plasma em algumas aplicações. Além da qualidade do revestimento e tensões residuais menores, outras vantagens incluem eficiência do depósito, reduzida sensibilidade ao ângulo de aspersão e menos variáveis críticas (LIMA e TREVISAN, 2007).

Inicialmente foi concebido para a aspersão de *cermets* resistentes ao desgaste; no entanto, o processo evoluiu para um processo chave e é utilizado para a aspersão de muitos tipos de materiais, incluindo metais, ligas metálicas, cerâmicas, compósitos, *cermets* e polímeros (MARROCCO, 2008).

O objetivo no desenvolvimento do processo HVOF foi o de permitir a transferência de energia cinética e térmica para as partículas de pó com alto grau de eficiência, de modo que haja menos fusão e, assim, menos evaporação e oxidação do material durante a aplicação (BOLELLI, 2014).

No processo HVOF, uma mistura de combustível sob a forma de gás (propano, propileno, hidrogênio) ou líquido (querosene) e oxigênio são injetados a alta pressão dentro de uma câmara de combustão onde são queimados e expulsos

para o exterior por meio de uma pistola especialmente desenhada para este fim (SAEIDI, 2010; THIRUVIKRAMAN *et al.*, 2014).

A elevada energia cinética gerada no processo fornece força mecânica suficiente para projetar o fluxo de partículas contra o substrato previamente preparado. À medida que o impacto de partículas atinge o substrato a energia térmica é rapidamente e uniformemente absorvida. A energia armazenada em cada partícula é a principal razão pela qual os revestimentos aplicados por HVOF ter força de adesão e densidade maiores do que a maioria dos outros revestimentos feitos por outros processos de aspersão térmica (BOLELLI *et al.*, 2014).

O tamanho das partículas de pó utilizados no processo HVOF é, usualmente, de 5 a 45 μm e a taxa de alimentação varia de 20 a 80 g/min. O pó é geralmente injetado na direção axial e, em algumas tochas, radialmente, utilizando nitrogênio como gás de arraste. A distância padrão de aspersão varia de 120 a 300 mm e chega a alcançar força de ligação em torno de 70 MPa e porosidade menor que 1% (LIMA e TREVISAN, 2007).

O processo de aspersão HVOF tem algumas vantagens, como as relacionadas a seguir: maior densidade; melhor resistência ao desgaste; revestimentos com maior dureza; melhor proteção contra a erosão; superior força de adesão; revestimento mais espesso; superfície mais lisa devido a maior velocidade; menor tamanho das partículas (RAJASEKARAN *et al.*, 2010).

Algumas desvantagens estão relacionadas ao fato de ter que ser aplicado em cabine de aspersão térmica especializada com instalações de atenuação de som e de extração de poeira adequados, além do que os equipamentos exigem mais investimento do que outros processos de aspersão térmica (RAJASEKARAN *et al.*, 2010).

Tipos de pistola HVOF

A primeira pistola HVOF, *Jet Kote*, foi comercialmente desenvolvida no final da década de 1.970 e início da década de 1.980, sendo a base de muitos sistemas de aspersão térmica em aplicação hoje (DRIVER, 2004).

As pistolas de aspersão diferem pelo tipo de combustível (líquido ou gás); de refrigeração a água ou ar; injeção dos consumíveis axial ou radial; configuração da câmara de combustão; comprimento do bico. As mais comumente utilizadas comercialmente são *Jet Kote II* da Deloro Stellite; *Diamante Jet* da Sulzer Metco; *Top Gun/HV-2000* da Praxair; e *JP-5000* da Tafa. A Figura 4 mostra a imagem de uma pistola de aspersão HVOF (EDRIS, 1997; SAEIDI, 2010). A Figura 5 mostra uma pistola HVOF em operação.



Figura 4 - Pistola HVOF. Fonte: Praxair -Tafa (2014).

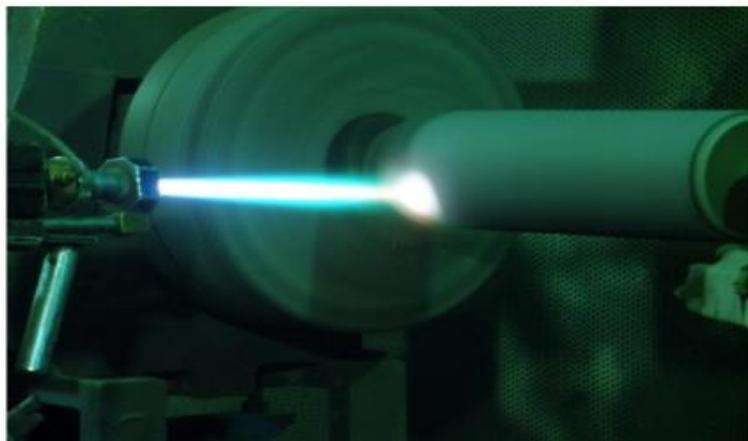


Figura 5 – Aplicação da camada pelo método HVOF.
Imagem cedida pela empresa Ogramac Ltda.

Variáveis do processo HVOF

Embora o processo de aspersão HVOF seja relativamente simples, são vários os parâmetros que devem ser controlados (THIRUVIKRAMAN *et al.*, 2014).

Segundo Pawlowski (1995), estes parâmetros são mais de 20. Os tidos como de maior importância são: distância de aspersão (SAAEDI *et al.*, 2010), velocidade das partículas (SHARMA *et al.*, 2015) a pressão de combustão (HACKETT *et al.*, 1995), a razão de oxigênio-combustível (SAAEDI *et al.*, 2010), ângulo de incidência (ARORA *et al.*, 2013) e a taxa de alimentação de pó (ZHANG *et al.*, 2012).

O processo de aspersão HVOF é um processo complexo, que tem uma grande variedade de variáveis que afetam a formação de depósitos e, conseqüentemente, as propriedades dos revestimentos. Estas variáveis incluem características de hardware, por exemplo: a geometria do bocal e da distância de pulverização; os parâmetros do processo, por exemplo; gás combustível, a densidade do fluxo de gás e da matéria-prima em pó (MURUGAN *et al.*, 2014).

No processo HVOF, as partículas de pó experimentam alta velocidade combinado com um aquecimento rápido até ao seu ponto de fusão ou acima

dele. Esta temperatura elevada pode provocar a evaporação do pó ou alguns componentes do mesmo, dissolução, e transformações de fase. Devido a esta natureza complexa da técnica de HVOF, o controle e otimização do processo de modo a atingir o revestimento com as propriedades desejadas é uma tarefa altamente exigente (MURUGAN *et al.*, 2014).

Existem diferentes maneiras de otimizar e analisar o processo de pulverização e formação de depósitos térmica. Estes incluem métodos estatísticos, tais como o método de Taguchi e planejamento de experimentos (DOE), modelagem numérica e simulação, e da metodologia de elementos finitos (POWAR e DATE, 2015).

Boa qualidade de revestimento com propriedades adequadas e desempenho necessário para aplicações específicas é o objetivo da aplicação de revestimentos feitos com aspersão térmica. Para alcançar este objetivo é necessário que as condições de aplicações com as variáveis do processo e as propriedades dos materiais de aspersão sejam otimizadas. Mas, devido ao grande número de variáveis e parâmetros do processo de aspersão, com suas iterações, fica praticamente impossível encontrar condições ótimas a partir de experimentos em que se alterem as variáveis e parâmetros um de cada vez, permanecendo as outras constantes. Normalmente alguma técnica numérica é recomendável para atingir este objetivo (POWAR e DATE, 2015).

A modelagem numérica, por meio das redes neurais artificiais, pode levar a uma compreensão da influência dos processos, das variáveis e dos parâmetros do processo e, assim, pode contribuir, decisivamente, para uma compreensão necessária na escolha a se adotar a fim de alcançar a propriedade desejada (MURUGAN *et al.*, 2014).

3. REDES NEURAIS ARTIFICIAIS – RNA

3.1. CONCEITOS E DEFINIÇÕES

Uma rede neural é um modelo matemático que opera de maneira a emular as habilidades de processamento do cérebro humano. É um processador paralelo massivamente distribuído que possui uma propensão natural para armazenar conhecimento adquirido pela experiência e torná-lo disponível para uso nas mais variadas condições em que o sistema, no qual se busca algum padrão, não seja linear, como as aplicações de engenharia (ZWASS, 2015).

Para Ramesh e Kumar (2012), uma rede neural artificial - RNA é um sistema paralelo e distribuído, composto por unidades de processamento simples que calculam determinadas funções matemáticas, normalmente não lineares, dispostas em camadas e interligadas por um grande número de conexões, geralmente unidirecionais. Na maioria dos modelos, estas conexões estão associadas a pesos, os quais armazenam o conhecimento representado no modelo e serve para ponderar a entrada recebida por cada neurônio da rede.

Um neurônio é uma unidade de processamento de informação composta de um conjunto de sinapses, cada qual caracterizado por um valor de peso, um somador, responsável por somar os sinais de entrada, devidamente multiplicados pelos pesos das sinapses e uma função de ativação, que define e limita a saída do neurônio. Em uma rede neural, o conhecimento sobre um determinado problema é armazenado nos pesos das sinapses que interconectam os neurônios nas camadas da rede. As funções de ativação são geralmente diferenciáveis, fato este que é crítico para o sucesso dos algoritmos de treinamento (HAYKIN, 2001).

A arquitetura de uma rede neural é formada, em geral, com camadas distintas encadeadas: a camada de entrada, que serve como porta de entrada para os dados oriundos do meio externo, uma ou mais camadas ocultas que processa

os resultados e os apresenta à camada de saída da rede, que comunica o resultado da operação ao meio externo. A camada de entrada de uma rede neural, em geral, multiplica cada um de seus sinais de entrada por pesos e utilizam uma função de ativação para determinar sua saída. Cada entrada de um neurônio tem um peso associado a si que determina sua intensidade (BRAGA *et al.*, 2000; DONNARUMMA *et al.*, 2015).

A utilização de redes neurais na resolução de um dado problema envolve três fases. Na primeira fase, a arquitetura e os parâmetros da rede são estabelecidos. Na segunda fase, de aprendizado, exemplos são apresentados à rede para que esta, seguindo um algoritmo de treinamento, armazene conhecimento. Por último, há uma fase de testes, em que o desempenho da rede, em relação ao problema para o qual foi treinada, é avaliado de maneira independente (VEERESH E PRAMOD, 2014).

As técnicas de modelagem por meio de redes neurais permitem estabelecer relações cuja descrição com a utilização de modelos físicos seria difícil de modelar. Ao contrário de abordagens tradicionais de análise, que são baseadas em um número de idealizações e considerações teóricas, as redes neurais artificiais possuem a capacidade de aprender por meio de exemplos e fazer interpolações e, em alguns casos, extrapolações do que aprenderam (MABBUTT *et al.*, 2012).

As redes neurais podem ser aplicadas a problema no qual uma relação entre variáveis de entrada, independentes e saída, dependentes exista e seja, de preferência, de natureza não linear. Exemplos desta natureza são problemas de regressão múltipla, em que entradas e saída são variáveis numéricas contínuas, e também problemas de regressão logística, nos quais as entradas são variáveis numéricas contínuas e as saídas são variáveis discretas (BRAGA *et al.*, 2000).

3.2. HISTÓRICO DAS REDES NEURAIS ARTIFICIAIS

Redes neurais surgiram das pesquisas em inteligência artificial, com o intento de imitar a tolerância a falhas e a capacidade de aprendizado de um sistema neural biológico, pela simulação das funções do comportamento do cérebro humano. O cérebro é composto por bilhões de neurônios interconectados, cada qual formado por uma estrutura de entrada, os dendritos, um núcleo celular e uma estrutura de saída, os axônios. Axônios de uma célula conectam-se aos dendritos de outra célula por meio de sinapses. A tarefa dos neurônios é a propagação de sinais eletroquímicos. Um neurônio é ativado quando os sinais eletroquímicos em seus dendritos ultrapassam um certo limiar de disparo. Quando ativado, um neurônio dispara um sinal eletroquímico por meio das suas sinapses para outros neurônios, os quais podem, por sua vez, ser ativados (PONTES, 2006).

A intensidade do sinal recebido por um neurônio depende da eficácia de suas sinapses de entrada. Cada sinapse contém um espaçamento entre seus terminais, no qual neurotransmissores são posicionados para transmitir um sinal de um neurônio a outro. O conhecimento da rede é adquirido por meio de um processo de aprendizado, o aprendizado consiste, principalmente, em alterar a intensidade das sinapses. Desta forma, partindo de unidades de processamento extremamente simples, os neurônios realizam tarefas das mais complexas (CHEN *et al.*, 2015).

O primeiro modelo artificial de neurônio foi introduzido por McCulloch e Pitts, em 1.943. Uma ilustração do conceito de neurônios McCulloch e Pitts é mostrada na Figura 6.

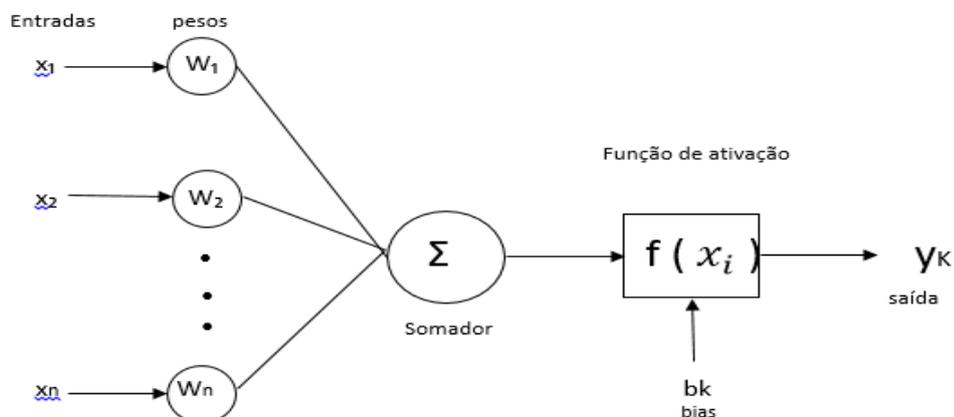


Figura 6 - Modelo do Neurônio artificial de Macculloch e Pitts. Fonte: Pontes (2006).

O neurônio de McCulloch e Pitts é um modelo matemático com n entradas x_1, x_2, \dots, x_n e apenas uma saída y_k . Cada entrada do neurônio traz um peso w_i associado a si. Os valores dos pesos podem ser positivos ou negativos. Pesos representam a intensidade de uma determinada entrada e estão relacionados à forma pela qual o neurônio deve considerar sinais que chegam por ele. A ativação do neurônio é obtida através da aplicação do resultado do produto escalar do vetor de entrada pelo vetor de pesos a um limiar de ativação b_k e a uma função de ativação $f(x)$. O neurônio original de McCulloch e Pitts tem uma função linear binária (HAYKIN, 2001).

Ainda que um único neurônio seja de limitada capacidade de desempenho, uma rede formada por tais unidades pode ser treinada para realizar tarefas mais complexas. Rosenblatt (1958) desenvolveu o perceptron, uma rede formada por neurônios de McCulloch e Pitts com pesos de entrada ajustáveis. Esta rede pode ser treinada para classificar alguns tipos de padrões. O aprendizado do perceptron utiliza o conceito do aprendizado desenvolvido por Hebb (1969).

Segundo HAYKIN (2001), a regra de aprendizado de Hebb propõe que o peso de uma conexão sináptica deve ser ajustado se houver sincronismo entre os

níveis de atividade das entradas e saídas. Se dois neurônios, em lados distintos da sinapse, são ativados sincronamente, teremos um fortalecimento desta sinapse. Entretanto, se os neurônios forem ativados assincronamente, a sinapse será enfraquecida ou mesmo eliminada. Em outras palavras, se o neurônio pré-sináptico tiver grande influência na ativação do neurônio pós-sináptico, a conexão entre eles deve ser reforçada.

Segundo Braga *et al.*, 2000 a sinapse hebbiana possui quatro características principais:

- *Mecanismo interativo*: dentro do aprendizado hebbiano, não se pode analisar atividades pré-sinápticas de forma isolada; qualquer modificação na sinapse hebbiana depende da interação entre os dois tipos de atividade, pré e pós-sinápticos.
- *Mecanismo local*: unia sinapse hebbiana é urna transmissão com sinais contínuos que produz modificações sinápticas locais que são entradas específicas. É a partir do mecanismo local que sinapses hebbianas efetuam o aprendizado não-supervisionado.
- *Mecanismo dependente do tempo*: as modificações em uma sinapse hebbiana dependem do momento exato de ocorrência das atividades pré e pós-sinápticas.
- *Mecanismo correlacional ou conjuncional*: a sinapse hebbiana pode ser chamada de sinapse conjuncional pelo fato de a ocorrência conjunta de atividades pré e pós-sinápticas ser suficiente para que haja uma modificação.

Além disso, pode também ser chamada de sinapse correlacional porque unia correlação entre estas mesmas atividades também é suficiente para gerar mudanças.

Porém, Minsky e Papert demonstraram, matematicamente, que o perceptron era incapaz de solucionar problemas que não são linearmente separáveis. Seu trabalho levou a uma forte retração nas pesquisas em redes neurais durante os anos 1.970. A inexistência ou desconhecimento de algoritmos de treinamento para redes com uma ou mais camadas ocultas, também contribuiu para a estagnação nas pesquisas com redes neurais durante aquele período (BRAGA *et al.*, 2000).

O trabalho de Hopfield (1982) sobre memórias associativas iniciou um novo período de investigação científica sobre o tema. Os trabalhos de Sollich *et al.* (2014) deram origem ao algoritmo de retro propagação, removendo a limitação apontada anos antes por Minsky e Papert. Com efeito, enquanto uma rede sem uma camada oculta pode resolver somente problemas linearmente separáveis, redes com camadas ocultas superam esta limitação (HAYKIN, 2001).

Broomhead e Lowe (1988) apresentaram o procedimento para projeto de redes neurais acíclicas com a utilização de funções de base radial, que se tornaram conhecidas como redes RBF (*Radial Basis Function*). Tais redes provaram constituir-se em alternativas às redes perceptron multicamadas (BRAGA *et al.*, 2000; BALASUBRAMANI e MURUGAN, 2015).

Outras arquiteturas de redes neurais artificiais incluem: redes neurais probabilísticas; redes GRNN (do inglês *Generalized Regression Neural Networks*), introduzidas por Specht (1991); redes SOFM (do inglês *Self-Organized Feature Map*) ou mapas de Kohonen (HAYKIN, 2001).

Neste trabalho, foi utilizada uma rede *Multi Layer Perceptron-MLP*, que foi escolhida por corresponder a uma arquitetura, mais frequentemente, empregada no campo da engenharia mecânica, para classificação e predição de comportamento de propriedades mecânicas. A compreensão do funcionamento desta arquitetura é útil para a compreensão do funcionamento de rede neurais, justificando, assim, a revisão sobre o tema.

3.3. APRENDIZADO

Por aprendizado entende-se o processo pelo qual os parâmetros de uma rede neural são ajustados através de uma forma continuada de estímulo pelo ambiente em que a rede está operando, sendo o tipo específico de aprendizado definido pela maneira particular como ocorrem os ajustes realizados nos parâmetros (HAYKIN, 2001).

Existe, notadamente, dois paradigmas principais de aprendizado: o aprendizado supervisionado e o aprendizado não supervisionado (HAYKIN,2001).

3.3.1. APRENDIZADO SUPERVISIONADO

No aprendizado supervisionado, um conjunto de exemplos, contendo valores de entradas e correspondentes saídas, é reunido por um supervisor e apresentado à rede um certo número de vezes. Durante o treinamento, os parâmetros da rede são ajustados de acordo com algum algoritmo. O objetivo é o ajuste de pesos e limiares de forma a mapear o relacionamento entre as grandezas de entrada e saída (BRAGA *et al.*, 2000; LAKSHMINARAYANAN e BALASUBRAMANIAN, 2009).

Como pode ser observado na Figura 7, a rede utiliza como orientação para o ajuste dos pesos sinápticos um sinal de erro gerado entre a saída esperada e a saída obtida. A cada par entrada-saída esperada apresentada à rede, um sinal de erro é gerado e os pesos sinápticos são ajustados de forma a minimizar o erro de saída da rede. Um dos parâmetros normalmente utilizados para aferição do desempenho de uma RNA é a soma dos erros quadráticos das saídas da rede para todo universo de amostras. O erro quadrático é também utilizado como função objetiva a ser minimizada pelo algoritmo de treinamento. O algoritmo mais utilizado para treinamento supervisionado é o algoritmo de retro propagação.

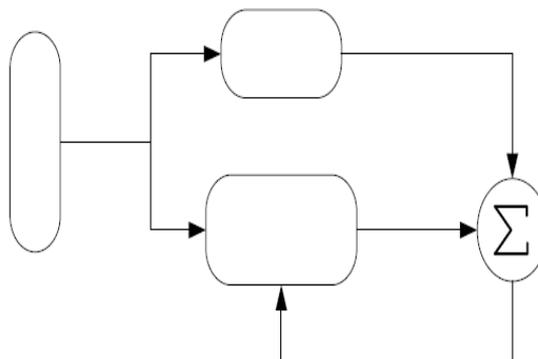


Figura 7 – Esquema do aprendizado supervisionado. Fonte: Oliveira (2005).

Exemplos típicos de aprendizado supervisionado são os problemas de aproximação de funções, modelagem, predição e classificação de sistemas (HAYKIN, 2001).

3.3.2. APRENDIZADO NÃO SUPERVISIONADO

O objetivo de um algoritmo de aprendizagem não supervisionado é descobrir padrões significativos ou características nos dados de entrada, e fazer esta descoberta sem um supervisor.

No aprendizado não supervisionado, como o próprio nome sugere, não há um supervisor para acompanhar o processo de aprendizado, apenas os padrões de entrada são apresentados à rede durante o treinamento. Na medida em que a rede identifica as regularidades estatísticas dos exemplos, ela forma representações internas que codificam características das entradas e permitem seu mapeamento nas saídas. Este tipo de aprendizado é possível quando existe uma certa redundância nos dados de entrada, posto que, sem redundância, é impossível inferir seus padrões ou características. A Figura 8 mostra o esquema do aprendizado não supervisionado (HAYKIN, 2001; MURUGAN *et al.*, 2014).

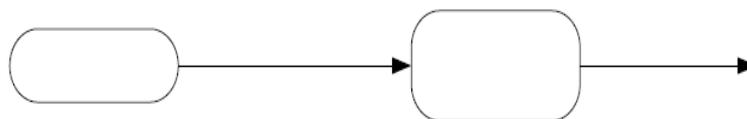


Figura 8 – Esquema do aprendizado não supervisionado. Fonte: Oliveira (2005).

Dentro de cada paradigma, existem diferentes algoritmos de treinamento. Algoritmo de treinamento é um conjunto de procedimentos bem definidos para adaptar os parâmetros de uma rede neural a fim de que a mesma possa aprender uma determinada função. O efeito dos algoritmos de treinamento é o ajuste dos valores dos pesos das sinapses e valores limiares de disparo. O ajuste é feito de tal modo a minimizar o erro de predição da rede (BRAGA *et al.* 2000; DUER *et al.*, 2013).

O erro de predição da rede, para um dado conjunto, pode ser reunido e expresso por meio de alguma função para estimar o desempenho da rede neural. (HAYKIN, 2001; PONTES, 2006).

As RNAs são aplicadas nas mais variadas áreas e são adequadas para aprendizagem periódica, com possibilidade de serem melhoradas de forma incremental, à medida que novos dados e conhecimentos se tornam disponíveis; são apropriadas para a computação em paralelo e têm capacidade de generalização e pode aproximar uma variedade de funções (HAYKIN, 2001).

Toda RNA é treinada para desempenhar uma função específica, bastando, para isso, ajustar os valores dos pesos sinápticos entre os neurônios. O ajuste é feito de modo a minimizar o erro de predição da rede. O erro é definido como a diferença entre o valor real esperado para um determinado conjunto de entrada e o valor obtido para o mesmo conjunto de entrada (HAYKIN, 2001; JEAN, 2009).

Redes neurais podem ser concebidas como uma técnica de interpolação não linear, e seu processo de treinamento é visto como um problema de ajuste de curvas, com capacidade de generalização. Essa capacidade é afetada por três fatores: o tamanho e qualidade do conjunto de treinamento, arquitetura da rede e a complexidade da função que se deseja modelar (SUN, 2011; KHALAJ, 2013).

De modo geral, dado um conjunto de dados $\{x_i, y_i\} \ i = 1, \dots, n$, a partir de uma função de ativação desconhecida $y = f(x)$, a RNA usa algoritmos numéricos para obter estimativas razoáveis da função $f(x)$. Isto envolve três passos: em primeiro lugar, uma estrutura de rede neural é escolhida por ser considerada adequada para o tipo de dados e processos subjacentes a serem modelados; em segundo lugar, a rede neural é treinada utilizando um conjunto suficientemente representativo de dados, e em terceiro lugar, a rede treinada é testada com dados diferentes, a partir das mesmas ou relacionadas com as fontes, para validar o mapeamento a uma qualidade aceitável (DUER *et al.*, 2013; KRANTHI E SATAPATHY, 2014).

Associado a cada neurônio existe um valor ajustável, w_{ij} (peso), forma o vetor: $w_j = (w_{1j}, w_{2j}, w_{3j}, \dots, w_{ij}, \dots, w_{nj})$, em que o peso w_{ij} representa o valor da ligação do neurônio i com o neurônio j . Ocasionalmente, existe um parâmetro adicional (bias) θ_j modulado pelo peso w_{ij} compondo as entradas dos neurônios, que servem para dar estabilidade aos cálculos, especialmente durante a fase de treinamento da rede (DUER *et al.*, 2013).

O somatório das entradas de um neurônio, balanceado por seus respectivos pesos e mais um bias, também ponderado, resulta no valor de entrada do j -ésimo neurônio Z_j . Este é modelado pela função de ativação, gerando a saída efetiva do neurônio y_i , como representado na Equação 4 e 5.

$$Z_j = (\sum x_i w_{ij}) + \theta_j w_{oj} \quad (4)$$

$$y_j = f(Z_j) \quad (5)$$

Existem várias funções de ativação propostas na literatura, as mais utilizadas estão indicadas no Quadro 4 (PHAM,1995; FUJITA, 2001).

Quadro 4 - Tipos de função de ativação mais utilizadas em modelos de RNA.

Tipos de Funções	Função
<i>Linear</i>	$f(s) = s$
<i>De ativação</i>	$f + 1$ se $s > s_t$ $f(s) = -1$ nos demais casos
<i>Sigmoide</i>	$f(s) = 1/(1 + \exp(-s))$
<i>Tangente hiperbólica</i>	$f(s) = (1 - \exp(-2s)) / (1 + \exp(2s))$
<i>Função de base radial</i>	$f(s) = \exp(-s^2 / \beta^2)$

Fonte: Pham (1995).

A maioria das redes multicamadas, como a rede de arquitetura Perceptron Multi-Camada-MLP, utiliza o produto escalar do vetor de entrada e o vetor pesos deste nó. Existe, porém, a rede Função de Base Radial-RBF (*Radial Basis Function*), uma rede multicamadas em que a ativação de um nó pode ser função da distância entre seus vetores de entrada e seus pesos (CHOUDHURY *et al.*, 2013).

3.4. REDES DE ARQUITETURA PERCEPTRON MULTICAMADAS - MLP

Redes com arquitetura *Perceptron* multicamada, ou MLP, do inglês *Multi Layer Perceptron*, constituem o modelo de redes neurais mais difundido na literatura. Cada unidade desse tipo de rede efetua o produto escalar do seu vetor de entrada pelo vetor de pesos associados a cada entrada. O resultado é comparado a um valor de limiar. Em caso de disparo, o resultado do produto escalar é utilizado como variável independente de uma função de ativação, cuja variável dependente constituirá a saída do neurônio. A função sigmoide é

a mais comumente utilizada como função de ativação, embora funções lineares, gaussianas e hiperbólicas também sejam utilizadas. Os neurônios são conectados em modo acíclico ou *feedforward*. Isso significa que neurônios de uma camada são ligados a cada neurônio da camada seguinte (HAYKIN, 2001; LIU *et al.*, 2015).

Uma rede MLP consiste numa camada de entrada, diversas camadas ocultas e uma camada de saída. Um neurônio de uma rede MLP é mostrado na Figura 9 12, que contém uma função de ativação não linear g .

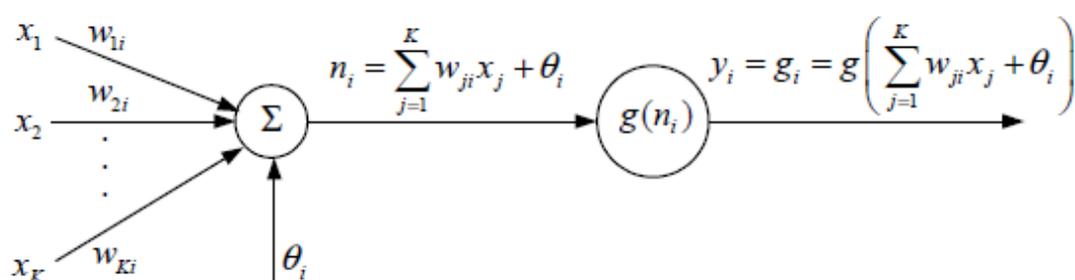


Figura 9 - Mostra um neurônio com função de ativação não linear. Fonte: Koivo (2008).

As entradas x_k , $k = 1, \dots, K$ são multiplicadas pelos pesos w_{ki} somados em conjunto com o termo de bias ou incrementos de ajustes constante θ_i . O resultado n_i são as entradas para a função de ativação g . As funções de ativação mais utilizadas são a função tangente hiperbólica e a função sigmoide. A função tangente hiperbólica e a função tangente sigmoide são formuladas como a equação 6, a seguir:

$$g(x) = \tanh(x) = \frac{1 - e^{-x}}{1 + e^x} \quad (6)$$

a saída do nó i torna-se

$$y_i = g_i = g\left(\sum_{j=1}^k w_{ji} x_j + \theta_i\right) \quad (7)$$

Conectando vários neurônios em paralelo e em série, uma rede MLP é formada. Uma típica rede MLP é mostrada na Figura 10.

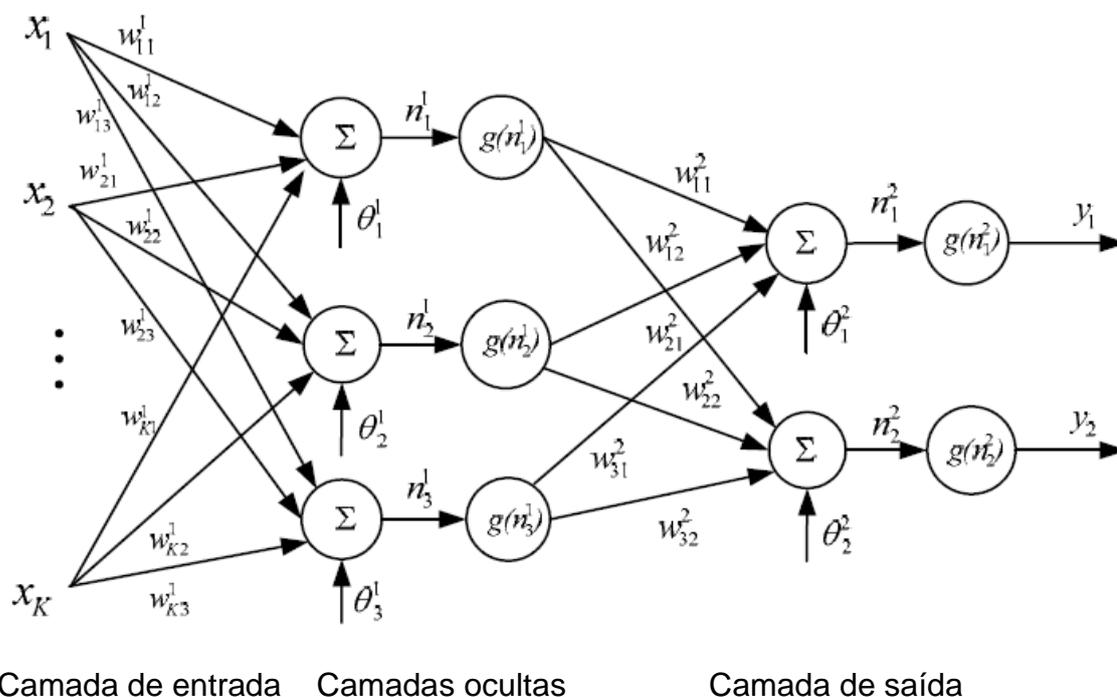


Figura. 10 - Arquitetura de uma rede perceptron multicamadas MLP. Fonte: Koivo (2008).

A saída y_i , $i = 1, 2$ da rede MLP torna-se:

$$y_i = g\left(\sum_{j=1}^3 w_{ji}^2 g(n_j^1) + \theta_i^2\right) = g\left(\sum_{j=1}^3 w_{ji}^2 g\left(\sum_{k=1}^K w_{kj}^1 x_k + \theta_j^1\right) + \theta_i^2\right) \quad (8)$$

A partir da equação 8, pode-se concluir que uma rede MLP é um mapa com parâmetros não-lineares do espaço de entrada $x \in R^k$ para o espaço de saída $y \in R^m$, com $m = 3$, neste exemplo. Os parâmetros são os pesos w_{ji}^k e os vieses ou incrementos de ajustes θ_j^k . A função de ativação g é utilizada em todas as camadas (CHOUDHURY *et al.*, 2013).

3.5. REDES NEURAS DE FUNÇÃO DE BASE RADIAL - RBF.

As redes neurais de funções de base radial representam uma classe de funções cujo valor diminui ou aumenta em função da distância a um ponto central. São utilizadas para tarefas de interpolação de conjuntos de pontos em espaços multidimensionais. O problema é caracterizado pelo mapeamento de um espaço vetorial \vec{X} de dimensão d em um espaço vetorial unidimensional t . O conjunto de dados consiste de N vetores de entrada $x^{\rightarrow n}$ e seus correspondentes valores t . O objetivo é encontrar uma função $h(\vec{x})$, como na equação 9 (HAYKIN, 2001; BODYANSKIY *et al.*, 2015).

$$h(x^{\rightarrow n}) = \vec{t}, n = 1, \dots, N \quad (9)$$

O uso de funções de base radial se mostra apropriado na tarefa de interpolação, com uso de conjuntos de N funções de base, uma para cada nó, sendo as funções dadas pela equação 10,

$$\emptyset(\|x^{\rightarrow} - x^{\rightarrow n}\|) \quad (10)$$

onde o argumento \emptyset é uma norma euclidiana entre os vetores x^{\rightarrow} e $x^{\rightarrow n}$ (BALASUBRAMANI E MURUGAN, 2015).

A função de base radial mais utilizada é a função gaussiana dada pela equação 11 (DUER *et al.*, 2013),

$$\emptyset_j(\mu) = -exp\left(\frac{\|x^{\rightarrow} - \mu_j\|^2}{2\sigma^2}\right), \quad (11)$$

em que x^{\rightarrow} corresponde a um dos vetores de entrada $x^{\rightarrow n}$, com elementos x_i . $\vec{\mu}_i$ é um vetor que determina o centro para função \emptyset_j e possui elementos μ_{ij} e σ representa um parâmetro que define a largura da mesma, isto é: a amplitude do decremento do valor de saída da função de ativação à medida que varia a distância ao centro. O conceito de funções de base radial é

ilustrado na figura 11. Seu pico localiza-se no centro e decresce em função da distância a este (Manual Mathematica, 2015; DUER *et al*, 2013).

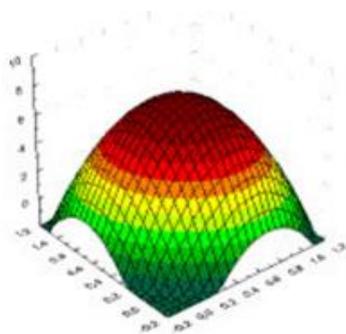


Figura 11 - Linhas das curvas de níveis da função de base radial.
Fonte: (Manual Mathematica, 2015).

Redes RBF constituem uma arquitetura de redes neurais multicamadas na qual as funções de ativação de cada unidade da camada oculta utilizam como argumento da sua função de ativação a distância entre seus vetores, chamada de unidades radiais (BRAGA *et al.*, 2000; DUER *et al.*, 2013).

Cada camada da rede desempenha uma função distinta e cada unidade radial modela uma função de ativação. A camada oculta organiza os dados de entrada em agrupamentos e transforma um conjunto de padrões de entrada não linearmente separáveis em um conjunto de saídas linearmente separáveis, as saídas da camada oculta são combinadas linearmente para formar a saída da rede (PONTES, 2006).

A camada de saída de uma rede RBF geralmente é linear. Isso significa que a função de ativação dos neurônios daquela camada é unitária. A saída, nestas condições, é simplesmente o produto escalar do vetor de saída da camada oculta pelo vetor de pesos da unidade radial (SHIFEI *et al.*, 2013).

A função radial é, geralmente, uma função gaussiana, do tipo mostrado na equação 8, na qual o vetor \vec{x} corresponde ao vetor de entrada da unidade radial e $\vec{\mu}_j$ representa o centro da função radial. Em uma rede RBF com k

unidades radiais na camada oculta e uma única saída são dadas pela equação 12 (SHIFEI *et al.*, 2013).

$$y = \sum_{i=1}^k w_i \phi(\|\vec{x} - \vec{\mu}\|)^2 + w_0 \quad (12)$$

onde k é o número de unidades radiais presentes na camada oculta, ϕ representa a função de ativação das unidades radiais, como, por exemplo, a função gaussiana representada pela equação 9, w_i representa os pesos pelos quais a saída de uma unidade radial é multiplicado (SHIFEI *et al.*, 2013).

A figura 12, a seguir, ilustra o conceito de uma rede RBF. Mostram-se as três camadas componentes: a camada de entrada, a camada oculta e a camada de saída, onde $x_1, \dots, x_j, \dots, x_n$, correspondem aos elementos do vetor de entrada da rede. As unidades radiais são mostradas cada qual com sua função de ativação $\phi_1(\vec{x}), \dots, \phi_j(\vec{x}), \dots, \phi_m(\vec{x})$. Os valores $w_1, \dots, w_j, \dots, w_m$, representam os valores dos pesos das sinapses localizadas entre a camada oculta e a camada de saída. A saída da rede neural em função do vetor de entrada é representada por $y(\vec{x})$.

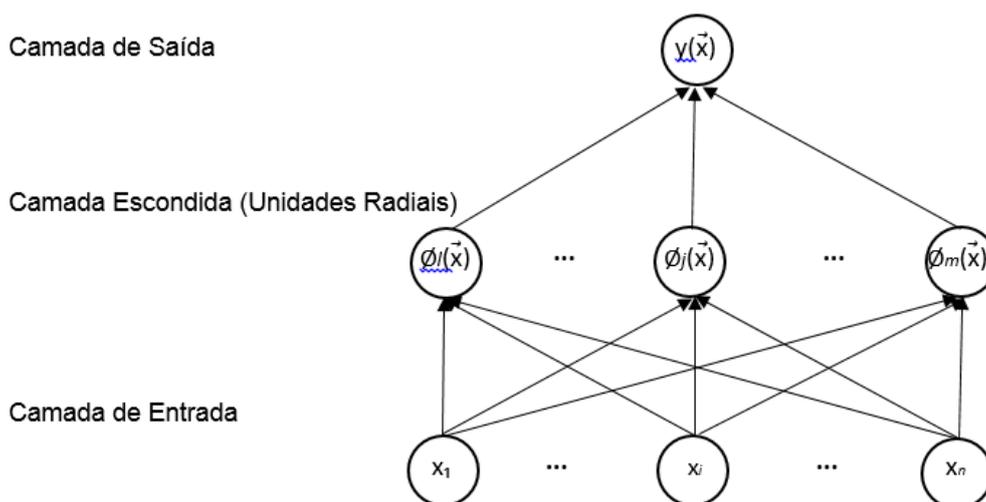


Figura 12 – Arquitetura de uma rede neural de função de base radial.

Fonte: adaptado de Pontes, 2006

Em uma rede RBF, os erros e os desvios podem ser calculados utilizando o processo de retro propagação, que envolve três fases (HAYKIN, 2001; ÇETIN *et al.*, 2015):

- A alimentação de entrada do padrão;
- Cálculo e a retro propagação do erro associado;
- O ajuste das ponderações. Este processo pode ser usado com um número de diferentes estratégias de otimização.

Cada camada de uma rede neural pode ter números diferentes de elementos. Como na natureza, a função da rede é determinada pelas ligações entre estes elementos, a relação entre o vetor de entrada $X_i^{(n)}$ e o vetor de saída $X_j^{(n+1)}$ pode ser descrito como na equação 13.

$$X_j^{(n+1)} = F \left(\sum W_{ji}^{(n)} X_i^{(n)} \right) \quad (13)$$

em que $F(x)$ é a função tangente sigmóide,

$$F(x) = \frac{\exp(x) - \exp(-x)}{\exp(x) + \exp(-x)} \quad (14)$$

O procedimento de aprendizagem é baseado em uma pesquisa de gradiente do erro, com o critério de otimização da soma dos mínimos quadrados dos erros entre os valores previstos e desejados, por meio de $X_{ij}^{(n)}$

$$E = \sum_{p=1}^p (d_p - o_p)^2 \quad (15)$$

A soma total de erro quadrático médio E de todos os padrões no conjunto de treinamento, em que d_p é a saída alvo (previsto) para o p-ésimo padrão e o_p é a saída real medida. No processo de minimização, os pesos de todos os nós de ligação são ajustados até que o nível desejado do erro seja alcançado ou o número máximo de ciclos seja atingido. O algoritmo de aprendizagem utilizado para os pesos é dado pela equação 16 (DUER *et al.*, 2013).

$$W_{ji}^{(n)}(t + 1) = W_{ji}^{(n)}(t) + \Delta W_{ji}^{(n)}(t) \quad (16)$$

com a sua correção pela equação 17,

$$(t + 1) = -n \frac{\sigma E}{\rho W_{ji}^{(n)}} + \mu \Delta W_{ji}^{(n)}(t) \quad (17)$$

onde $\Delta W_{ji}^{(n)}(t)$ é a correção do peso no t -ésimo passo de treinamento, n é a taxa de aprendizagem, e μ é o fator de impulso. n é um pequeno parâmetro para ajustar a correção um de cada vez, e μ reduz a oscilação e auxilia a convergência rápida. Os valores apropriados destes parâmetros ajudam a aprendizagem (HASSAN *et al.*, 2009).

Uma vez que a arquitetura de rede seja definida, em seguida, através de um processo de aprendizagem, os pesos são calculados de modo a apresentar o resultado desejado. Para isso a entrada dos nós individuais da RNA deve ser numérica e cair no intervalo fechado $[0,1]$. Devido a este método de conversão da técnica de normalização foi utilizado na RNA de acordo com a equação 18 (SOUSA *et al.*, 2009).

$$V_n = \frac{V_{ent} - V_{min}}{V_{max} - V_{min}} \quad (18)$$

onde V_n é o valor normalizado, V_{ent} é o valor de entrada, V_{min} é o valor mínimo, V_{max} é o valor máximo. Os valores de saída da RNA também devem cair no intervalo fechado $[0,1]$ e convertidos para os seus valores equivalentes com base no método reverso das técnicas de normalização (KHALAJ, 2013).

As aplicações mais adequadas para as RNAs são aquelas que têm as seguintes características:

- Que tenha disponível um grande banco de dados;

- É difícil encontrar uma solução exata para o problema por abordagens matemática algorítmica;
- O conjunto de dados é incompleto, com muitos ruídos.

A avaliação do desempenho do treino da RNA, é dado pela razão do erro quadrático médio - RMSE, dado pela fórmula 19 (KHALAJ, 2013).

$$RMSE = \sqrt{\frac{\sum(\theta - \theta_0)^2}{\sum \theta^2}}, \quad (19)$$

onde θ é o valor experimental e θ_0 representa o valor de saída previsto para cada nó de saída. A qualidade da previsão pode ser normalmente caracterizada pelo erro quadrático médio (RMSE) dos valores previstos a partir dos dados reais medidos. Quanto menor o RMSE do conjunto de dados de ensaio, mais elevada é a qualidade preditiva da rede (HASSAN *et al.*, 2009).

É importante avaliar o desempenho do modelo de RNA. Isto é feito através da separação dos dados em dois conjuntos: o conjunto de treino e o conjunto de validação. O valor dos pesos sinápticos da rede é calculado utilizando o conjunto de treino. Ao atingir a meta de erro o processo de aprendizagem é interrompido e a rede é avaliada com os dados do conjunto de validação (KHALAJ, 2013).

A qualidade de uma rede pode ser dada pelo cálculo do coeficiente de determinação R^2 definida pela equação 20:

$$R^2 = 1 - \frac{\sum_{i=1}^m (Op^{(i)} - O^{(i)})^2}{\sum_{i=1}^m (O^{(i)} - O)^2}, \quad (20)$$

Em que $Op^{(i)}$ é a i -ésima característica da propriedade predita $O^{(i)}$ e o i -ésimo valor medido, O é a média de $O^{(i)}$ e M é o número de dados de teste. O coeficiente R^2 descreve o ajuste de saída de resposta de aproximação variável da RNA à curva variável de saída de dados de teste real. Maiores coeficientes

de determinação R^2 indicam uma RNA com melhor capacidade de aproximação aos dados reais de saída (SHIFEI *et al.*, 2013).

A maior vantagem das RNAs é a sua capacidade de modelar relações funcionais não lineares e complexas e relações multidimensionais sem quaisquer suposições anteriores sobre a natureza destas relações. No entanto, há limitações com as redes neurais, que são enumeradas como segue (SHIFEI *et al.*, 2013):

- A formação do banco de dados deve ter um fino relacionamento com os parâmetros preditos;
- É necessário um grande banco de dados para treinamento da RNA;
- RNAs são puramente fenomenológicas e não inerentemente produzem um entendimento mecanicista do processo que está sendo modelado.

As redes neurais artificiais (RNAs) são um robusto e inteligente sistema de tratamento de informação, são ferramentas poderosas e amplamente utilizadas no campo das ciências dos materiais, incluindo o desenvolvimento das relações das propriedades mecânicas (SUN *et al.*, 2011; CULLITON *et al.*, 2013).

Uma RNA fornece um conjunto de dados de saída como resposta a um conjunto de dados de entrada. Pode modelar o comportamento do modo de desgaste por meio da aprendizagem das características dos parâmetros do processo de aspersão, das variáveis e dos fatores que os influenciam, tais como: ângulo de impacto da partícula com o substrato, métodos de aspersão, materiais de revestimentos, velocidade de impacto das partículas, de modo a permitir prever o comportamento do desgaste erosivo de superfície aspergida termicamente (SUN *et al.*, 2011; SZYMAŃSKI *et al.*, 2015).

3.6. TREINAMENTO DE UMA REDE NEURAL

O treinamento de uma rede neural consiste em um procedimento numérico para estimar os pesos; geralmente é baseado na minimização de uma função que depende do erro apresentado na saída da rede. São vários os tipos de treinamento, cada um apropriado para uma determinada finalidade. Os mais recorrentes na literatura são o treinamento rede feedforward; retro propagação e Algoritmo dos Mínimos Quadrados.

Independente do algoritmo usado para treinar a RNA, atenção voltada para a inicialização e ajuste de pesos é fundamental para a convergência e para evitar *Overfitting*, problema que geralmente acontece em padrões de treinamento. Algoritmos de aprendizagem são utilizados para ajustar os valores de peso, *backpropagation* (BP) é o mais popular, com base no método gradiente descendente, é eficiente para treinar RNA. No entanto, este algoritmo é sensível a mínimos locais e requer ajustes no coeficiente de aprendizagem. Como alternativa, os algoritmos evolutivos podem ser aplicados na pesquisa de pesos de uma rede para escapar de mínimos locais (SLOWIK, 2011).

3.6.1. TREINAMENTO DE REDES *FEEDFORWARD*

Dentre os principais tipos de redes *feedforward*, destaca-se o *multilayer perceptron* (MLP). Redes MLP consistem em múltiplas camadas: uma camada de entrada, uma ou mais camadas escondidas e uma camada de saída. Cada camada possui nós e cada nó está totalmente interligado por pesos com todos os nós da camada subsequente. O MLP transforma entradas em saídas por meio de alguma função não-linear como:

$$X_o = f\left(\sum_{h=1}^H (X_h * W_{h,o})\right) \quad (21)$$

Em que $f()$ é a função de ativação do o -ésimo neurônio da camada de saída, X_h é a saída do h -ésimo neurônio da camada escondida e $W_{h,o}$ é a interconexão

entre o h -ésimo neurônio da camada escondida e o o -ésimo neurônio da camada de saída (YILMAZ e KAYNAR, 2011).

O algoritmo consiste em uma fórmula recorrente para obter a variação apresentada na saída de um dado neurônio, quando um dos pesos da rede é alterado. Pode ser descrito em termos das derivadas dos neurônios da camada imediatamente anterior, o que caracteriza uma relação recorrente. Com isso a derivada é obtida para a saída apresentada na última camada, a seguir para a penúltima, e assim por diante. O algoritmo do gradiente utiliza essa forma de retro propagação para propagar o erro na saída da rede até as camadas ocultas, para com isso efetuar um ajuste nas matrizes de pesos (CARRARA, 1997; YILMAZ e KAYNAR, 2011)).

O algoritmo de retro propagação é formado pela derivada parcial do valor apresentado na saída de um determinado neurônio com relação a um determinado peso da camada anterior. Considere então a componente i do vetor x^k apresentado na saída da camada k . A derivada dessa componente com relação ao peso j associado a esse neurônio é obtida derivando-se a expressão

$$x^k = f^k(w^k x^{k-1}) \quad (22)$$

resulta:

$$\frac{\partial x_i^k}{\partial w_{ij}^k} = f^{k'}(x_i^{k-1}) x_j^{k-1} \quad (23)$$

na qual $f^{k'}(x)$ é a derivada da função de ativação da camada k com relação ao seu argumento. Em termos vetoriais a derivada parcial fica (CONTRUCCI, 2012):

$$\frac{\partial x^k}{\partial w_{ij}^k} = F^k \begin{vmatrix} 0 \\ x_j^{k-1} \\ 0 \\ 0 \end{vmatrix} \quad (24)$$

na qual todas as componentes da última parcela são nulas, exceto a i -ésima componente, e F^k é uma matriz diagonal contendo as derivadas da função de ativação.

Sendo a equação de ativação conhecida e contínua. O esquema do treinamento de uma rede *feedforward*, com seus elementos característicos, esta representado na Figura 13.

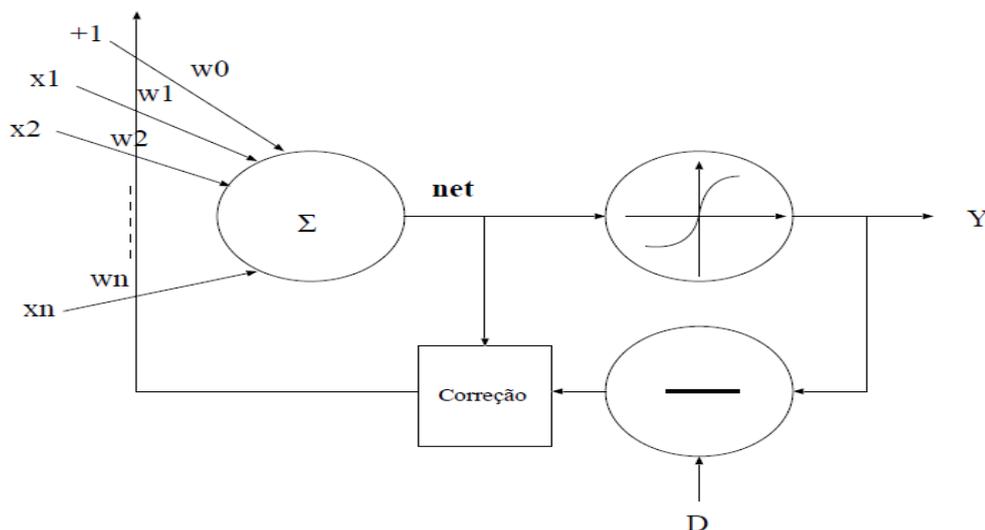


Figura 13 - Esquema de uma rede *feedforward*. Fonte: adaptado de DAS (2012).

Cada ciclo ou épocas tem duas fases, a primeira é *Forward*, da camada de entrada para a camada de saída. Com a apresentação das entradas e geração das saídas equivalentes; a segunda é *Backward*. Da camada de saída para a camada de entrada, com a atualização dos pesos, das camadas intermediárias, faz a estimativa do erro a partir do erro da camada seguinte. Os pesos são ajustados após a apresentação de k exemplos do conjunto de treinamento.

Normalmente, o critério de parada do treinamento é feito pelo número de ciclos de treinamento; neste caso, o treinamento para após a execução de k ciclos de treinamento. Ou pelo valor do erro ou métrica usada. Assim, o treinamento para quando o valor do erro é menor do que um valor estimado. Ou ainda, pelo critério de validação, o treinamento de aprendizado da rede para quando o erro no conjunto de validação deixa de decrescer (CONTRUCCI, 2012).

3.6.2. TREINAMENTO DE REDES NEURAL COM ALGORITMOS DE RETRO PROPAGAÇÃO.

O algoritmo de treinamento, conhecido como gradiente do erro, e como retro propagação, é o mais difundido e utilizado entre todos os outros algoritmos de treinamento. A sua principal vantagem reside no alto grau de paralelismo alcançado por esse método na atualização dos pesos da rede (HUNT *et al.*, 1992).

Sua origem remonta ao início da década de 1.960, quando Widrow e Hoff propuseram um circuito para uso em filtragem de sinal, sendo denominado de Adaline (NGUYEN e WIDROW, 1990).

A saída única desse circuito foi obtida pela adição das entradas ponderadas por pesos e, a seguir, submetendo este resultado a uma função não-linear, originalmente uma função sinal, ou degrau. Os pesos foram ajustados meio de um processo de minimização do erro apresentado na saída, o que levava a uma solução de mínimos quadrados. Dessa forma, uma rede Adaline pode ser visualizada como uma rede neural de uma única camada (CARRARA, 1997).

O aprendizado via algoritmo do gradiente do erro foi adaptado da generalização do método de *Widrow-Hoff* para redes de multicamadas e funções de ativação diferenciáveis e não lineares. Da mesma forma que na rede Adaline, o algoritmo do gradiente usa um critério de minimização do erro da rede no ajuste dos pesos durante a fase de aprendizagem. Como resultado,

o algoritmo de ajuste caminha na direção do gradiente da função a ser minimizada, provocando uma convergência segura (CONTRUCCI, 2012).

Os pesos começam a ser ajustados a partir da última camada dos neurônios e, com isso, fornecem informações suficientes para o ajuste do peso na camada anterior e assim sucessivamente. A função a ser minimizada, nesse caso, é o erro quadrático na saída da rede, ou seja, (RUMELHART, HILTON e WILLIAMS, 1986):

$$j(t) = \frac{1}{2} \varepsilon(t)^T \varepsilon(t) \quad (25)$$

em que $\varepsilon(t)$ é o erro na saída da rede, no instante t , e vale:

$$\varepsilon(t) = y^d(t) - y(t) \quad (26)$$

onde $y^d(t)$ é o vetor de saída desejada para a rede e T é a magnitude de erro. O gradiente dessa função com relação aos pesos da camada k dos neurônios, já incluindo o patamar de ativação na última coluna, é definido pela matriz:

$$\nabla J^k = \begin{bmatrix} \frac{\partial J}{\partial u_{11}^k} & \cdots & \frac{\partial J}{\partial u_{im_{k+1}+1}^k} \\ \frac{\partial J}{\partial u_{n_{k+1}}^k} & \cdots & \frac{\partial J}{\partial w_{n_{k+1}+1}^k} \end{bmatrix} \quad (27)$$

O ajuste dos pesos se faz na direção do gradiente da função, conforme a equação:

$$W^k(t+1) = W^k(t) - \lambda \nabla J^k \quad (28)$$

e onde a matriz de pesos W^k é dada por:

$$W^k = \begin{bmatrix} w_{11}^k & \cdots & w_{1n_{k-1}+1}^k \\ \vdots & & \vdots \\ w_{n_{i1}}^k & \cdots & w_{n_{kn_{k-1}+1}}^k \end{bmatrix} \quad (29)$$

sendo que os patamares de ativação da camada k estão representados pelos pesos da última coluna, λ é o parâmetro de convergência do aprendizado, compreendido normalmente entre 0 e 1.

Quanto maior o valor de λ mais rápido o aprendizado, porém não se consegue boa estabilidade dos coeficientes quando a rede adquire conhecimento do sistema. Por outro lado, valores pequenos de λ acarretam tempos de aprendizado extremamente longos e frequentemente podem fazer com que o processo de treinamento fique preso a um mínimo local.

A derivada da função com relação ao peso j associado ao neurônio i da camada k é obtida derivando-se a equação 32, e como o vetor de saída da rede $y(t)$ é dado por

$$y(t) = x^1(t) \quad (30)$$

obtem-se a equação:

$$\frac{\partial J}{\partial w_{ij}^k} = -\varepsilon^T \frac{\partial x^1}{\partial w_{ij}^k} \quad (31)$$

na forma matricial fica, a partir da equação (19)

$$\frac{\partial J}{\partial w_{ij}^k} = -\varepsilon^T \Delta^k \begin{vmatrix} 0 \\ 0 \\ x_j^{k-1} \\ 0 \\ 0 \end{vmatrix} \quad (32)$$

que pode ser simplificada, resultando:

$$\frac{\partial J}{\partial w_{ij}^k} = -x_j^{k-1} \sum_{n=1}^{n_i} \varepsilon_n \delta_{n,j}^k \quad (33)$$

Nota-se que esse resultado indica que a derivada da função depende exclusivamente da componente j do vetor de entrada da camada $k - 1$ e da coluna da matriz δ^k . Isso sugere que o gradiente pode ser colocado em termos de operações entre matrizes, que resulta, após algumas manipulações:

$$\nabla J^k = -\Delta^{kT} \varepsilon \chi^{(k-1)T} \quad (34)$$

derivando e simplificando fica:

$$\frac{\partial J}{\partial w_{ij}^k} = -\delta_i^k x_j^{k-1} \quad (35)$$

na qual o escalar δ_i^k é a i -ésima componente do vetor δ^k . Por sua vez, o gradiente fica expresso pelo produto do vetor δ^k pelo vetor χ^{k-1} , ou seja:

$$\nabla J^k = -\delta^k \chi^{(k-1)T} \quad (36)$$

O algoritmo de retro propagação resulta da otimização e, como todo processo desse tipo, pode levar o resultado para um mínimo local. Um passo de aprendizado ou parâmetros de convergência elevados podem levar o processo de aprendizado para uma situação instável, enquanto que valores pequenos resultam numa razão de convergência muito baixa. Para contornar esse problema e também para acelerar o processo de aprendizado, foram desenvolvidos métodos de ajuste de λ , de forma a se ter valores grandes no início do aprendizado e reduzi-lo, à medida que a rede caminha para a solução absoluta. Ainda assim, dada a grande quantidade de variáveis envolvidas, o processo de aprendizado de uma rede multicamadas, via retro propagação é demasiadamente lento, exceto nos casos em que o treinamento é realizado num conjunto reduzido de valores (CHEN e BILLINGS, 1992).

3.6.3. TREINAMENTO COM O ALGORITMO DOS MÍNIMOS QUADRADOS

Seja a função $y(t)$ o vetor com dimensão n_l de saída da rede neural no instante t , função dos pesos dos neurônios $w(t)$ e do vetor de entrada $x(t)$, de dimensão n_l no mesmo instante:

$$y(t) = f(x(t).w(t)) \quad (37)$$

Nesse caso, optamos por representar todos os pesos dos diversos neurônios que compõem a rede em um único vetor $w(t)$. Os algoritmos para estimar os parâmetros foram desenvolvidos para sistemas lineares e, como a função $f(t)$ é não-linear, efetua-se uma linearização da mesma em torno do instante $t-1$, no qual, por hipótese, são conhecidos os pesos. Desta forma, como o vetor de entrada $x(t)$ não varia durante o processo de atualização dos pesos e desprezando os termos de segunda ordem, temos (CONTRUCCI, 2012):

$$y(t) = y(t-1) + \frac{\partial y}{\partial w} |_{t-1} [w(t) - w(t-1)] \quad (38)$$

Essa expressão pode ser posta em termos do erro apresentado na saída da rede, bastando, para isso, substituir o valor de $y(t)$, reagrupando-se os termos, chega-se a:

$$Z(t) = H(t)w(t) + \varepsilon(t) \quad (39)$$

onde a matriz de derivadas da saída da rede, $H(t)$, vale:

$$H(t) = \frac{\partial y}{\partial w} |_{t-1} \quad (40)$$

e o vetor $z(t)$ é dado por:

$$z(t) = y^d(t) - y(t-1) + H(t)w(t-1) \quad (41)$$

A equação 30 está na forma de um sistema linear e, neste caso, pode-se aplicar um método para estimar os parâmetros com informação a priori, de forma a se obter o vetor de pesos w . O algoritmo dos mínimos quadrados é obtido a partir da minimização de uma função representada por uma ponderação da informação a priori e do erro quadrático médio na saída (CARRARA, 1997).

3.7. REDES NEURAS APLICADAS À PREDIÇÃO DO COMPORTAMENTO DO DESGASTE EROSIVO

Algumas aplicações, descritas a seguir, mostram que as redes neurais estão sendo utilizadas em muitos ramos da engenharia e têm se revelado adequadas para o desenvolvimento de modelos de predição de sistemas complexos, onde o desenvolvimento de modelos com base nos conceitos físicos seja difícil.

Para Lalithamma e Puttaswamy (2013), as aplicações de redes neurais na determinação da resistência ao desgaste de alguns materiais têm sido estudadas com sucesso, no entanto, há poucos relatos sobre a RNA aplicada à tenacidade de revestimentos aplicados por aspersão térmica.

Ao investigar a influência de diferentes proporções de oxigênio, da velocidade e da temperatura das partículas por meio das redes neurais artificiais, Picas *et al.*, (2013) estabeleceu os efeitos sobre a qualidade dos revestimentos em relação ao comportamento contra a erosão de revestimento feito pelo processo HVOF com o cermet WC-CoCr. Os resultados mostram que a velocidade das partículas tem um efeito significativo sobre a porosidade, dureza e resistência à erosão. A maior resistência à erosão é obtida com os parâmetros que permitem uma fusão suficiente dos aglomerados e a descarburização das partículas de WC.

Zhao *et al.* (2004) estudaram a aplicação do cermet WC-CoCr na forma de pó aspergido pelo processo HVOF com a variação dos parâmetros de aspersão para estudar a sua influência sobre as propriedades das partículas em voo e as propriedades de revestimento resultantes utilizando uma rede neural para

classificar a influência de cada um. O comportamento de desgaste dos revestimentos foi avaliado tanto por testes de rodas de borracha, como pino sobre disco. Verificaram que a taxa de alimentação do gás e do pó influenciam fortemente as propriedades das partículas em voo. A distância de aspersão teve menor influência na resistência ao desgaste dos revestimentos.

Wang *et al.* (2013) compararam os revestimentos de WC-10Co-4Cr depositados com o processo de aspersão HVOF e *Flame Spray*. Os resultados experimentais indicaram que a descarburização do WC no revestimento WC-10Co4Cr foi dramaticamente influenciada pelo equipamento de aspersão em termos de dureza, resistência à fratura e desgaste erosivo. Os testes de treinamento da rede neural foram inicialmente preparados utilizando resultados experimentais. Os resultados do teste revelaram que a resistência à flexão e dureza dos compósitos aumentou com a diminuição da ductilidade e com a diminuição do tamanho das partículas.

Chen *et al.* (2015) utilizaram um modelo de rede neural para investigar a influência da porosidade sobre erosão de partículas de materiais compósitos com o objetivo de compreender melhor o mecanismo de erosão das amostras de partícula sólida com diferentes densidades de poros. Encontraram coerência entre a modelagem e observações experimentais.

Por sua vez, Murugan *et al.* (2014) utilizaram um modelo de rede neural para encontrar a influência dos parâmetros: fluxo de oxigênio; vazão de gás; taxa de alimentação de pó e distância padrão de aspersão sobre a qualidade final do revestimento executado por HVOF. Chegaram à conclusão que o processo de aspersão influencia fortemente a porosidade da superfície final.

A taxa de desgaste erosivo depende dos parâmetros como: fluxo das partículas, ângulo de impacto, velocidade das partículas erodentes e também, das propriedades das partículas, do substrato, do processo de aspersão e de outros parâmetros de aspersão. Portanto, para levar em conta estes e outros fatores na predição no comportamento da taxa de desgaste erosivo, é recomendável que alguma técnica numérica seja levada em consideração. As

redes neurais artificiais têm se revelado adequadas para este propósito (MISHRA, 2010).

A vantagem da utilização de modelo de rede neural é que ele pode prever uma saída com precisão, mesmo se as interações entre variáveis não sejam completamente conhecidas ou tenha sido treinada anteriormente (MISHRA *et al.*, 2010; HAMDIA *et al.*, 2015).

A capacidade de aprender através de exemplos e de generalizar a informação aprendida é o atrativo principal da solução de problemas através de redes neurais artificiais (HAYKIN, 2001; RODRÍGUEZ *et al.*, 2013).

A generalização que está associada à capacidade de a rede aprender através de exemplos e posteriormente dar respostas coerentes para dados não conhecidos é uma demonstração de que a capacidade das RNAs vai muito além do que simplesmente mapear relações de entrada e saída (BRAGA *et al.*, 2000; RODRÍGUEZ *et al.*, 2013).

4. MATERIAIS E MÉTODOS

4.1 Materiais utilizados na pesquisa

Os materiais utilizados para os revestimentos deste trabalho foram aspergidos sobre um substrato de aço de baixo carbono (ASTM 1020), utilizando os processos de aspersão térmica HVOF e *Flame spray-FS/FlexiCords-FC*, com consumíveis na forma de pó e cordões flexíveis, respectivamente. O material do substrato foi preparado com as dimensões (180x70x3 mm) e sua superfície foi tratada antes de iniciar o processo de aspersão térmica.

Inicialmente, a superfície foi usinada e lavada com óxido de alumínio para remover impurezas e induzir a rugosidade, visando a garantir uma forte ligação mecânica entre o revestimento e o substrato. A espessura média dos revestimentos foi de 500 μm . Todos estes passos foram executados na empresa brasileira OGRAMAC, reconhecida por suas contribuições para a pesquisa relacionada à engenharia de superfícies. A Tabela 2 mostra os materiais utilizados nos experimentos de coleta dos dados de desgaste e de tenacidade à fratura.

Tabela 2. Materiais e processos utilizados para aquisição de dados na pesquisa

HVOF			FS/FC	
Material (pó)	Tamanho (μm)	Densidade g/cm^3	Material (cordão)	Densidade g/cm^3
Colmonoy 88HV (Hasteloy)	5/10	4,78	HardKarb 15HC D4.75 (Hasteloy)	13,30
1350VM/WC-731-1	-45/+15	5,02	HardKarb 1350	13,30
Amperit Cr_3C_2 NiCr75-25	-45/+15	2,90	KhromKarb Fine (75CrCo/25NiCr)	7,10
Amperit WC-Co88-12	-45/+15	3,90	HardKarb 12Co-F D4.75	13,70
Durmat 135.015	-25/+10	5,46	Roc Dur 62	8,20

4.2 O processo de aspersão HVOF e material de recobrimento.

Para o processo HVOF, foram utilizados pós comerciais, aglomerados e sinterizados, fornecidos por várias empresas. Os valores da densidade e da composição química destes materiais estão apresentados na Tabela 3.

Tabela 3 – Composição química e densidade dos materiais (pós) usados no processo HVOF.

Materiais Depositados	Densidade (g/cm ³)	Composição química (% Wt)							
		W	Co	Cr	B	Ni	Si	Al	Fe
Colmonoy 88HV	4,78	16,5		15,0	3,0	Bal.	4,0		3,5
1350 VM/ WC-731-1	5,02	Bal.	10,1	4,2					
Amperit Cr3C2-NiCr 75-25	2,90			Bal.		19,0		0,002	
Amperit WC-Co 88-12	3,90	Bal.	12,0						
Durmat 135.015	5,46	Bal.	10,5	3,9					

A Figura 14 mostra imagens de microscopia electrónica de varredura (MEV) dos pós usados na técnica de HVOF. A ampliação das imagens mostra as partículas aglomeradas e sinterizadas com morfologia esférica.

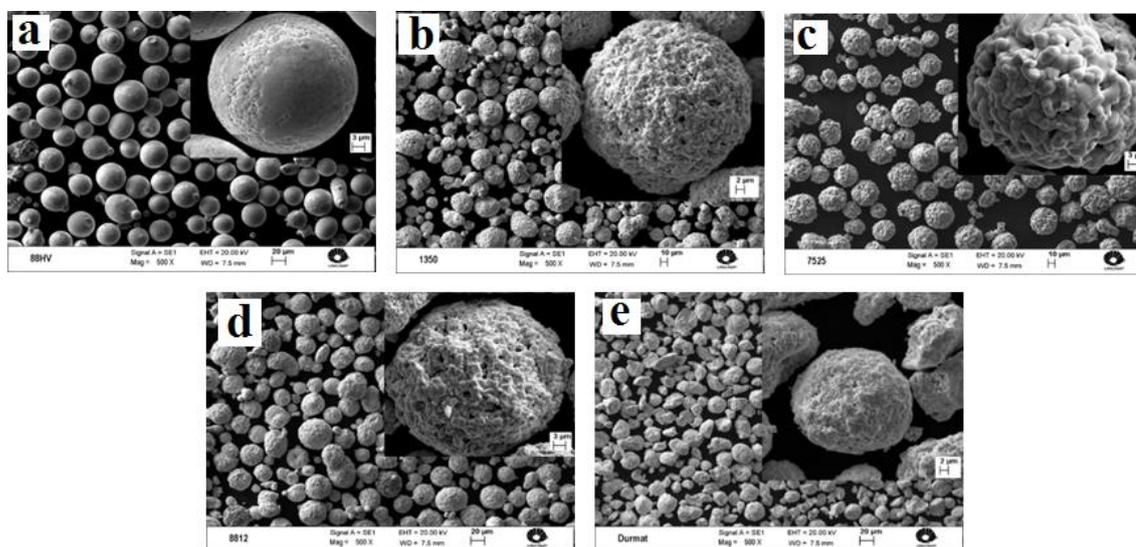


Figura 14 - Imagens de MEV da morfologia dos pós usados no processo HVOF.

Na Figura 14, em (a) tem-se o material 88HV com tamanho de partículas de 5/10 µm, com partículas esféricas; em (b), o material 1350 VM/WC-731-1 na forma de pó com tamanho de partículas de -45/+15 µm, e aglomerados; em (c), o material 7525, na forma de pó, com tamanho de partículas de 45/15 µm; em

(d), o material 8812, em forma de pó com tamanho de partículas de 45/15 μm ; finalmente, em (e), tem-se o material Durmat 135 com partículas de -25/+10 μm de tamanho e forma irregular, tendendo para a forma esférica.

4.3 O processo de aspersão a Chama FS/FlexiCords FC e material de recobrimento

O material na forma de cordão, como mostrado na Figura 15, utilizado para criar os revestimentos que foram avaliados neste trabalho com o processo FS/FC, são comercializados pela *Saint-Gobain Coating-Solutions*, e foram concebidos para ser depositados pelo método de aspersão térmica a chama convencional e FlexiCords. Sua densidade e a composição química estão na Tabela 4.



Figura 15- Materiais para depositados na forma de cordões flexíveis.

Tabela 4 - Composição química e densidade dos materiais depositados pelo processo FC/FS.

Material	Densidade (g/cm ³)	Composiçión química (% Wt)							
		W	Co	Cr	B	Ni	Si	Fe	Mo
HardKarb 15HC D4,75	13,30	Bal.	0,40	2,70		10,7		1,00	2,70
HardKarb 1350 10Co 4Cr	13,30	Bal.	10,00	4,00					
KhromKarb Fine 75CrCo/25NiCr	7,10			Bal.		Base	0,03	0,21	
HardKarb 12Co-F D4,75	13,70	80,00	12,00						
RocDur 62	8,20			14,10	2,92	Bal.	3,82	3,52	

A Figura 16 mostra as Imagens de microscopia eletrônica de varredura (MEV). Mostra a micrografia da seção transversal dos cordões usado na técnica de FS/FC. Os pormenores ampliados das imagens apresentam claramente as partículas aglomeradas e morfologia esférica sinterizados, com a capa de proteção dos cordões flexíveis.

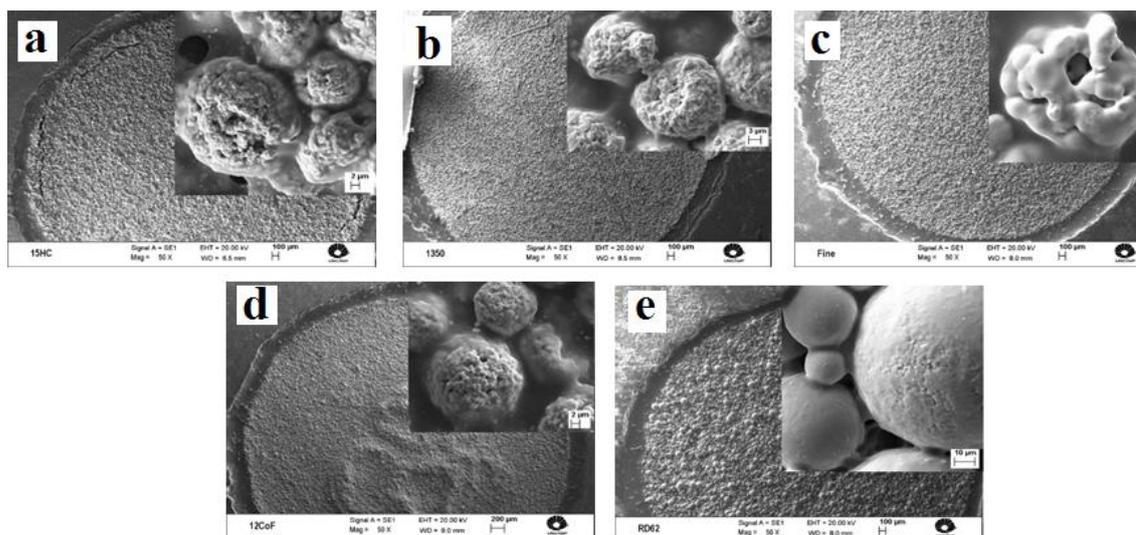


Figura 16 – Micrografia da seção transversal dos cordões confeccionados com os materiais aspergidos pelo processo de aspersão FS/FC. Fonte: Reyes (2015).

Na Figura 16, em (a) tem-se o material HardKarb 15HC D4,75, na forma de cordão flexível e a imagem da seção transversal, na qual se vêem as partículas esféricas, aglomeradas com a proteção ao seu redor; em (b), o material HardKarb 1350 10Co 4Cr com as partículas esféricas aglomeradas; em (c), o material HardKarb 12Co-F D4,75 com a forma esférica; em (d), o material HardKarb 12Co-F D4,75 na forma esférica aglomerada; finalmente, em (e), tem-se o material RocDur 62 com forma esférica mais acentuada que todos os outros cordões flexíveis.

4.4 Procedimento experimental para o planejamento.

Cada vez menos se sustenta a tese de que o modo científico adequado para conduzir um experimento seja o de variar um fator ou variável por vez, permanecendo fixos os remanescentes. Isto porque esta metodologia requer a realização de muitos experimentos, e não possibilita identificar se o efeito pode

ser atribuído a uma ou outra variável que foi mudada ou a uma combinação particular dos conjuntos das variáveis consideradas constantes. Consequentemente, para se ter confiança nos resultados obtidos, adicionam-se mais experimentos. Esta característica onera muito a realização prática do experimento tanto em termos financeiros, de recursos humanos e de material, quanto em termos de tempo exigido (PAREDES, 2013; LONG *et al.*, 2015).

A forma mais econômica para pesquisar problemas de vários fatores é a utilização de experimentos fatoriais fracionados, frações de experimentos completos, arranjando os fatores e observações de acordo com um plano em que todos os fatores variam simultaneamente. Neste caso, maior eficiência se traduz pela obtenção de maior conhecimento e um bom grau de precisão nas estimativas dos efeitos com o mesmo número de repetições e um número bem menor de observações ou ensaios. Esta é a abordagem utilizada no presente trabalho (PAREDES, 2013; LONG *et al.*, 2015).

Preparação dos corpos de prova para ensaios de desgaste

Antes de preparar as amostras ou corpos de prova, destinados a diferentes testes, os materiais para revestimentos, processos de aspersão, o número de corridas de teste foram determinados com a utilização de *software Statgraphics* profissional, cujas condições de contorno constam a seguir:

Projeto de experimento fatorial dos testes de erosão com mistura de partículas sólidas em suspensão.

- Classe de Projeto de experimento: Multifatorial categórico
- Projeto de desenho básico:
 - Número de fatores experimentais: 4
 - Número de respostas: 1
 - Aleatorizado: Sim
- Fatores experimentais: Quadro 5

Quadro 5- Fatores experimentais para o planejamento de experimentos

Fatores	Nível	Unidades
Ângulo de Impacto	2	graus (°)
Método de Revestimento	2	un
Materiais Depositados	5	un
Velocidade das Partículas	2	m/s

- **Variável resposta:** Eficiência de desgaste.

Foi criado um projeto experimental que estimou os efeitos de 4 fatores categóricos. O projeto de experimento fatorial consiste em todas as combinações de níveis dos fatores. Há um total de 120 corridas no projeto com os seguintes parâmetros.

- **Angulo de Impacto das partículas**
 - 30°
 - 90°
- **Método de revestimento:**
 - HVOF
 - *Flame Spray (FlexiCords)*
- **Velocidade de Impacto das Partículas**
 - Valor da Velocidade Mínima (3,61 m/s)
 - Valor da Velocidade Máxima (9,33 m/s).

4.5. ANÁLISE ESTATÍSTICA

O modelo proposto foi testado com dados experimentais do desgaste erosivo e da tenacidade à fratura. Uma análise estatística, utilizada para verificar a validade dos dados foi, inicialmente, realizada e indicou que os dados são adequados, visto que os mesmos estão ajustados ao modelo, com dispersão dentro de um limite aceitável, com coeficiente de variação, $CV < 0,2$.

Foi realizada a análise de regressão com os dados de todos os materiais para cada processo de aspersão escolhido obtendo o valor do coeficiente de determinação (R^2), variando de 95,30% a 99,85%, indicando que a variabilidade na resposta é explicada em pelo menos 95,30% dos casos e, portanto, o modelo pode ser utilizado para prever o comportamento do desgaste de forma consistente, tendo em vista estar dentro do intervalo de confiança estabelecido na análise de regressão.

A análise de variância – ANOVA - foi aplicada aos dados da eficiência de todos os materiais para os dois processos, com o propósito de verificar se existe diferença significativa entre as médias dos tratamentos e se os fatores exercem influência em alguma variável dependente. O valor do teste F ficou muito abaixo do intervalo de confiança para todos os materiais, o que mostra a evidência de que pelo menos uma das variáveis contribuem para explicar a variabilidade do modelo. Com essas informações em mãos, partiu-se para o modelo de redes neurais artificiais.

4.6. REDES NEURAS - RNA

As RNA tentam reproduzir as funções das redes biológicas, buscando simular seu comportamento básico e sua dinâmica. No entanto, do ponto de vista físico, no momento, as redes neurais artificiais se diferem bastante das redes biológicas.

Dada a revisão da literatura e os resultados do uso de redes neurais artificiais nas aplicações relacionadas a processos de engenharia, desenvolveu-se uma rede neural para modelar a eficiência de desgaste erosivo de revestimento feito pelos processos de aspersão térmica HVOF e FS/FC.

O modelo de eficiência de desgaste utilizado para comparar e validar os resultados do modelo baseado em RNA foi proposto por Patnaik *et al.* (2010), representados na equação 3. Os dados de desgaste foram os propostos por

Reyes *et al.*, (2015), e os dados da tenacidade à fratura foram obtidos por Orozco (2015), aplicados por aspersão térmica com os processos HVOF e FS/FC.

A seguir, estão descritos os passos da metodologia utilizada para se obter um modelo, com base nos dados experimentais que pode prever a eficiência de desgaste, para satisfazer às exigências de aplicações futuras esperadas.

Para o desenvolvimento da pesquisa, foi selecionada uma RNA *Perceptron* multicamada (MLP), que é o tipo de rede neural mais empregada em aplicações de engenharia, devido a sua capacidade de resolver problemas de modelagem complexa e de generalização, que se traduz na habilidade de fornecer saída satisfatória a entradas de um sistema, mesmo que o sistema não esteja completamente compreendido e treinado anteriormente.

Para consecução do modelo proposto, fazem parte da arquitetura da rede neural os seguintes parâmetros: número de camada da rede; número de nó em cada camada da rede; tipos de conexão entre os nós e a topologia da rede.

O modelo pode ter várias camadas: a camada de entrada, as camadas ocultas e a camada de saída. A camada de entrada é composta por um número de nós de entrada, que reúnem todos os dados experimentais extraídos do processo estudado e foram denominados por $x_1 \dots x_n$. A topologia da rede depende do número de camadas e do número de nó, existente, em cada uma delas.

Levando em conta a expressão da eficiência de desgaste proposta na equação 40 e os dados experimentais, foi definida como entrada da RNA a tenacidade à fratura K_c , a velocidade de impacto das partículas V , a densidade das partículas ρ , o ângulo de impacto das partículas α , a dureza das partículas Hv , o fator tempo t , além dos processos HVOF e FS/FC.

Na nova proposta de modelo baseado em RNA, além da tenacidade à fratura (K_c), incluem-se os tipos de processos (FS/FC e HVOF) e o fator tempo (t), e exclui-se a variável E_r . Com a eliminação desta variável, no modelo proposto,

não serão necessários ensaios de desgaste para estimar a eficiência, constituindo uma das principais vantagens do mesmo.

A entrada para a rede é enviada para os neurônios das camadas escondidas durante a passagem através do seu interior para neurônios de saída. Cada neurônio de cada camada oculta está conectado a todos os outros neurônios das camadas anteriores, por meio do conjunto de ligações ponderadas, chamados de pesos, designada por (W_1). A soma ponderada passa por meio de uma função de ativação linear para produzir o vetor de saída (Y), no intervalo de 0 a 1. A rede MLP é adequada para modelar as relações não lineares deste tipo. A saída da rede foi calculada utilizando a equação 42.

$$y = f(W_3(f(W_2(f(W_1 + b_1) + b_2) + b_3))) \quad (42)$$

onde: W_1 , W_2 e W_3 representam as matrizes de ponderação dos neurônios da camada de entrada, ocultas e saída, respectivamente; s_1 , s_2 , e s_3 representam os desvios de cada um dos neurônios da camada de entrada, oculta e de saída da rede.

As funções de transferência de todos os neurônios ocultos são funções *tangente sigmoid*, como mostrado na equação 43.

$$f(x) = \frac{\exp(x) - \exp(-x)}{\exp(x) + \exp(-x)} \quad (43)$$

No caso dos neurônios de saída, a função de transferência é linear, como mostrado na equação 44

$$f(x) = x \quad (44)$$

O valor da eficiência proposta é computado na camada de saída, que contém um neurônio que corresponde ao parâmetro eficiência de desgaste, a ser modelado.

A determinação do número de neurônios das camadas ocultas é crítica para a concepção das redes neurais. Para a solução de problemas práticos, alocasse para a rede um número de unidades intermediárias suficientes para a solução do problema. Deve-se ter cuidado para não utilizar nem unidades demais, o que pode levar a *overfitting*, que leva a rede a memorizar os padrões de treinamento, em vez de extrair as características gerais que permitirão a generalização ou o reconhecimento de padrões não vistos durante o treinamento. Por outro lado, um número muito pequeno de neurônios escondidos restringe a capacidade de aprendizagem e degrada o desempenho de convergência da rede (BRAGA *et al.*, 2000).

Para determinar o número ideal de neurônios das camadas ocultas foram empregados dois critérios: a regra da pirâmide e regra baseado em algoritmos genéticos e finalmente, a partir de uma sequência de retreinamento, o número ótimo de neurônio é alcançado.

A fim de introduzir os padrões na ARN, foi necessária normalização por meio de fase de pré-processamento. Os dados experimentais de desgaste e de tenacidade à fratura foram introduzidos na rede neural; foram empregados um total de 799 padrões de entrada e saída em treinamento e 268 foram utilizados para verificar o funcionamento da rede. Normalmente, de todo o conjunto de dados experimentais cerca de 70% é empregado para treinar a rede, reservando cerca de 30% como conjunto de teste.

Redes neurais artificiais possuem a capacidade de aprender por exemplos e fazer interpolações e extrapolações do que aprenderam. O *Perceptron* multicamadas com aprendizagem *Backpropagation* – BP, ou alguma de suas variantes, é o modelo neural mais utilizado em aplicações práticas. Estima-se que 70% dos desenvolvimentos com redes neurais fazem uso de algumas das suas variantes. O algoritmo de aprendizagem *backpropagation* foi aplicado no modelo proposto. A RNA foi treinada usando o algoritmo de treinamento *Levenberg-Marquardt* (LM) e várias topologias com uma ou duas camadas ocultas foi utilizada.

A escolha foi motivada pelo alto desempenho na convergência das redes neurais com esta técnica. As técnicas de mais rápida convergência se dividem em duas categorias principais: heurísticas e métodos de otimização numérica padrão, tais como algoritmo de retro propagação e *Levenberg-Marquardt* (LM).

O algoritmo LM é semelhante ao método quase-Newton, em que uma forma simplificada da matriz de Hesse, segunda derivadas é usada quando a função de custo tem a forma de uma soma de quadrados. A matriz (H) Hessiana, pode ser aproximada como:

$$H = J^T J \quad (45)$$

e o gradiente de g pode ser calculada por:

$$g = J^T e \quad (46)$$

onde J é a matriz Jacobiana contendo as primeiras derivadas do erro da rede em relação aos pesos e desvios e é o vetor de erros de rede. A matriz Jacobiana pode ser calculada por meio de uma técnica padrão back-propagação, que é muito menos complexo para calcular a matriz de Hesse. O algoritmo LM é o mais rápido de todos os que foram testados para treinar redes multicamadas de tamanhos moderados. A equação 47 mostra a função utilizada durante o treinamento da RNA.

$$F(w) = \frac{1}{2} e^T(w).e(w) \quad (47)$$

A Figura 17 mostra as etapas gerais da metodologia utilizada na pesquisa.

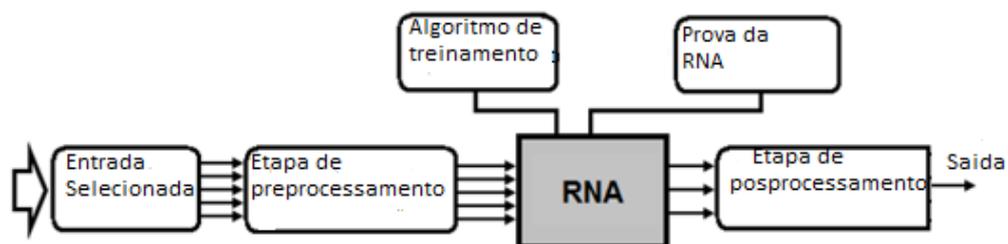


Figura 17– Metodologia de desenvolvimento da rede neural do modelo proposto

Após a conclusão da formação da rede neural, os dados de teste foram introduzidos na RNA para avaliar a capacidade do modelo de prever a eficácia do processo na mudança nos parâmetros de entrada.

5. RESULTADOS E DISCUSSÃO

5.1 RESULTADOS DO PROJETO EXPERIMENTAL

A análise estatística indicou que os dados são adequados, visto apresentar coeficiente de variação abaixo de 0,2, dentro de um intervalo aceitável. A análise de regressão indicou que os dados estão ajustados ao modelo em pelo menos 95,30% e a análise de variância indicou que há variabilidade estatística significativa entre suas médias. A ANOVA não indica quais variáveis ou tratamentos contribuem e qual a contribuição de cada um deles para a variabilidade das médias dentro ou entre os tratamentos. A contribuição dos tratamentos para a variabilidade das médias é dada pelo teste Tukey. O teste Tukey compara, par a par, aquele par que tem interação menor do que o intervalo de confiança; esse par contribui para explicar a variação das médias. Para determinar quais são estes tratamentos, foi implementado o teste Tukey, com os dados de desgaste e tenacidade à fratura, utilizando, para isso, o software *Past*. O par com interação menor que 0,05% está colorido na Gráfico 4. Esse par contribui, de forma efetiva, para a variabilidade das médias. A saída do *Past* consta na Tabela 5.

Tabela 5: Saída do *Past* com a contribuição dos fatores para a variação das médias na ANOVA

	A	B	C	D	E	F	G	H	I	J
A		0,1578	0,1091	0,9855	0,977	1,249E-05	1,249E-05	1,249E-05	1,249E-05	1,249E-05
B	3,875		1,315E-05	0,8248	0,003691	1,249E-05	1,249E-05	1,249E-05	1,249E-05	1,249E-05
C	4,083	7,958		0,002786	0,7856	1,249E-05	1,249E-05	1,249E-05	1,249E-05	1,249E-05
D	1,545	2,329	5,628		0,4143	1,249E-05	1,249E-05	1,249E-05	1,249E-05	1,249E-05
E	1,653	5,528	2,429	3,199		1,249E-05	1,249E-05	1,249E-05	1,249E-05	1,249E-05
F	17,76	21,64	13,68	19,31	16,11		0,2683	1,249E-05	0,9847	0,008311
G	21,3	25,17	17,21	22,84	19,64	3,535		9,644E-05	0,01177	0,973
H	28,02	31,89	23,94	29,56	26,36	10,26	6,721		1,249E-05	0,01386
I	16,2	20,08	12,12	17,75	14,55	1,558	5,093	11,81		7,925E-05
J	22,99	26,86	18,91	24,53	21,34	5,228	1,693	5,028	6,786	

Os dados dos experimentos de desgaste erosivo foram realizados no laboratório de construção mecânica da Faculdade de Engenharia da Universidade Metodista de Piracicaba e constam nas Tabelas 6 até 15; em seguida, apresenta-se um gráfico que mostra o comportamento da perda de massa de cada uma das respectivas tabelas, cuja legenda é: TE, taxa de erosão; desg, o desgaste; V. desg., a velocidade de desgaste.

Esta etapa foi desenvolvida em cooperação com o grupo de caracterização de processos avançados de soldagem da Universidade de Oriente, em Cuba, sob orientação dos professores Dr. Hipólito D. Carvajal Falls e Dr. Angel Sanchez Rocca.

Tabela 6 – Dados dos ensaios de desgaste erosivo dos materiais 88HV e 15HC com ângulo de 30º, velocidade de 3,61m/s e 9,33m/s, aplicados com o processo HVOF e FS/FC.

88 HV HVOF / V = 3,61 m/s, 30º				88 HV HVOF / V = 9,33 m/s, 30º			
Tempo/ minuto	TE. Média	Desg. Médio	V. Desg Médio	Tempo/ minuto	TE. Média	Desg. Médio	V.Desg. Médio
0	0,00	0,00	0,00	0	0,00	0,00	0,00
60	1,22	1,22	0,02	60	8,11	8,11	0,14
120	0,89	2,11	0,02	120	5,11	13,22	0,11
180	0,55	2,67	0,01	180	5,78	19,00	0,10
240	0,55	3,22	0,01	240	5,00	24,00	0,10
300	0,78	4,00	0,01	300	4,89	28,89	0,09
360	1,11	5,11	0,01	360	5,11	34,00	0,09
15 HC FS/FC / V = 3,61 m/s, 30º				15 HC FS/FC / V = 9,33 m/s, 30º			
Tempo/ Minuto	TE. Média	Desg. Médio	V.Desg. Médio	Tempo/ Minuto	TE. Média	Desg. Médio	V.Desg. Médio
0	0,00	0,00	0,00	0	0,00	0,00	0,00
60	9,00	9,00	0,15	60	47,33	47,33	0,79
120	4,44	13,44	0,11	120	24,56	71,89	0,60
180	2,89	16,33	0,09	180	18,11	90,00	0,50
240	3,78	20,11	0,08	240	20,00	110,00	0,46
300	3,11	23,22	0,08	300	17,89	127,89	0,43
360	1,44	24,66	0,07	360	17,78	145,67	0,41

O Gráfico 4 mostra os materiais 88HV, aplicados com o processo HVOF, e 15HC, aplicados com o processo FS/FC, correspondente à Tabela 6.

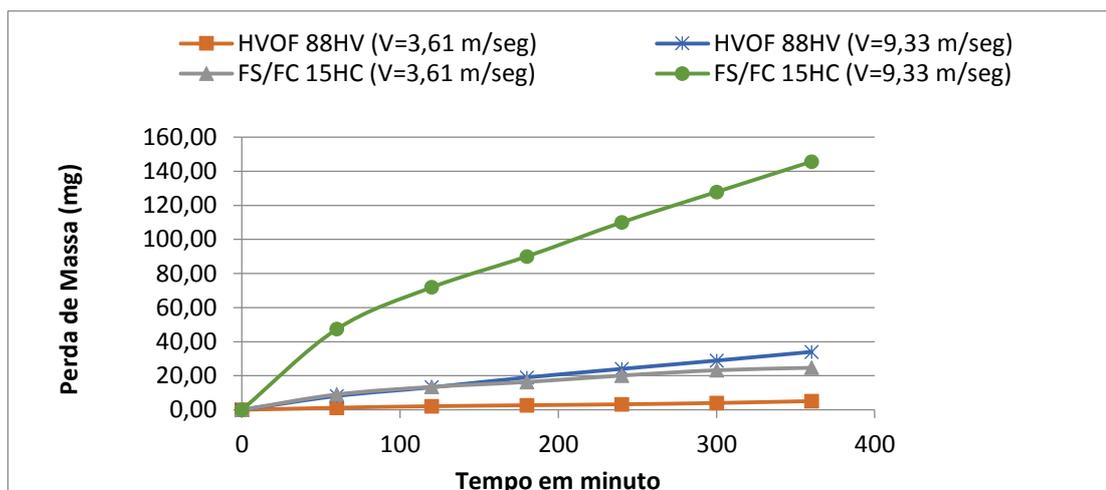


Gráfico 4. Perda de massa no ensaio de erosão com ângulo de 30°, Tabela 6.

O Gráfico 4 mostra que a taxa de desgaste é maior no ensaio com ângulo de 30° para o material 15HC no processo FS/FC com velocidade de 9,33 m/s e menor com ângulo de 30° com velocidade de 3,61 m/s com o material 88HV e com o processo HVOF.

Tabela 7 – Dados dos ensaios de desgaste erosivo dos materiais 1350, com ângulo de 30°, velocidade de 3,61m/s e 9,33m/s, aplicados com o processo HVOF e FS/FC.

1350 HVOF / V = 3,61 m/s, 30°				1350 HVOF / V = 9,33 m/s, 30°			
Tempo/ minuto	TE. Médio	Desg. Médio	V.Desg. Médio	Tempo/ minuto	TE. Médio	Desg. Médio	V.Desg. Médio
0	0,00	0,00	0,00	0	0,00	0,00	0,00
60	3,11	3,11	0,05	60	8,11	8,11	0,14
120	0,78	3,89	0,03	120	4,67	12,78	0,11
180	1,55	5,45	0,03	180	3,78	16,55	0,09
240	1,56	7,00	0,03	240	2,55	19,11	0,08
300	0,89	7,89	0,03	300	3,11	22,22	0,08
360	0,67	8,55	0,03	360	3,22	25,44	0,07
1350 FS/FC / V = 3,61 m/s, 30°				1350 FS/FC / V = 9,33 m/s, 30°			
Tempo/ minuto	TE. Médio	Desg. Médio	V.Desg. Médio	Tempo/ minuto	TE. Médio	Desg. Médio	V.Desg. Médio
0	0,00	0,00	0,00	0	0,00	0,00	0,00
60	5,44	5,44	0,09	60	77,67	77,67	1,30
120	3,78	9,22	0,08	120	63,55	141,22	1,18
180	2,67	11,89	0,06	180	47,33	188,55	1,05
240	2,45	14,33	0,06	240	43,44	232,00	0,97
300	2,78	17,11	0,06	300	45,56	277,55	0,93
360	2,34	19,45	0,05	360	41,56	319,11	0,88

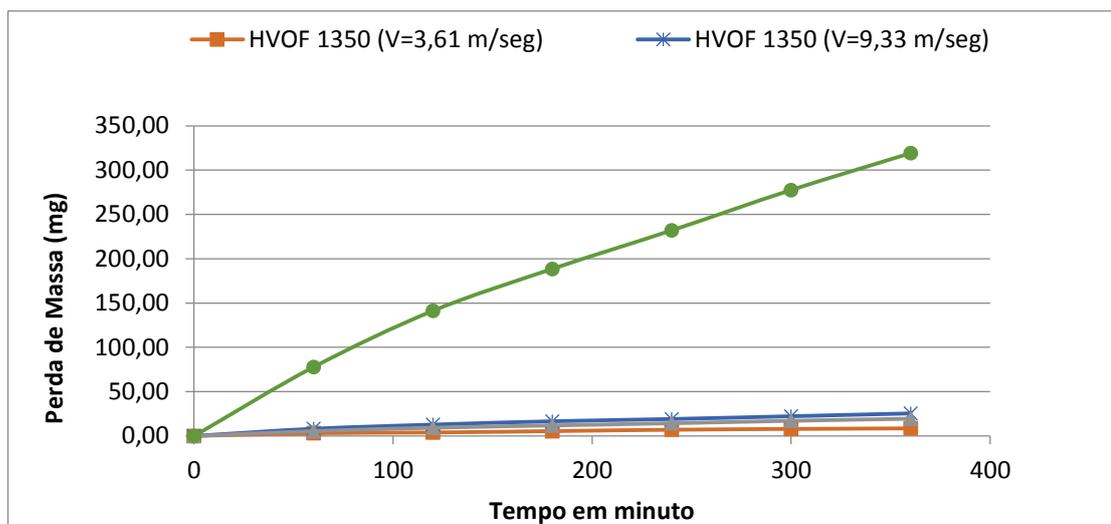


Gráfico 5 - Comportamento do desgaste erosivo, correspondente à Tabela 7.

O Gráfico 5 mostra que a taxa de desgaste é maior com ângulo de 30° , com o material 1350, com velocidade de 9,33m/s e processo FS/FC, e menor para o ângulo de 30° , material 1350, velocidade de 3,61m/s, no processo HVOF.

Tabela 8 – Dados de desgaste dos materiais 7525 a velocidade de 3,61m/s e 9,33m/s, aplicados com os processos HVOF e FS/FC.

7525 HVOF / V = 3,61 m/s, 30º				7525 HVOF / V = 9,33 m/s, 30º			
Tempo/ minuto	TE. Médio	Desg. Médio	V.Desg. Médio	Tempo/ minuto	TE. Médio	Desg. Médio	V.Desg. Médio
0	0,00	0,00	0,00	0	0,00	0,00	0,00
60	2,22	2,22	0,04	60	9,67	9,67	0,16
120	1,22	3,44	0,03	120	7,56	17,22	0,14
180	0,56	4,00	0,02	180	7,67	24,89	0,14
240	0,56	4,55	0,02	240	6,67	31,56	0,13
300	1,00	5,56	0,02	300	6,00	37,56	0,13
360	0,78	6,33	0,02	360	7,11	44,67	0,12
7525 FS/FC / V = 3,61 m/s, 30º				7525 FS/FC / V = 9,33 m/s, 30º			
Tempo/ minuto	TE. Médio	Desg. Médio	V.Desg. Médio	Tempo/ minuto	TE. Médio	Desg. Médio	V.Desg. Médio
0	0,00	0,00	0,00	0	0,00	0,00	0,00
60	3,11	3,11	0,05	60	16,44	16,44	0,27
120	1,33	4,45	0,04	120	17,89	34,33	0,29
180	1,11	5,56	0,03	180	12,56	46,89	0,26
240	0,89	6,44	0,03	240	12,55	59,45	0,25
300	0,67	7,11	0,02	300	11,11	70,56	0,23
360	0,78	7,89	0,02	360	13,67	84,22	0,24

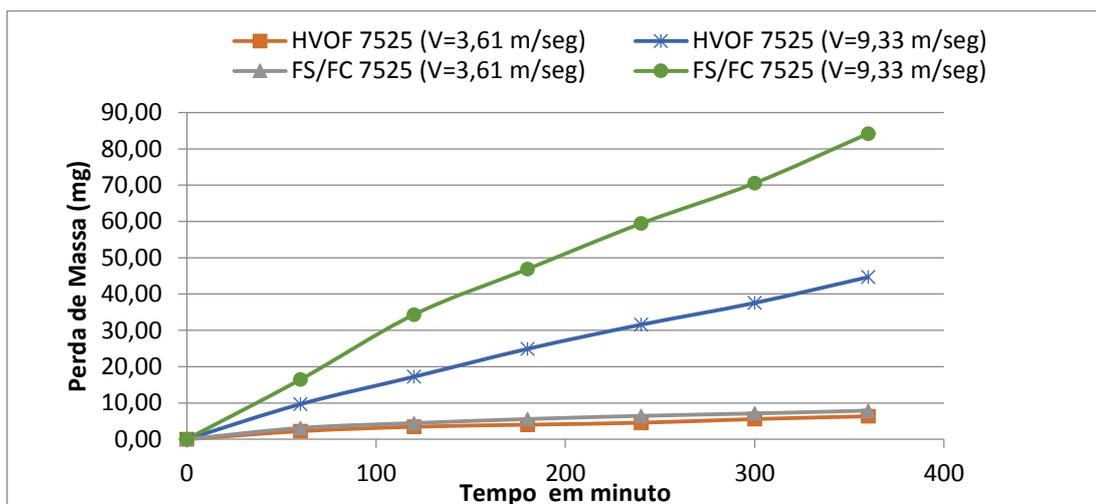


Gráfico 6 - Gráfico com o comportamento do desgaste, da Tabela 8 a um ângulo de 30°.

O Gráfico 6 mostra que a taxa de desgaste é maior com ângulo de 30° com velocidade de 9,33m/s, com o material 7525 no processo FS/FC, e menor no mesmo ângulo com a velocidade de 3,61m/s, o mesmo material, no processo HVOF.

Tabela 9. Dados dos ensaios de desgaste erosivo dos materiais 8812 com ângulo de 30°, velocidade de 3,61m/s e 9,33m/s, aplicados com os processos HVOF e FS/FC.

8812 HVOF / V = 3,61 m/s, 30°				8812 HVOF / V = 9,33 m/s, 30°			
Tempo/ minuto	TE. Médio	Desg. Médio	V.Desg. Médio	Tempo/ minuto	TE. Médio	Desg. Médio	V.Desg. Médio
0	0,00	0,00	0,00	0	0,00	0,00	0,00
60	4,89	4,89	0,08	60	7,89	7,89	0,13
120	2,22	7,11	0,06	120	4,66	12,55	0,11
180	0,67	7,78	0,05	180	6,45	19,00	0,11
240	0,89	8,67	0,04	240	5,45	24,45	0,10
300	1,44	10,11	0,03	300	5,67	30,11	0,10
360	0,89	11,00	0,03	360	7,22	37,33	0,11
8812 FS/FC / V = 3,61 m/s, 30°				8812 FS/FC / V = 9,33 m/s, 30°			
Tempo/ minuto	TE. Médio	Desg. Médio	V.Desg. Médio	Tempo/ minuto	TE. Médio	Desg. Médio	V.Desg. Médio
0	0,00	0,00	0,00	0	0,00	0,00	0,00
60	6,00	6,00	0,10	60	25,00	25,00	0,42
120	3,44	9,44	0,08	120	21,44	46,45	0,39
180	2,89	12,33	0,07	180	22,33	68,78	0,38
240	3,11	15,44	0,06	240	18,89	87,67	0,37
300	1,78	17,22	0,06	300	21,22	108,89	0,36
360	3,44	20,67	0,06	360	22,11	131,00	0,36

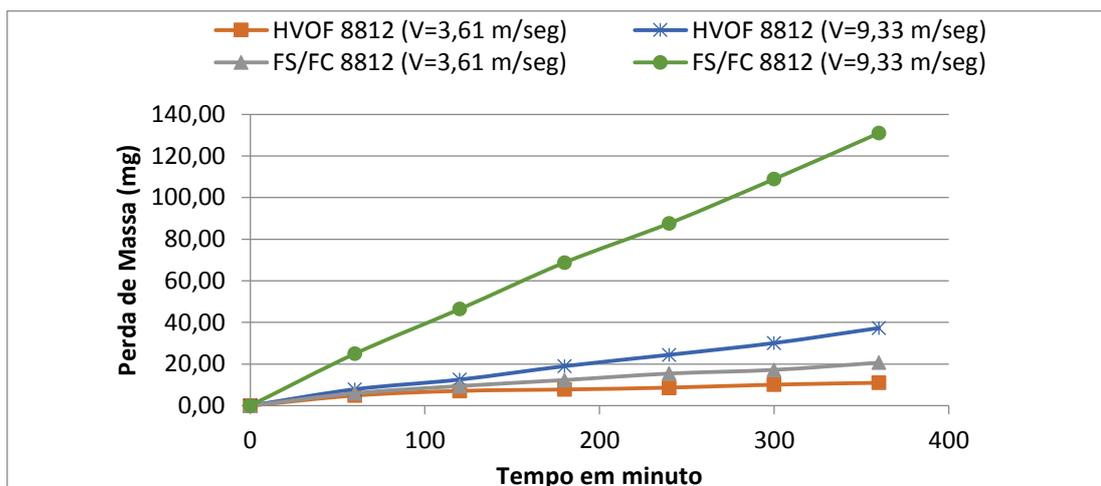


Gráfico 7 - Comportamento do desgaste, Tabela 9, dos materiais 8812 com ângulo de 30°, velocidade de 3,61m/s e 9,33m/s, aplicados com os processos HVOF e FS/FC.

O Gráfico 7 mostra que a taxa de desgaste é maior no ângulo de 30°, com velocidade de 9,33m/s, com o material 8812 e no processo FS/FC. E menor no ângulo de 30° com velocidade de 3,61m/s, com o material 8812, com o processo HVOF.

Tabela 10. Dados dos ensaios de desgaste erosivo dos materiais Durmat com ângulo de 30°, velocidade de 3,61m/s e 9,33m/s, aplicados com os processos HVOF e FS/FC

Durmat HVOF / V = 3,61 m/s, 30°				Durmat HVOF / V = 9,33 m/s, 30°			
Tempo/ minuto	TE. Médio	Desg. Médio	V.Desg. Médio	Tempo/ minuto	TE. Médio	Desg. Médio	V.Desg. Médio
0	0,00	0,00	0,00	0	0,00	0,00	0,00
60	2,11	2,11	0,03	60	6,44	6,44	0,11
120	1,67	3,78	0,03	120	3,67	10,11	0,08
180	0,89	4,66	0,02	180	4,22	14,33	0,08
240	0,44	5,11	0,02	240	3,00	17,33	0,07
300	0,78	5,89	0,02	300	3,67	21,00	0,07
360	0,67	6,56	0,02	360	3,00	24,00	0,07
RocDur62 FS/FC / V = 3,61 m/s, 30°				RocDur62 FS/FC / V = 9,33 m/s, 30°			
Tempo/ minuto	TE. Médio	Desg. Médio	V.Desg. Médio	Tempo/ minuto	TE. Médio	Desg. Médio	V.Desg. Médio
0	0,00	0,00	0,00	0	0,00	0,00	0,00
60	3,11	3,11	0,05	60	3,11	17,67	0,05
120	2,00	5,11	0,04	120	2,00	30,33	0,04
180	1,56	6,67	0,04	180	1,56	42,66	0,04
240	0,89	7,56	0,03	240	0,89	55,00	0,03
300	1,33	8,89	0,03	300	1,33	68,78	0,03
360	1,22	10,11	0,03	360	1,22	82,33	0,03

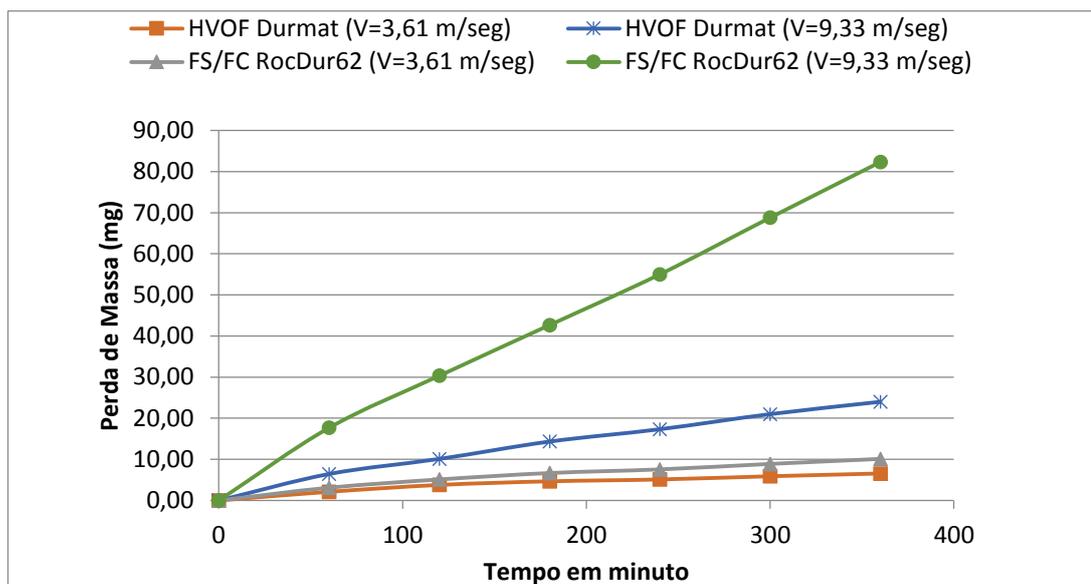


Gráfico 8 - Comportamento do desgaste, correspondente à Tabela 10 a um ângulo de 30°

O Gráfico 8 mostra que a taxa de desgaste é maior no ângulo de 30°, com velocidade de 9,33m/s, com o material RocDur 62 e no processo FS/FC. É menor para o ângulo de 30°, com velocidade de 3,61m/s e material Durmat, no processo HVOF. O gráfico 8, a seguir, mostra o comportamento do desgaste erosivo, comparando os processos, os materiais, as velocidades, com o ângulo de impacto de 30°.

O Gráfico 9 mostra o comportamento de desgaste erosivo por meio da comparação dos processos, velocidade e materiais. Ele mostra que a perda de massa é sempre maior no processo FS/FC para a mesma velocidade, do que no processo HVOF e para o mesmo ângulo. Indicando que o processo HVOF produz revestimentos mais resistentes ao desgaste do que o processo FS/FC. E, portanto, a eficiência de desgaste é menor, neste processo.

Ao se comparar o processo HVOF com a velocidade de 3,61m/s, para cada um dos materiais com o processo FS/FC, com a mesma velocidade, percebe-se que a perda de massa é mais acentuada. O mesmo acontece com os dois processos para a velocidade de 9,33m/s, com todos os materiais.

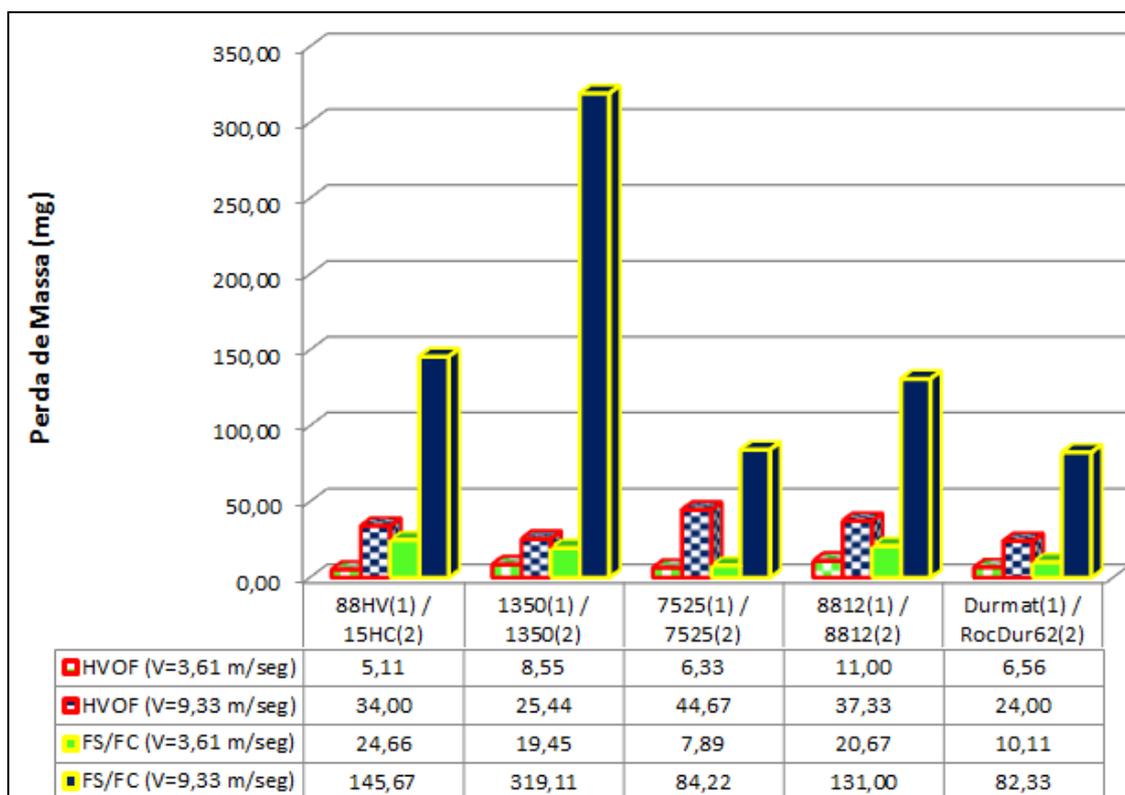


Gráfico 9 – Comparação dos processos, velocidade e materiais com o ângulo de 30°.

Nas Tabelas 11 até a Tabela 15 constam os dados dos ensaios com ângulo de incidência de 90°.

Tabela 11 – Dados de desgaste dos materiais 88HV, aplicados com o processo HVOF e 15HC, aplicados com o processo FS/FC, aplicados com a velocidade de 9,33m/s, com ângulo de 90°.

88 HV HVOF - V = 9,33 m/s, 90°				15HC FS/FC - V = 9,33 m/s, 90°			
Tempo/ Minuto	TE. Médio	Desg. Médio	V.Desg. Médio	Tempo/ Minuto	TE. Médio	Desg. Médio	V.Desg. Médio
0	0,00	0,00	0,00	0,00	0,00	0,00	0,00
60	11,67	11,67	0,20	60,00	58,78	58,78	0,98
120	9,00	20,67	0,17	120,00	38,78	97,56	0,81
180	9,22	29,89	0,17	180,00	39,66	137,22	0,76
240	8,89	38,78	0,16	240,00	32,22	169,45	0,71
300	9,00	47,78	0,16	300,00	34,56	204,00	0,68
360	8,78	56,55	0,16	360,00	28,33	232,34	0,65

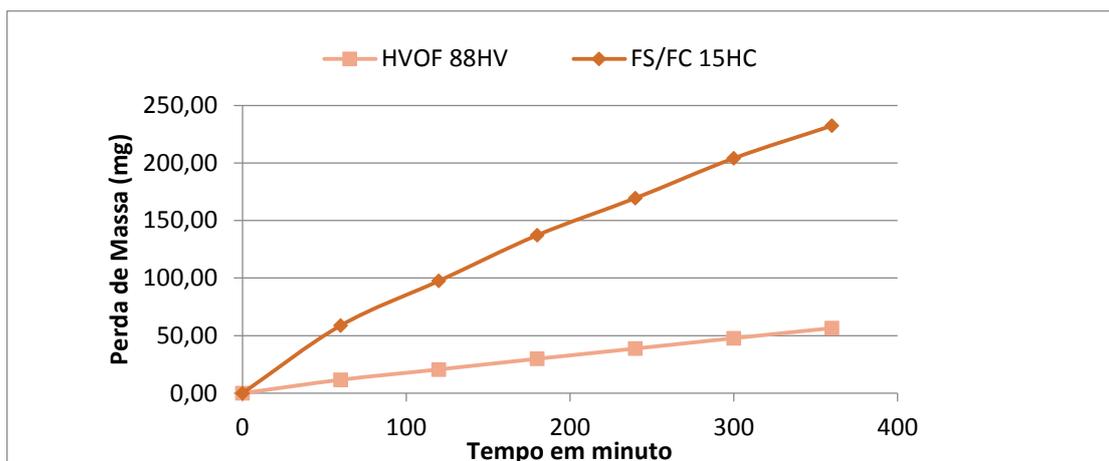


Gráfico 10 – Comportamento do desgaste, correspondente à Tabela 11 a um ângulo de 90°.

O Gráfico 10 mostra que a perda de massa é maior no ângulo de 90° com velocidade de 9,33m/s, para o material 15HC, no processo FS/FC do que com o material 88HV, no processo HVOF.

Tabela 12 – Dados de desgaste dos materiais 1350, com velocidade 9,33 m/s

1350 HVOF - V = 9,33 m/s, 90°				1350 FS/FC - V = 9,33 m/s, 90°			
Tempo/ minuto	TE	Desg	V.Desg	Tempo/ minuto	TE	Desg	V.Desg
0	0,00	0,00	0,00	0	0,00	0,00	0,00
60	9,11	9,11	0,15	60	90,00	90,00	1,50
120	4,78	13,89	0,12	120	69,67	159,66	1,33
180	2,89	16,78	0,09	180	68,44	228,11	1,27
240	4,22	21,00	0,08	240	64,78	292,89	1,22
300	3,22	24,22	0,08	300	54,00	346,89	1,15
360	4,11	28,34	0,08	360	52,00	398,89	1,11

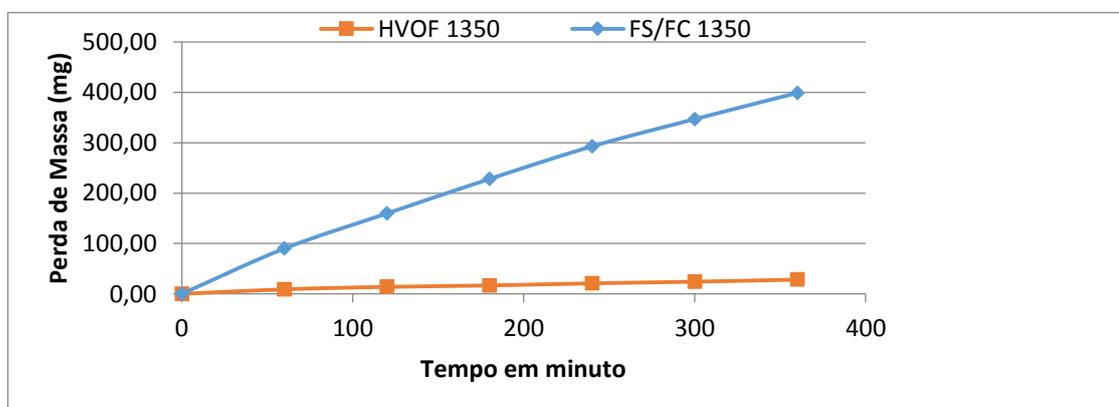


Gráfico 11. Comportamento do desgaste, correspondente à Tabela 12, ângulo 90°, V = 9,33 m/s.

O Gráfico 11 mostra que a perda de massa é, consideravelmente, mais acentuada para o material 1350, com o processo FS/FC e menor no mesmo ângulo e material no processo HVOF, para a mesma velocidade de 9,33m/s e ângulo de 90°

Tabela 13 – Dados de desgaste dos materiais 7525 a uma velocidade 9,33m/s

7525 HVOF - V = 9,33 m/s, 90°				7525 FS/FC - V = 9,33 m/s, 90°			
Tempo/Minuto	TE	Desg	V.Desg	Tempo/Minuto	TE	Desg	V.Desg
0	0,00	0,00	0,00	0	0,00	0,00	0,00
60	10,33	10,33	0,17	60	27,67	27,67	0,46
120	9,22	19,56	0,16	120	25,11	52,78	0,44
180	9,11	28,67	0,16	180	25,33	78,11	0,43
240	9,67	38,33	0,16	240	27,55	105,67	0,44
300	9,78	48,11	0,16	300	24,56	130,22	0,43
360	9,67	57,78	0,16	360	24,89	155,11	0,43

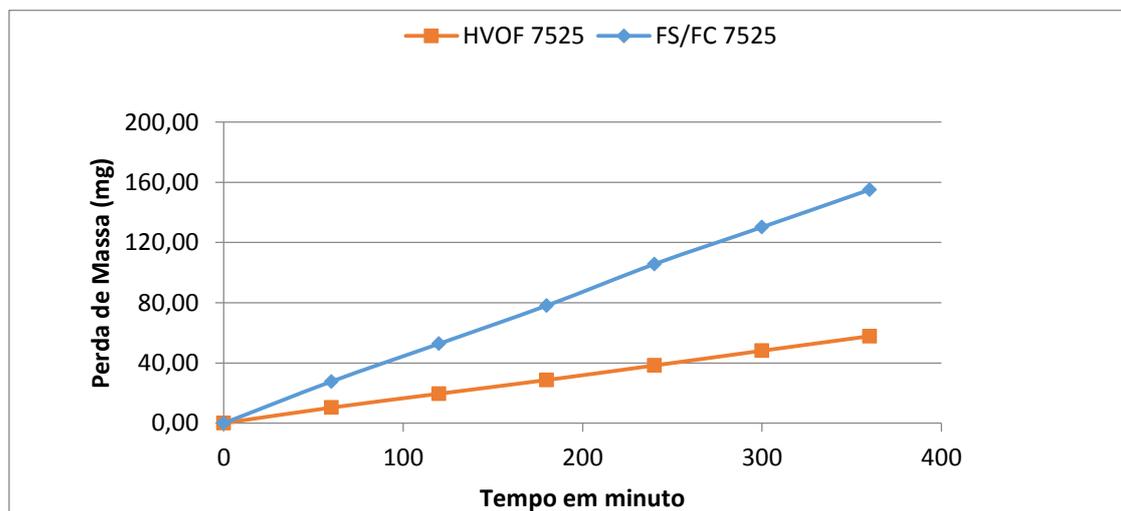


Gráfico 12 - Gráfico com o comportamento do desgaste, correspondente à Tabela 13 a um ângulo de 90°, V = 9,33 m/s, aplicados com os processos HVOF e FS/FC.

O Gráfico 12 mostra que a taxa de desgaste é mais acentuada na velocidade de 9,33m/s com o material 7525 e no processo FS/FC do que na mesma velocidade e material com o processo HVOF.

Tabela 14 – Dados de desgaste dos materiais 8812 a uma velocidade 9,33m/s

8812 HVOF - V = 9,33 m/s, 90º				8812 FS/FC - V = 9,33 m/s, 90º			
Tempo/minuto	TE	Desg	V.Desg	Tempo/minuto	TE	Desg	V.Desg
0	0,00	0,00	0,00	0	0,00	0,00	0,00
60	10,11	10,11	0,17	60	60,56	60,56	1,01
120	6,55	16,67	0,14	120	57,11	117,67	0,98
180	6,56	23,22	0,13	180	53,78	171,44	0,95
240	6,11	29,33	0,12	240	58,44	229,89	0,96
300	6,89	36,22	0,12	300	44,33	274,22	0,92
360	6,67	42,89	0,12	360	58,00	332,22	0,92

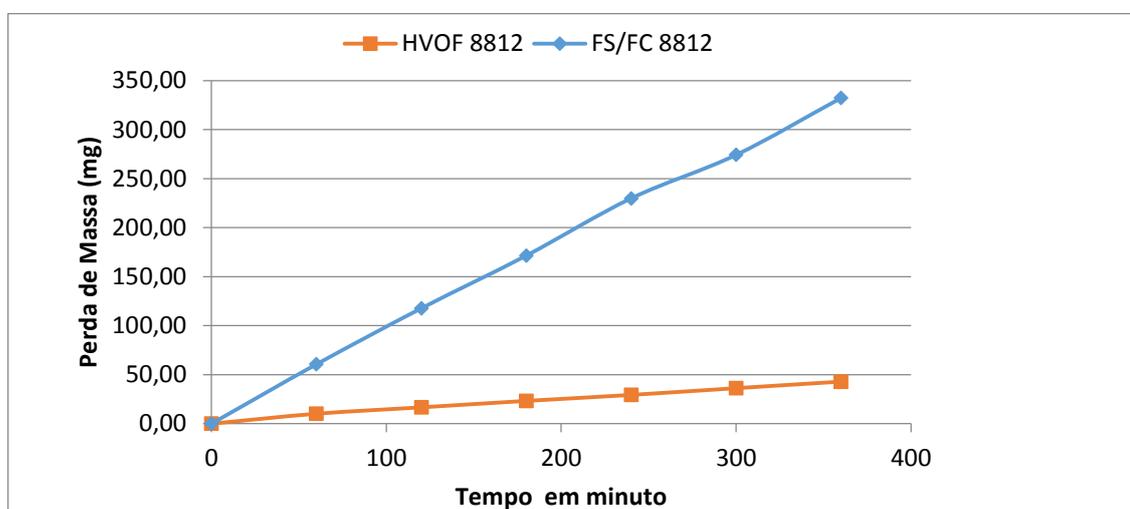


Gráfico 13 - Comportamento do desgaste, correspondente à Tabela 14 a um ângulo de 90º, V= 9,33 m/s.

O Gráfico 13 mostra que a taxa de erosão é mais acentuada no material 8812 com o processo FS/FC, com ângulo de 90º do que no processo HVOF, para o mesmo material e ângulo.

Tabela 15 – Dados de desgaste dos materiais Durmat, a uma velocidade de 3,61m/s e 9,33m/s com os processos HVOF e FS/FC

Dumat HVOF - V = 9,33 m/s, 90°				RocDur 62 FS/FC - V = 9,33 m/s, 90°			
Tempo/ minuto	TE	Desg	V.Desg	Tempo/ minuto	TE	Desg	VDesg
0	0,00	0,00	0,00	0	0,00	0,00	0,00
60	8,22	8,22	0,14	60	31,11	31,11	0,52
120	6,33	14,56	0,12	120	28,89	60,00	0,50
180	5,33	19,89	0,11	180	28,00	88,00	0,49
240	7,00	26,89	0,11	240	27,89	115,89	0,49
300	6,00	32,89	0,11	300	28,89	144,78	0,48
360	6,11	39,00	0,11	360	28,11	172,89	0,48

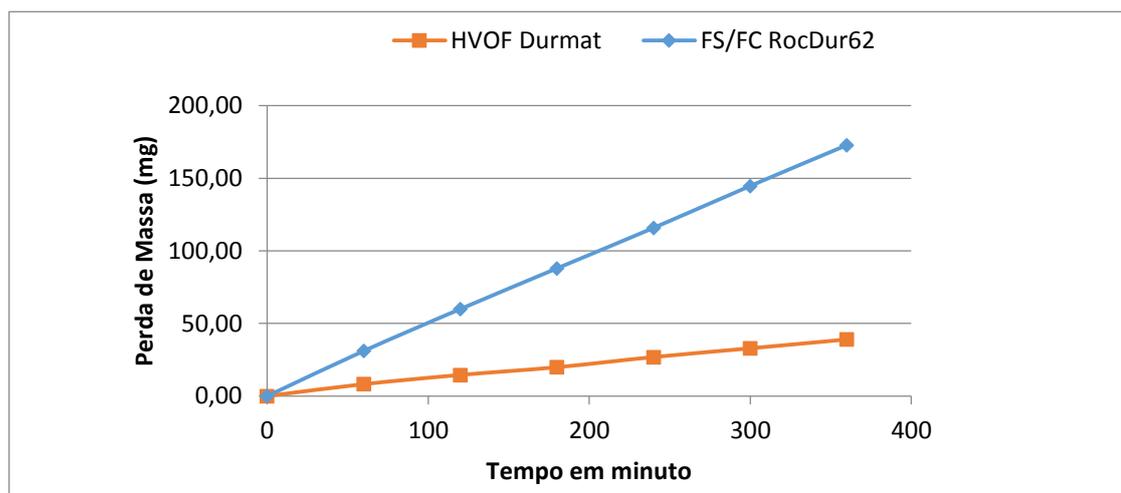


Gráfico 14 - Comportamento do desgaste, correspondente à Tabela 15 a um ângulo de 90°, velocidade V=9,33 m/seg.

A taxa de desgaste é mais acentuada para o material RocDur 62, com ângulo de 90°, com o processo FS/FC do que o Durmat para o mesmo ângulo no processo HVOF.

Os valores da perda de massa foram determinados para cada condição experimental feita e processada através de um programa de planilhas *Microsoft Excel*, apresentado nas tabelas anteriores. Os resultados foram representados graficamente. A primeira análise foi feita com comportamento dos

revestimentos sob a influência do valor da velocidade de impacto das partículas sólidas; em seguida, os valores das velocidades foram estabelecidos e a sua influência foi analisada com o ângulo de contato de 30° e 90°, das partículas sólidas. Os valores, a seguir, se referem às condições experimentais.

Velocidade das partículas com 3,61 m/s

a) Influência da velocidade com ângulos de impacto de partículas com 30°

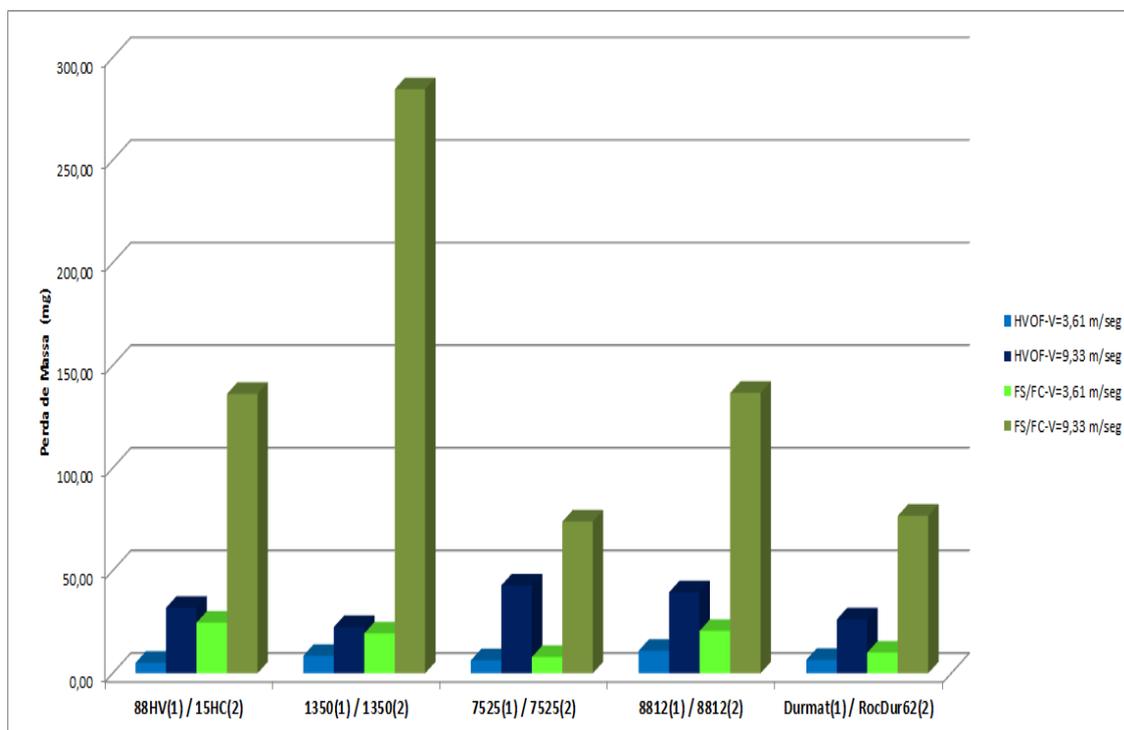


Gráfico 15 - Valores de perda de massa de amostras para as condições estudadas e velocidade 3,61 m/s e ângulo de partículas 30°

b) Influência da velocidade com ângulos de impacto de partículas com 90°

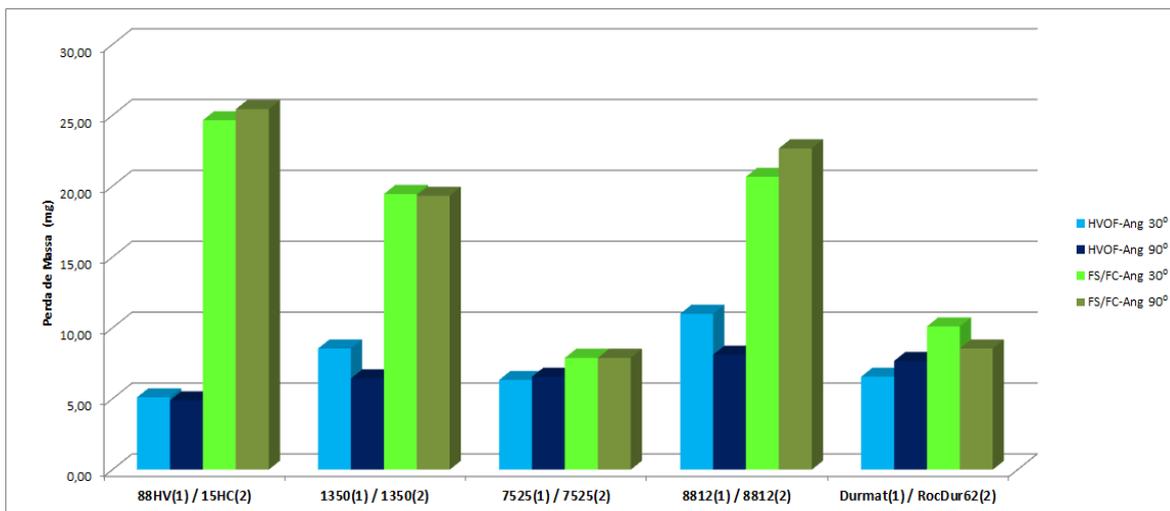


Gráfico 16 - Valores de perda de massa das amostras para as condições do experimento com velocidade 3,61 e partículas com ângulo de impacto 90°

Velocidade das partículas com 9,33 m/s.

a) Influência da velocidade com ângulos de impacto de partículas com 30°

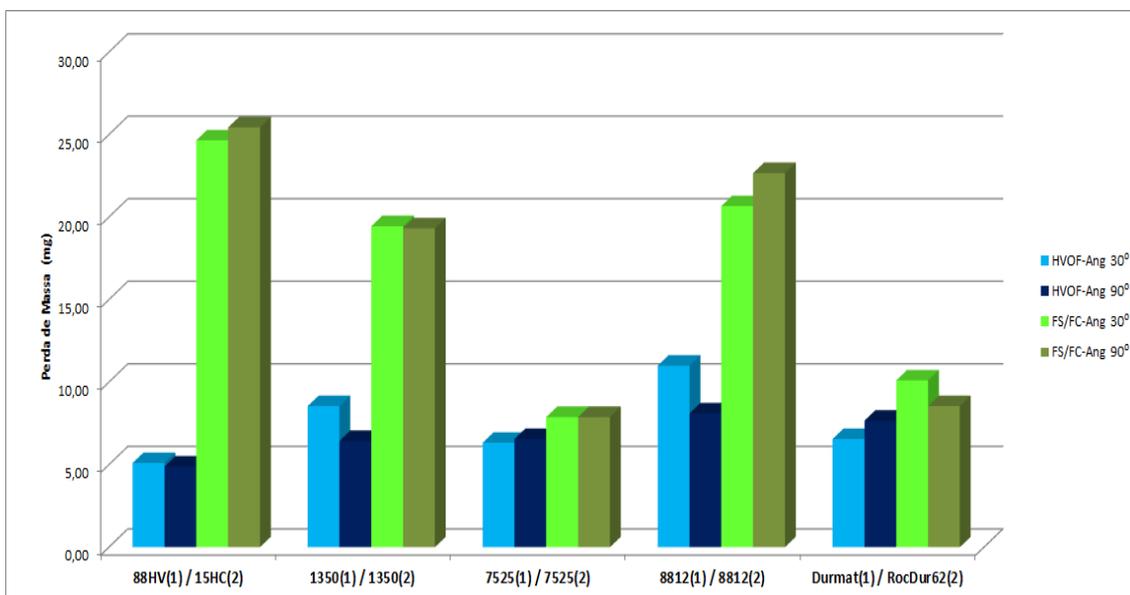


Gráfico - 17 Valores de perda de massa das amostras para as condições experimentais com ângulo de impacto de partículas com 30° e velocidade de 9,33 m/s.

b) Influência da velocidade com ângulos de impacto de partículas com 90°

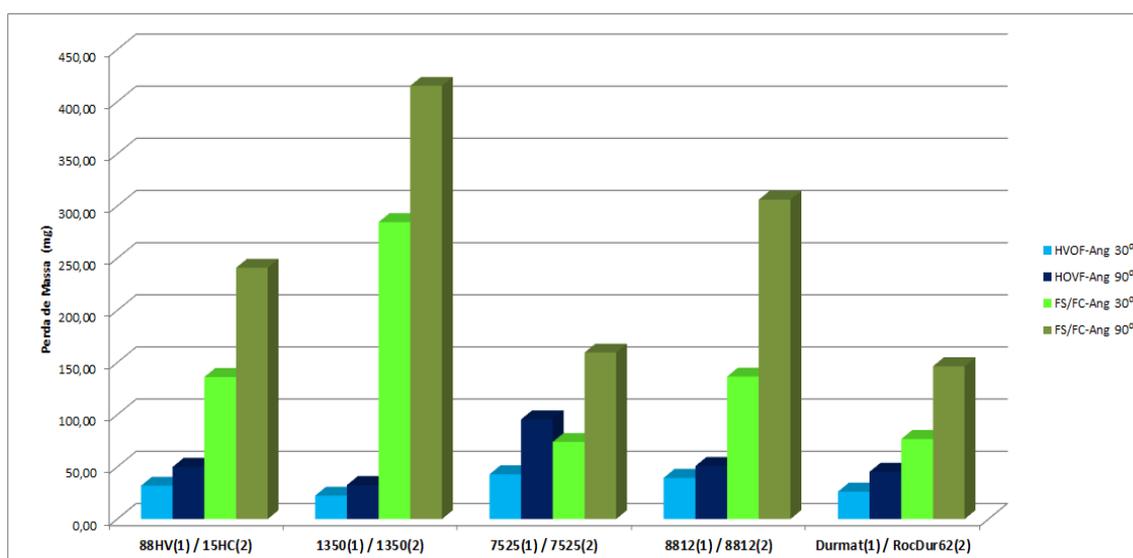


Gráfico 18 - Valores de perda de massa das amostras para as condições experimentais com ângulo de impacto de partículas com 90° e velocidade de 9,33 m/s.

O comportamento de desgaste mostrado em todos os gráficos indica a influência da velocidade na taxa de desgaste. Tem-se a maior taxa de desgaste para a velocidade de 9,33 m/s e ângulo de 30° para o processo FS/FC e a mais baixa taxa de desgaste com a velocidade de 3,61 m/s e a um ângulo de 90°, para os materiais aplicados com o processo HVOF.

O mesmo comportamento se repete para todas as condições experimentais e isso também é observado na eficiência de desgaste obtido pela rede neural. A maior taxa de desgaste ocorre no processo FS/FC com velocidade de 9,33 m/s e a menor taxa de desgaste ocorre com a velocidade de 3,62 m/s e no processo HVOF, confirmando o fato de que o processo HVOF produz revestimentos mais resistentes ao desgaste erosivo.

O modelo de desgaste erosivo, proposto por meio da rede neural artificial, é regido pela equação genérica (42). Ao se aplicar os dados dos ensaios de desgaste experimentais resulta na equação (48), a seguir com os pesos W_1 , W_2 e W_3 representando as matrizes de ponderação dos neurônios da camada de entrada, ocultas e saída, respectivamente; com os desvios s_1 , s_2 , e s_3 representando os desvios de cada um dos neurônios da camada de entrada, oculta e de saída da rede.

A metodologia usual para determinar o desgaste erosivo é realizada pela determinação da perda de material, seja pela variação da massa ou pela diminuição na espessura de componentes mecânicos. Com a redução na espessura pode gerar dificuldades no funcionamento dos equipamentos, podendo levá-los à deterioração de suas funções

Uma das principais vantagens alcançada, com o modelo proposto, é expressa pela eliminação da taxa de desgaste e pela introdução da tenacidade à fratura no mesmo. Assim, pode-se determinar o comportamento do desgaste erosivo sem a necessidade de ensaios de desgaste. Isto é possível com a introdução da tenacidade à fratura no modelo, este fato exprime com mais precisão os esforços com os quais os materiais estão submetidos no momento do desgaste, pois a tenacidade fornece o comportamento dos materiais com relação à absorção de energia, levando ao comportamento de desgaste de forma dinâmica, que está mais próximo do que acontece na realidade do processo de desgaste erosivo. A principal limitação do modelo consiste no fato da restrição da determinação da tenacidade em filmes finos, como os feitos por aspersão térmica. E, ainda pelo fato de que os modelos, baseados em redes neurais, ainda são tidos, pela maioria dos pesquisadores, como uma verdadeira caixa preta no que diz respeito ao seu funcionamento e operação das camadas internas.

Os dados de desgaste foram utilizados para implementar o modelo de rede neural proposto.

5.2 MODELO COM APLICAÇÃO DAS REDES NEURAIIS

A arquitetura da rede selecionada conta com 7 entradas, que são: Os processos **HVOF e FS/FC**; a tenacidade K_c (Mpa/m²); a densidade ρ do erodente (Kg/m³); a velocidade v das partículas (m/s); o ângulo α de incidência das partículas (grau); o tempo de realização dos experimentos t (minuto); a dureza do material erodente H_v (N/m²). Duas (2) camadas ocultas, uma camada com (10) neurônios e outra com (5) neurônio, ambos com função de

ativação não-linear, tangente sigmoide e um neurônio de saída, com função de ativação linear. O modelo da topologia da RNA selecionada é então [7-10-5-1], apresentada na Figura 18.

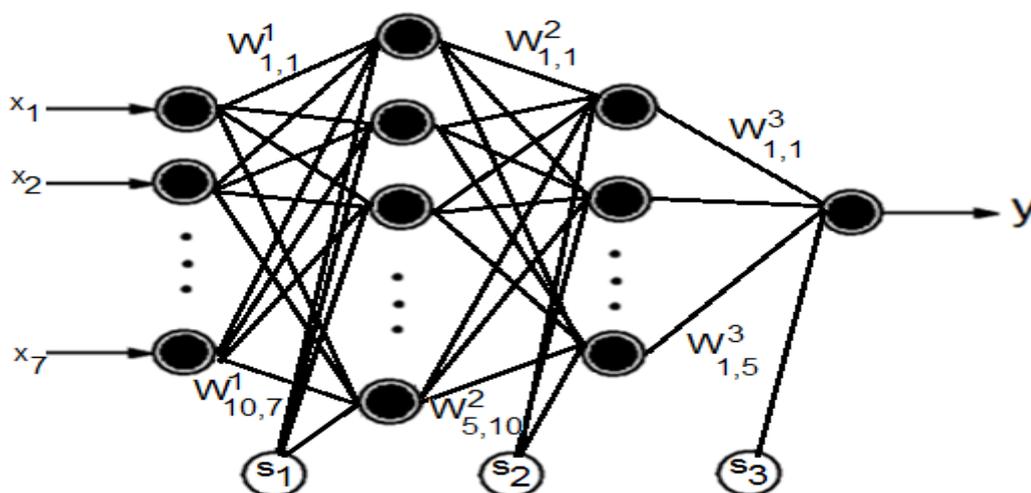


Figura 18 – Topologia da rede neural

O modelo de operação com base em RNA é regido pela equação 48 a seguir:

$$y = N_1 W^3_{1,1} + N_2 W^3_{1,2} + N_3 W^3_{1,3} + \dots + N_5 W^3_{1,5} + S_3 \quad (48)$$

onde:

$$N_i = f(W^2 x + S_2), i = 1,2,3,4,\dots,10 \quad (49)$$

A rede *Perceptron* multicamadas foi conduzida com treinamento supervisionado usando o método de algoritmo de retro propagação do erro e LM.

No caso da topologia da rede, o número de entradas e saídas da RNA foi feita em concordância com as necessidades da aplicação, ou seja, os requisitos do processo em estudo. O número de nós das camadas ocultas foi escolhido e ajustado para o erro desejado, e levando em conta o menor tamanho possível da RNA para reduzir os problemas de convergência, que consiste em não permitir que a rede fique presa a pontos de inflexão e não venha convergir para o ponto ótimo desejado e diminuir o tempo de processamento computacional. A

Figura 19 mostra o treinamento empregado com o algoritmo de otimização numérico LMBP. A curva dos erros obtidos durante o processo de formação é observada utilizando uma topologia do tipo [7-10-5-1].

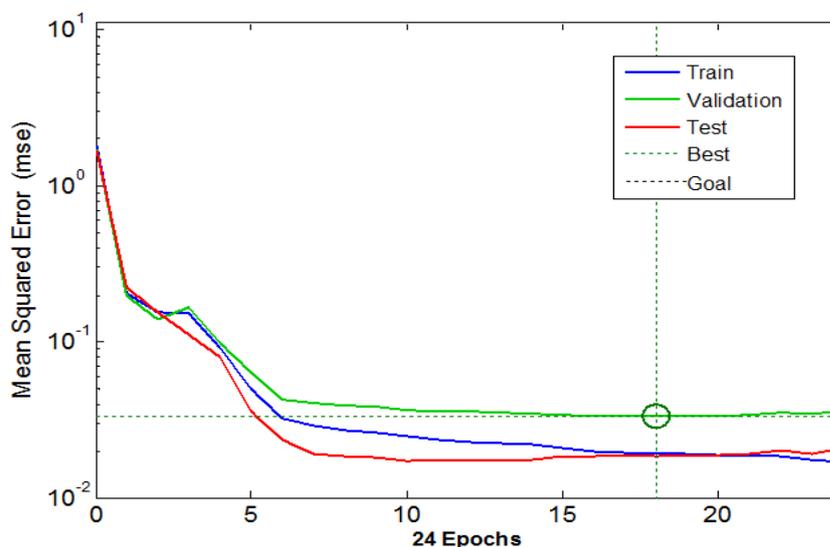


Figura 19 - Curvas do erro durante o treinamento com o algoritmo de *Levenberg-Marquardt*

Na Figura 19, a interseção das linhas pontilhadas, na cor verde, mostra o alvo que a rede deve alcançar. A linha verde contínua mostra o teste de validação do modelo; o treino da rede é indicado pela curva na cor azul e a prova da rede é feita pela curva vermelha; o gráfico mostra uma convergência consistente para a rede com 24 épocas e erro de 0,01.

Uma vez finalizado o treinamento, foram obtidos valores dos pesos e desvios da RNA como resultado da própria formação. Em seguida, foram mostradas as matrizes dos valores dos pesos e desvios que lhe permitem implementar modelo baseado em RNA.

Matriz de pesos w^1 (50)

$$w^1 = \begin{bmatrix} 0.998 & 0.157 & 0.919 & 0.021 & -1.023 & -0.028 \\ -0.545 & 0.668 & 1.848 & 0.784 & 2.300 & 0.190 \\ 0.372 & 0.755 & -0.024 & -1.377 & 1.357 & -0.845 \\ -0.469 & 1.843 & -1.729 & -0.592 & 0.504 & 0.178 \\ -1.792 & -1.361 & 0.601 & 1.334 & -1.299 & -1.059 \\ 1.400 & -2.103 & -1.245 & -1.347 & -0.594 & -2.111 \\ -0.572 & 1.605 & -0.364 & -2.063 & 1.020 & 2.605 \\ 0.597 & 1.870 & -0.163 & -2.098 & -1.129 & 1.022 \\ 0.975 & -0.494 & -1.826 & -1.826 & 1.541 & -1.136 \\ 0.948 & -0.821 & 0.770 & 0.805 & -1.553 & 0,504 \end{bmatrix}$$

Matriz dos desvíos s_1 : (51)

$$s_1 = \begin{bmatrix} -2.834 \\ 3.077 \\ -1.703 \\ 3.167 \\ 1.494 \\ -0.115 \\ -0.155 \\ -1.143 \\ 0.916 \\ -2.645 \end{bmatrix}$$

Matriz de pesos W^2 : (52)

$$w^2 = \begin{bmatrix} 0.605 & 1.488 & 0.775 & -1.167 & -3.099 & 1.107 & -1.794 & 2.804 & 0.255 & 0.939 \\ -0.828 & -0.561 & -0.023 & -1.952 & 0.293 & -0.716 & 0.011 & 0.125 & 0.112 & -0.586 \\ -0.699 & 1.203 & 1.766 & 1.096 & -0.593 & 0.160 & 0.085 & -0.318 & 0.494 & -0.411 \\ 0.609 & 0.923 & -2.166 & 0.510 & -1.599 & -0.397 & 0.066 & 0.704 & 0.345 & -0.580 \\ -1.136 & 0.429 & -0.485 & 0.804 & -1.024 & 0.546 & 0.069 & 0.069 & -0.142 & 0.421 \end{bmatrix}$$

Matriz de desvíos s_2 : (53)

$$s_2 = \begin{bmatrix} -2.482 \\ 0.223 \\ 0.346 \\ -0.642 \\ -1.439 \end{bmatrix}$$

Matriz de pesos W^3 : (54)

$$w^3 = [1.590 \ 0.893 \ 0.559 \ -0.368 \ 0.857]$$

Desvíos s_3 : (55)

$$S_3 = [1.035]$$

Substituindo a matriz dos pesos e dos desvios apresentados nas equações (50), (51), (52), (53), (54) e (55) na equação (48), tem-se o procedimento para validar os resultados. Para isso, foi utilizado 30% dos padrões desconhecidos pelo RNA, foram utilizados para testar a rede e verificar se ela produz os resultados esperados durante a fase de treinamento, e assim, avaliar a capacidade da rede neural de interpolar e de generalizar.

Os valores obtidos na saída do RNA foram introduzidos na fase de pós-processamento para obter os valores reais de eficiência. Uma comparação entre os valores numéricos calculados pelo modelo proposto baseado em RNA, equação 48, pelos valores reais obtidos pelo modelo da eficiência proposta na literatura, equação 3, é mostrado na Figura 20.

O resultado mostrado na Figura 20 demonstra que, para a topologia selecionada ([7-10-5-1]), pode ser obtida uma precisão superior a 95,51% em prever a eficácia dos parâmetros experimentais medidos. O uso de uma topologia com um maior número de camadas escondidas e neurónios pode requerer mais tempo para cálculo do modelo.

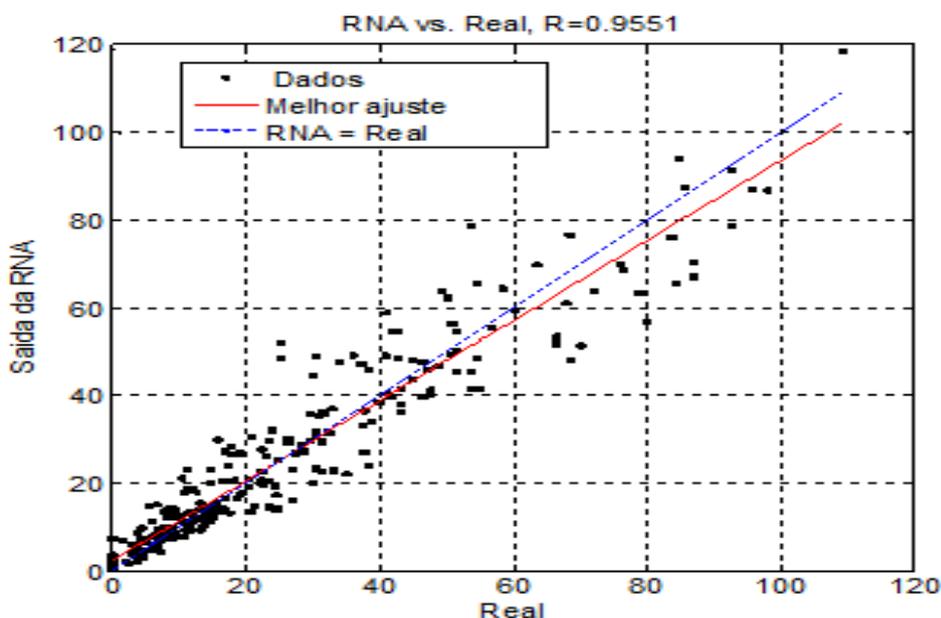


Figura 20: Análise comparativa entre os valores reais e os obtidos pela RNA

A avaliação da RNA utilizando dados de ensaio demonstra que existe uma relação quase linear entre os valores reais da proposta de eficiência, equação 3 e os calculados com o modelo da RNA, equação 48. A grande vantagem dos valores obtidos com o uso de RNA é sua capacidade de estimar novos valores de eficiência utilizando a sua capacidade de generalização.

A magnitude da eficiência η pode ser utilizada para caracterizar a natureza e o mecanismo de erosão. Neste caso, valores η estavam acima da unidade, que está acima de 100%. Isto é típico de materiais duros, em que o fenômeno de erosão resulta no aparecimento de fissuras entrelaçadas, como mostra a Figura 21. Essa figura mostra fissuras na microestrutura de um revestimento feito com o material RocDur62, que pode contribuir para o mecanismo de desgaste. Em a), antes do processo de erosão, a superfície do substrato tem uma rugosidade acentuada e, em b), após o processo de erosão, a superfície do substrato se mostra com rugosidade visivelmente menos acentuada do que em a); isso se deve ao processo de desgaste ao qual a mesma foi submetida. A seta indica o encontro de fissuras entrelaçadas que cooperam para aumento do desgaste.

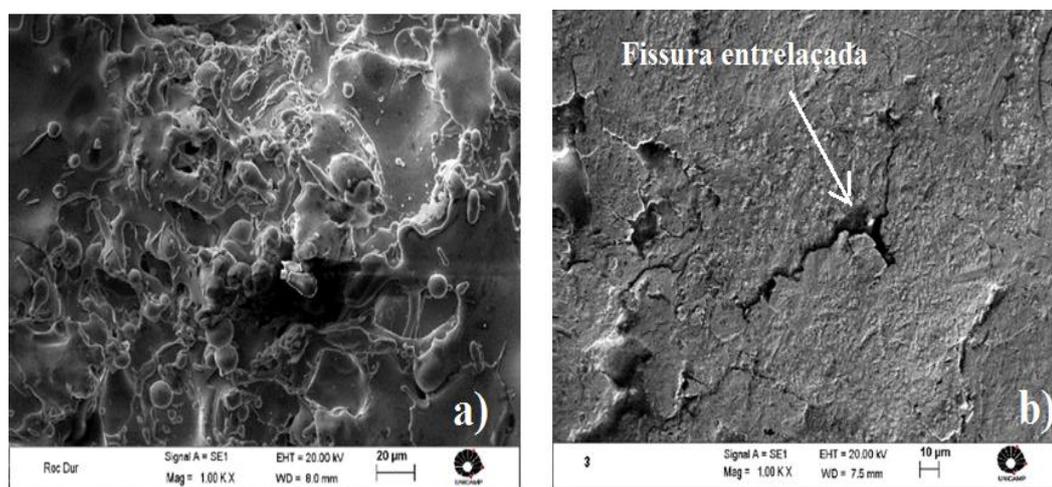


Figura 21 – Superfície do revestimento com RocDur62: a) antes; e b) depois do processo de erosão.

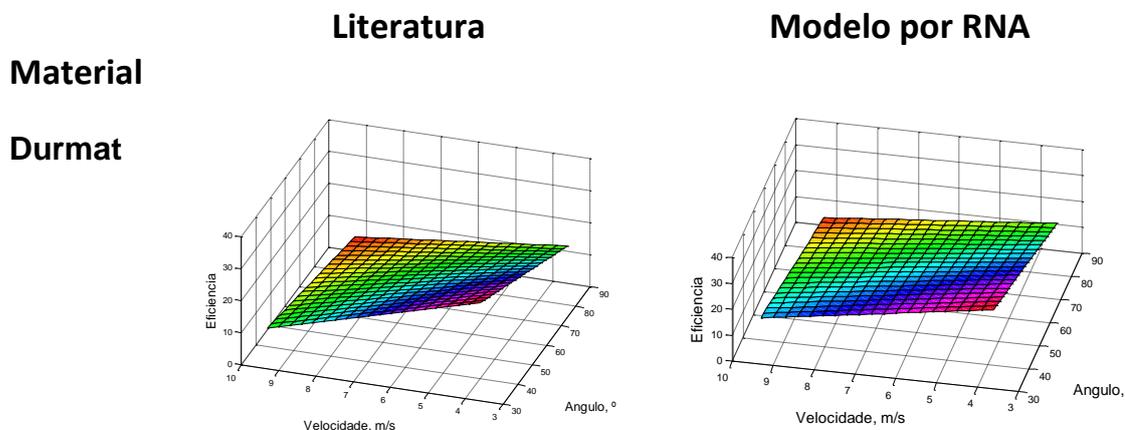
A plotagem dos dados da Tabela 16 resulta na Figura 22. E a Tabela 17 resulta na Figura 23. A eficiência de desgaste, obtida dos dados experimentais, foi plotada em função da velocidade e do ângulo de impacto, para efeito de

comparação, tanto para o modelo da literatura, quanto para o modelo proposto por redes neurais artificiais. Foi feita uma análise interpretativa dos mesmos de modo a se ter uma visão do comportamento do desgaste erosivo e sua correlação com a eficiência, assim como a correlação da eficiência de desgaste com a tenacidade à fratura.

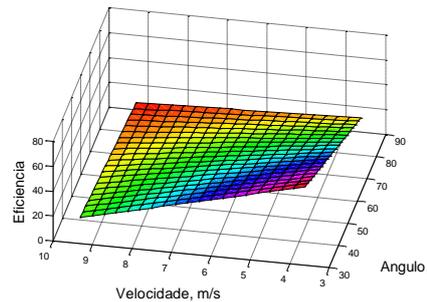
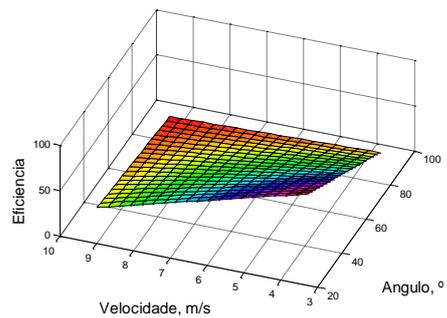
Tabela16 – Dados da eficiência de desgaste obtida pelo modelo proposto na literatura e pelo modelo de redes neurais, a partir dos dados experimentais, para o processo HVOF

Processo	Material	Velocidade (m/s)	Eficiência (Literatura)		Velocidade (m/s)	Eficiência da RNA	
			30º	90º		30º	90º
HVOF	Durmat		30º	90º		30º	90º
		3,61	30,533	11,679	3,61	30,7566	10,4324
		9,33	12,545	4,515	9,33	17,7920	17,7920
	8812		30º	90º		30º	90º
		3,61	78,929	12,244	3,61	63,5142	11,4786
		9,33	18,241	6,200	9,33	20,6297	5,6003
	7525		30º	90º		30º	90º
		3,61	19,516	4,828	3,61	17,5724	4,8512
		9,33	14,552	4,081	9,33	11,4151	4,0520
	1350		30º	90º		30º	90º
		3,61	37,126	8,672	3,61	47,1698	9,9061
		9,33	18,556	3,238	9,33	16,4395	4,6311
	88HV		30º	90º		30º	90º
		3,61	12,105	2,988	3,61	18,5178	3,6054
		9,33	11,083	4,325	9,33	11,0807	7,0996

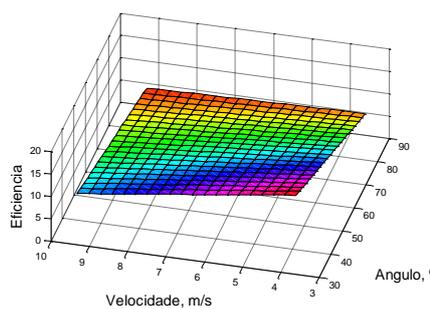
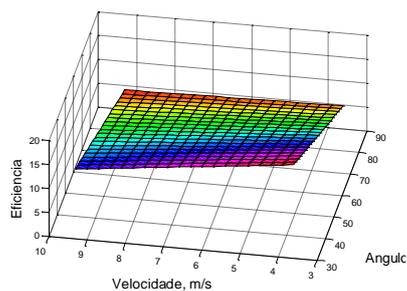
A Figura 22 mostra a superfície de resposta com o comportamento da eficiência de desgaste erosivo em função do ângulo de impacto e da velocidade das partículas com o processo HVOF



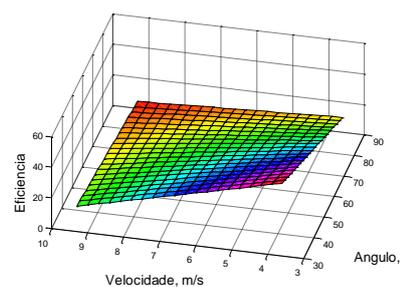
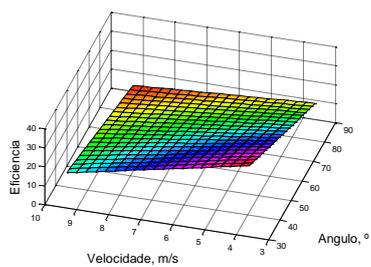
8812



7525



1350



88HV

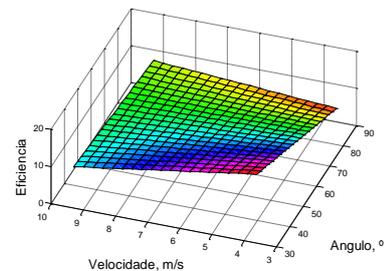
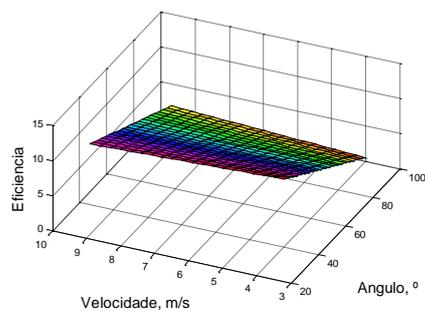
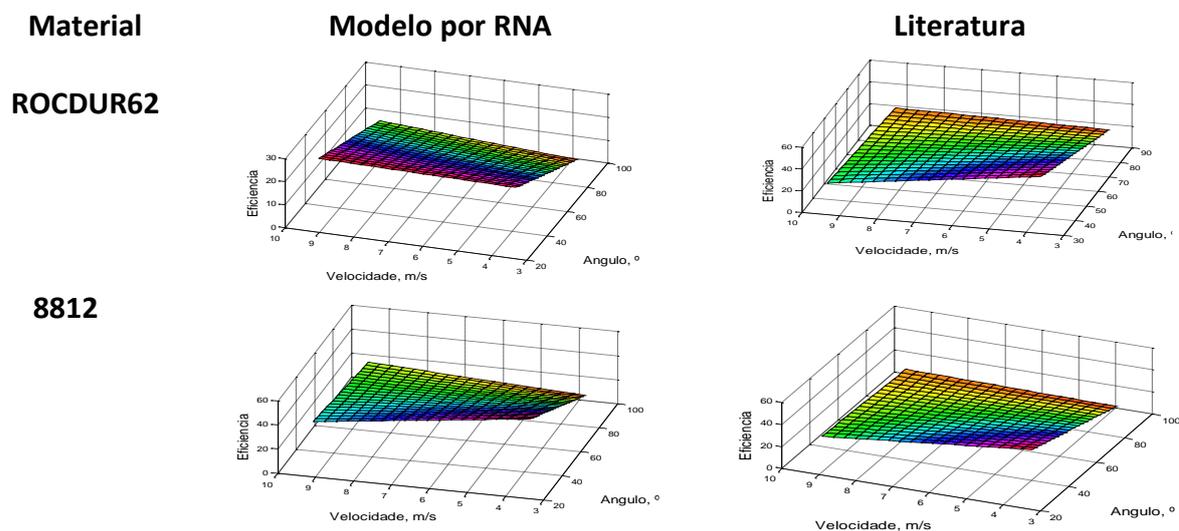


Figura 22: Comparação entre a superfície de resposta da eficiência de desgaste das partículas, dos materiais aplicados com o processo HVOF.

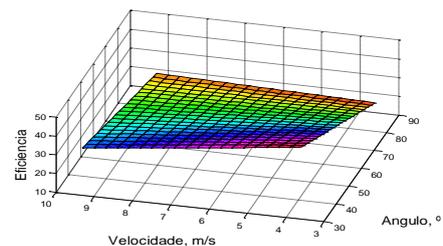
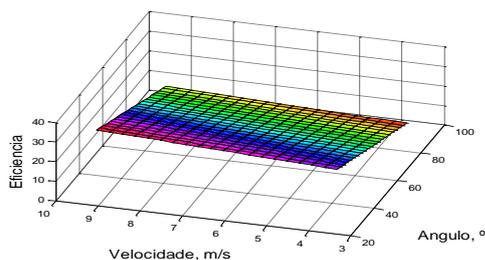
Tabela17 – Mostra os dados da eficiência de desgaste obtida pelo modelo proposto na literatura e pelo modelo de redes neurais, a partir dos dados experimentais, para os processos FS/FC.

Processo	Material	Velocidade (m/s)	Eficiência da Literatura		Velocidade (m/s)	Eficiência da RNA	
			30°	90°		30°	90°
FS/FC	ROCDUR 62		30°	90°		30°	90°
		3,61	25,072	5,552	3,61	51,9687	14,8457
		9,33	26,264	10,994	9,33	29,1592	17,9988
	8812		30°	90°		30°	90°
		3,61	55,126	15,057	3,61	41,2105	14,5272
		9,33	35,061	24,553	9,33	22,0450	17,0561
	7525		30°	90°		30°	90°
		3,61	25,408	6,520	3,61	48,3542	15,0819
		9,33	30,997	10,830	9,33	35,0517	17,9255
	1550		30°	90°		30°	90°
		3,61	31,966	13,173	3,61	35,5407	15,4151
		9,33	72,157	22,471	9,33	63,9339	19,6054
15HC		30°	90°		30°	90°	
	3,61	79,722	21,218	3,61	56,6486	14,7212	
	9,33	63,573	19,314	9,33	69,7585	17,4412	

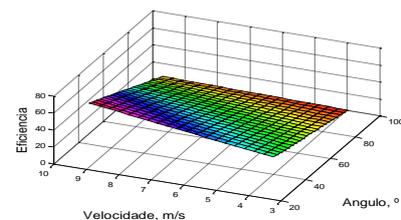
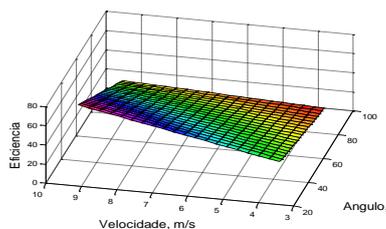
A Figura 23 mostra a superfície de resposta com o comportamento da eficiência de desgaste erosivo em função do ângulo de impacto e da velocidade das partículas com o processo FS/FC



7525



1550



15HC

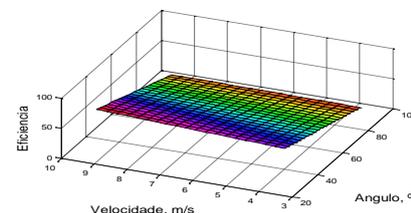
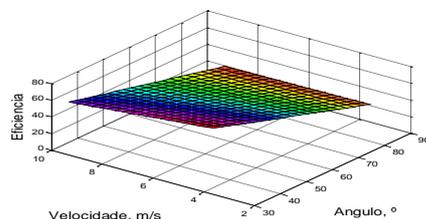


Figura 23: Comparação entre a superfície de resposta da eficiência de desgaste das partículas, dos materiais de pesquisa aplicados com o processo FS/FC.

Para o processo HVOF, na Tabela 16, o material Durmat tem eficiência maior para a velocidade de 3,61m/s, já para o material 8812, a eficiência é maior para a velocidade de 3,61m/s do que para a velocidade de 9,33m/s, para os dois modelos, nos dois ângulos. No material 7525, a eficiência é maior para os dois ângulos e para os dois processos, para a velocidade de 3,61m/s, maior do que a velocidade de 9,33m/s. A menor eficiência para o 88HV foi obtida com o ângulo de 90° e velocidade de 9,33m/s. O material 1350 tem a maior diferença entre a eficiência das duas velocidades, com a eficiência da velocidade de 3,61m/s sempre maior. Para o material 88HV a eficiência é maior para a velocidade de 3,61m/s do que a eficiência da velocidade de 9,33m/s para os ângulos de 30°, tanto para o modelo da literatura quanto para o modelo de RNA. A superfície de resposta está mais espaçada para a eficiência da RNA comparado à obtida pela literatura.

Para o processo FS/FC, na Tabela 17, o material ROCDUR62 tem eficiência maior para a velocidade de 3,61m/s e ângulo de 30,° e para o modelo da rede neural ela é menor para todas as outras condições. O material 8812 tem

eficiência maior nos dois ângulos e nos dois modelos com a velocidade de 3,33m/s. O material 7525, com velocidade de 3,61m/s, tem eficiência maior somente para o ângulo de 30° e para o modelo da RNA com relação à velocidade de 9,33m/s. O material 1550, com a velocidade de 3,61m/s é sempre menor do que a velocidade de 9,33m/s para o modelo da literatura e da RNA. O material 15HC tem eficiência maior para o modelo da literatura com a velocidade de 3,61m/s e menor para o modelo da RNA. Para todos os materiais há uma convergência mais acentuada para a eficiência a um ângulo de 30° e velocidade de 3,61m/s, maior do que a eficiência obtida com ângulo de 90° e velocidade de 9,33 m/s. Isto se deve ao fato de a velocidade de desgaste ser mais acentuada para o ângulo nas proximidades de 30°. A eficiência no processo HVOF é menor. Isto mostra que o processo HVOF produz revestimento mais resistente ao desgaste erosivo.

De modo geral, a eficiência de desgaste, proposto pelo modelo de rede neural, é ligeiramente superior do que a eficiência proposta na literatura. Este comportamento pode ser observado na Figura 24.

A Figura 24 mostra a superfície de resposta da eficiência de desgaste, plotada em função dos parâmetros: velocidade e ângulo de impacto. Observa-se que a eficiência de desgaste decresce com o acréscimo do ângulo e que a eficiência cresce lentamente com aumento da velocidade de impacto.

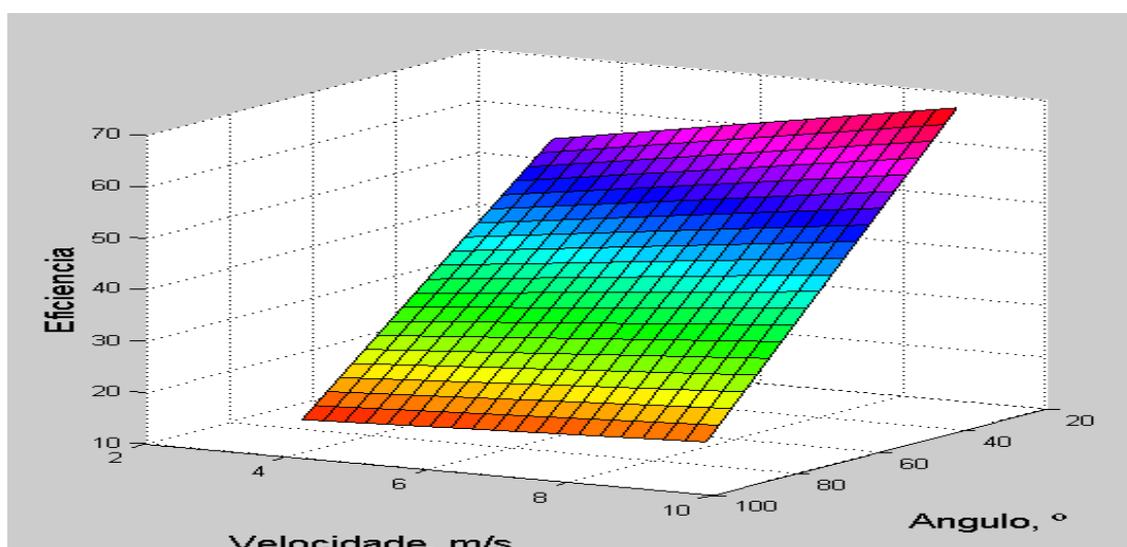


Figura 24 – Gráfico mostra a superfície de resposta da eficiência de desgaste em função da velocidade e do ângulo de impacto.

Esse comportamento fica mais claro quando se gira a Figura 24 e a superfície de resposta da eficiência é plotada em função somente do ângulo de impacto, como na Figura 25. Quando se plota a eficiência de desgaste somente em função da velocidade de impacto, como mostra a Figura 25, percebe-se uma ligeira curvatura na superfície de resposta. Em grande parte, este comportamento é explicado pela tenacidade à fratura, tendo em vista que o material vai absorvendo energia e isso faz com que haja um novo arranjo da sua microestrutura, o que leva ao comportamento não linear.

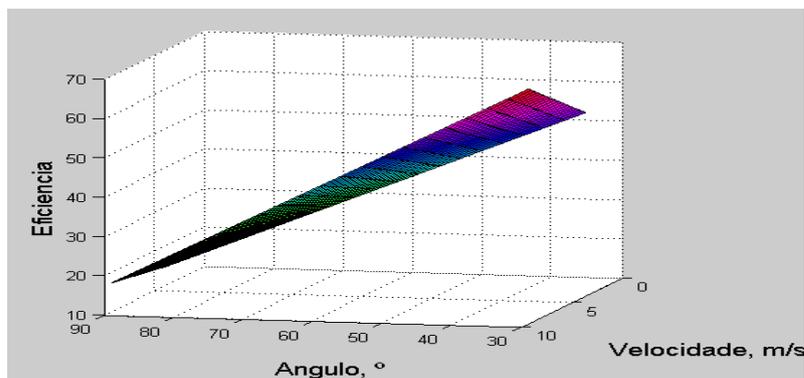


Figura 25. Superfície de resposta da eficiência de desgaste com o ângulo de impacto

Na Figura 25, o aumento no ângulo de impacto tem diminuição correspondente da eficiência de desgaste.

Na figura 26, ao se plotar a eficiência de desgaste somente em função da velocidade de impacto, percebe-se que o aumento na velocidade tem aumento correspondente na eficiência de desgaste.

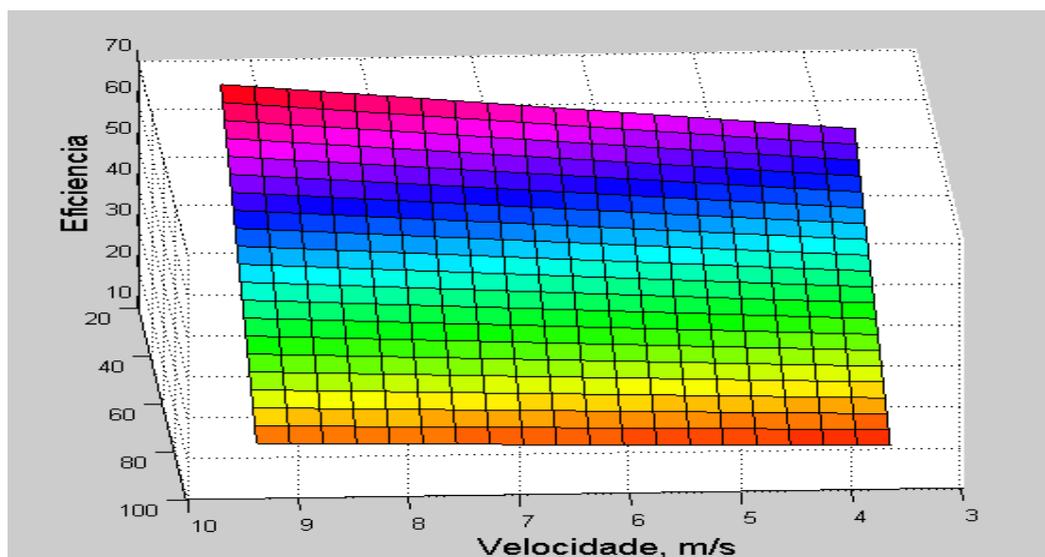


Figura 26- mostra a superfície de resposta da eficiência de desgaste em função da velocidade das partículas.

6. CONCLUSÃO E SUGESTÕES PARA TRABALHO FUTURO

6.1. CONCLUSÃO

Neste trabalho, foi apresentado um novo modelo, baseado em redes neurais artificiais, para ajustar os dados de eficiência de desgaste, com dados dos experimentos dos materiais escolhidos para teste, aplicados por aspersão térmica com os processos HVOF e FS/FC.

Um comparativo entre o modelo proposto, baseado em rede neural artificial e o modelo consolidado na literatura, mostrou que o valor estimado tem um comportamento ajustado aos dados reais e, mesmo que se observe uma pequena discrepância entre os dados, ela fica dentro do intervalo de confiança estabelecido para a análise estatística.

O método de aspersão térmica utilizando FlexiCord é um método alternativo ao processo de aspersão térmica a chama convencional. É uma nova técnica para produzir revestimentos com carbonetos metálicos de cerâmica com alta qualidade, utilizando o mesmo equipamento e princípios do método aspersão térmica a chama convencional.

A técnica FS/FlexiCords fornece características de revestimento exclusivo e tem uma ampla gama de aplicações em diversos setores do mercado. Não é uma tecnologia que compete com outras técnicas de revestimento, tais como a aspersão a plasma ou HVOF. A tecnologia de aspersão térmica FS/FlexiCords é complementar à aspersão de chama convencional e tem diferentes benefícios e operação de ajuste mais rápido.

No modelo proposto, não serão necessários ensaios de desgaste para estimar a eficiência, constituindo uma das principais vantagens do mesmo. Na nova proposta, a eficiência de desgaste é determinada pela variação dos pesos W_1 , W_2 e W_3 que representam a matriz de ponderação dos neurônios da camada de entrada, ocultas e saída, respectivamente; com os desvios s_1 , s_2 , e s_3 que representam os desvios de cada um dos neurônios da camada de entrada, oculta e de saída da rede, em um processo de aprendizagem. Com isso, o modelo prediz a eficiência de desgaste sem ensaios de desgaste.

Com a inclusão da tenacidade, o modelo da rede neural faz os ajustes dos pesos e dos desvios levando em conta a variação progressiva do acúmulo de energia até o início de propagação da trinca, o que permite a otimização dos valores de predição a cada incremento de tempo e absorção de energia pelo material, no processo de aspersão.

A avaliação da RNA, utilizando dados experimentais, demonstra que existe uma relação quase linear entre os valores reais da eficiência de desgaste, proposto na literatura, regidos pela equação 3, e os calculados com o modelo de RNA, regidos pela equação 48. A grande vantagem dos valores obtidos com o uso de RNA é a sua capacidade de generalização.

Com relação ao desempenho da rede neural, foi observado um desempenho elevado para todos os testes efetuados com todos os materiais, com rápida convergência para ambos os processos de aspersão, com coeficiente de determinação (R^2) de 95,51%. Em uma rede neural, maiores coeficientes de determinação indicam melhor capacidade de aproximação dos dados de saída com os dados reais.

A comparação entre a taxa de desgaste para os dois processos, mostrou que ela é maior para os materiais aplicados pelo processo FS/FC do que com o processo HVOF. Isso implica que o processo HVOF produz revestimento de maior qualidade, mais resistente ao desgaste.

Ao se comparar a eficiência de desgaste erosivo com o ângulo de impacto e a velocidade das partículas, percebe-se que há uma correlação entre a taxa de desgaste e a eficiência de desgaste e da taxa de desgaste com a tenacidade à fratura. Pelo fato do modelo de RNA estar ajustado ao modelo da literatura de forma quase linear, o modelo proposto, por meio da rede neural, pode ser utilizado para determinar o comportamento do desgaste erosivo, cumprindo assim, com o objetivo estabelecido para este trabalho.

6.2. SUGESTÕES PARA TRABALHOS FUTUROS.

Com o objetivo de melhorar as técnicas empregadas, aumentando a precisão dos valores estimados e preditos, bem como expandir o trabalho para outros processos de aspersão, sugerimos novas pesquisas que venha:

- Desenvolver uma metodologia que utilize os dados preditos de eficiência de desgaste para criar um mapa de tendência do processo de aspersão;
- Utilizar o modelo proposto para classificação de materiais quanto ao comportamento de desgaste erosivo;
- Aplicar diferentes arquiteturas de redes neurais para estimar o efeito da eficiência do desgaste erosivo utilizando outros processos de aspersão e outros materiais comumente aplicados na indústria.
- Desenvolver aplicações do método FlexiCord, com os materiais de pesquisa deste trabalho, utilizando redes neurais artificiais e o método de elementos finitos de modo a permitir a comparação do resultado dos dois métodos e com resultado experimentais e gerar conhecimentos da técnica FlexiCord, de modo a que possa ser recomendado em aplicações específicas.

7. REFERÊNCIAS

ALAVI, S.; MOSTAGHIMI, J.; PASSANDIDEH-FARD, M. Simulation of Semi-Molten Particle Impacts Including Heat Transfer and Phase Change. **Journal of**

Thermal Spray Technology, v.21, n.6 p. 1278-1293, 2012.

ARORA, H.S.; GREWAL, H.; SINGH, MUKHERJEE, S., Zirconium based bulk metallic Glass-Better resistance to slurry erosion compared to hydroturbine steel. **Wear**, v. 307, n.1-2, p. 28-34, set. 2013.

ASTM INTERNACIONAL. **ASTM D5045 – 14**: standard Test Methods for Plane-Strain Fracture Toughness and Strain Energy Release Rate of Plastic Materials. West Conshohocken. 2014. Disponível em: <www.astm.org/Standards/D5045>. Acesso em: 15 fev. 2016.

BALASUBRAMANI, P.; MURUGAN, P. R. Efficient Image Compression Techniques for Compressing Multimodal Medical Images Using Neural Network Radial Basis Function Approach. **International Journal of Imaging Systems and Technology**, v.25, n.2, p.115-122, jun. 2015.

BALASUBRAMANIAN, B.; VIJAYALAKSHMY, S. Enhanced performance of dye-sensitized solar cells with TiO₂ blocking layers and Pt counter electrodes prepared by physical vapor deposition (PVD). **Electrochemical Acta**, v.116, p. 334–342, 2014.

BALASUBRAMANIAN, V.; THIRUVIKRAMAN, C.; SRIDHAR, K. Optimizing HVOF Spray Parameters to Maximize Bonding Strength of WC-CrC-Ni Coatings on AISI 304L Stainless Steel. **Journal of Thermal Spray Technology**, v. 23, n. 5, p.860-875, jun. 2014.

BEHERA, A. **Processing and characterization of plasma spray coatings of industrial waste and low grade ore mineral on metal substrates**. 2012. 92p. Thesis (Master of technology in metallurgical & materials engineering).- Program of Metallurgical & Materials Engineering, National Institute of Technology, Rourkela - India, 2012.

BESHISH, G. K. et al. Fracture toughness of thermal spray ceramic coatings determined by the indentation technique. **Journal of Thermal Spray Technology**, v.1, n. 2, p. 35-38, mar. 1993.

BODYANSKIY, Y. V.; TYSHCHENKO, A.K.; DEINEKO, A. A. An evolving radial basis neural network with adaptive learning of its parameters and architecture. **Automatic Control and Computer Sciences**, v. 49, n. 5, p. 255–260, 2015.

BOLELLI, G.; Bonferroni B.; Coletta G.; Lusvarghi L.; Pitacco F. Tribological behavior of HVOF- and HVOF-sprayed composite coatings based on Fe-Alloy + WC–12% Co. **Surface & Coatings Technology**, v. 248, p. 104–112, 2014.

BOUSSER, E. Solid Particle Erosion Mechanisms of Protective Coatings for Aerospace Applications. **Surface & Coatings Technology**, v. 257, p. 165-181, 2014.

BRAGA, A. P.; CARVALHO, A. P.; LUDERMIR, T. B. **Redes Neurais Artificiais: teoria e Aplicações**. Rio de Janeiro: LTC Livros Técnicos, 2000. 262p.

BRINK, R. **Revestimentos de Nitreto de Titânio Através do Processo P.V.D. e sua utilização em ferramentas**. Balzers, Liechtenstein: Brasimet, 1998. Apostila.

BROOMHEAD, D. S.; LOWE, D. Multivariable Functional Interpolation and Adaptive Networks. **Complex Systems**, v. 2, n.3, p. 321 – 355, 1988.

CARRARA, V. **Redes Neurais Aplicadas ao Controle de Atitude de Satélites com Geometria Variável**. 1997. Tese (Doutorado em Mecânica Espacial e Controle).—Programa de Pós-Graduação em Engenharia e Tecnologias Espaciais, Instituto Nacional de Pesquisas Espaciais, São José dos Campos – SP, 1997.

ÇETIN, O.; TEMURTAS, F.; GÜLGÖNÜL, S. An application of multilayer neural network on hepatitis disease diagnosis using approximations of sigmoid activation function Sigmoid. **Dicle Medical Journal: Dicle Tıp Dergisi**, India, v. 42, p. 150-157, 2015.

CHEN, J.; ZENG, H.; FAN, N. Nonlinear distance function learning using neural network: an iterative framework. **Multimedia Tools and Applications**, v. 74, p. 671–688, 2015.

CHEN, S.; BILLINGS, S. A.; GRANT, P. M. Recursive hybrid algorithm for non-linear system identification using radial basis function networks. **International Journal of Control**, v. 55, n. 5, p. 1051-1070, 1992.

CHOUDHURY, T. A.; BERNDT, C. C.; ZHIHONG, MAN. An Extreme Learning Machine Algorithm to Predict the In-flight Particle Characteristics of an Atmospheric Plasma Spray Process. **Plasma Chemistry and Plasma Processing**, v 33, n.5, p. 993–1023, 2013.

CONTRUCCI, J. G. **Aplicação de Redes Neurais Artificiais na Predição de Diâmetro e Rugosidade Durante o Processo de Furação**. 2012. Dissertação (Mestrado em Engenharia Elétrica).— Programa de Pós-Graduação em Engenharia Elétrica, Universidade Estadual Paulista, Bauru - SP, 2012.

CULLITON, D. et al. Improving Tribological Properties of Cast Al-Si Alloys through Application of Wear-Resistant Thermal Spray Coatings. **Journal of Thermal Spray Technology**, v. 22, n. 4, p. 491-501, 2013.

DAS, N. **A Study ON Analysis and Prediction of Erosion Response of Plasma Sprayed Alumina Coatings**. 2012. Dissertation (Master of Technology in Metallurgical & Materials Engineering) - Program of Metallurgical & Materials Engineering, National Institute of Technology, Rourkela - India, 2012.

DONNARUMMA, F. et al. Programmer–Interpreter Neural Network Architecture for Prefrontal Cognitive Control. **International Journal of Neural Systems**, v. 25, n. 6, 2015.

DRIVER, L.C. **HVOF spraying of WC-Co & MCrAlY coatings for aero engine components**. 2004. Thesis (PhD Mechanical, Materials and Manufacturing Engineering).— Program of Mechanical, Materials and Manufacturing Engineering, University of Nottingham, Nottingham-England, 2004.

DUER, S. et al. Training of an artificial neural network in the diagnostic system of a technical object. **Neural Computing and Applications**, v. 22, p. 1581–1590, 2013.

EDRIS, H. **Studies on high velocity oxy-fuel sprayed coatings of Inconel 625 and Ni-Cr3C2**. 1997. Thesis (PhD Mechanical, Materials and Manufacturing Engineering) - Program of Mechanical, Materials and Manufacturing Engineering, University of Nottingham, Nottingham - England, 1997.

FINNIE, I.M. Erosion of surfaces by solid particles. **Wear**, v.3, n.2, p. 87–103, mar./abr. 1960.

FLEICHER G. Triboquímica. **Review of Materials Research**, v.18, p. 303–323, 1988.

FONTANA, L.C. **Estudo da deposição de filmes de Ti e TiN e desenvolvimento de sistema modificado triodo-magnetron-sputtering**. 1997. Tese (Doutorado em Engenharia Mecânica).— Programa de Pós-Graduação em Engenharia Mecânica, Universidade Federal de Santa Catarina, Florianópolis – SC, 1997.

FROSELL, T.; FRIPP, M.; GUTMARK, E. Investigation of slurry concentration

effects on solid particle erosion rate for an impinging jet. **Wear**, v. 342-343, p. 33–43, nov. 2015.

FUJITA, E. G. L. **Modelagem de Forno Para a Produção de Cimento Através da Aplicação de Técnicas de Redes Neurais**. 2001. Dissertação (Mestrado em Engenharia Química).— Programa de Pós-Graduação em Engenharia Química, Universidade Estadual de Campinas, Campinas - SP, 2001.

GHOSH, P.K.; KUMAR, R. Surface Modification of Micro-Alloyed High-Strength Low-Alloy Steel by Controlled TIG Arcing Proces. **Metals & Materials Society and ASM Internacional**, [S.l.], 2014.

HACKETT, C. M.; SETTLES, G. S. The influence of the nozzle design on HVOF spray particle velocity and temperature. In: **Proceedings of the 8th National Thermal Spray Conference**, September 11-15, Houston, Texas, USA. [s.n.], 1995.

HAMDIA, K. et al. Predicting the fracture toughness of PNCs: A stochastic approach based on ANN and ANFIS. **Computational Materials Science**, v.102, p. 304–313, 2015.

HASSAN, A. M. et al. Prediction of density, porosity and hardness in aluminum–copper-based composite materials using artificial neural network. **Journal of Materials Processing Technology**, v. 209, p. 894 - 899, 2009.

HAYKIN, S. **Neural networks: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001.

HEATH, P.J.; CUBBERLY, W N H. Ultra hard Tool Materials, in **Metals Handbook**. ASM International. Ohio: Metals Park, 1989.

HEBB, D. O. The Organization of Behavior. Wiley: [s.n.], 1969.

HOPFIELD, J. Neural networks and physical systems with emergent collective properties. **Proceedings of the National Academy of Sciences of the United States of America**, v. 79, n. 8, p. 2554-2558, 1982.

HOUDKOVA, S. KAŠPAROVA, W. Experimental study of indentation fracture toughness in HVOF sprayed hard metal coatings. **Engineering Fracture Mechanics**, v.110, p. 468–476, 2013.

HUNT, K. J., SBARBARO, D., ŽBIKOWSKI, R., GAWTHROPET, P.J. Neural networks for control systems: a survey. **Automatica**, v.28, n. 6, p. 1083- 1112, 1992.

HUTCHINGS, I. M.A. Model for the Erosion of Metals by Spherical Particles at Normal Incidence. **Wear**, v. 70, n.2, p. 269 – 281, 1981.

HUTCHINGS, I.M., **Tribology**: Friction and Wear of Engineering Materials. London: Edward Arnold,1992. p.171-197.

ILYUSCHENKO, A.P. et al. On the properties of PVD coating based on nanodiamond and molybdenum disulfide nanolayers and its efficiency when drilling of aluminum alloy. **Surface & Coatings Technology**, v. 270, p.190-196, 2015.

JAFARI, M. et al. Microstructural and mechanical characterizations of a novel HVOF-sprayed WC-Co coating deposited from electrolysis Ni-P coated WC-12Co powders. **Materials Science & Engineering**, v. 578, p. 46–53, 2013.

JEAN, M.D.; LIN, B.-T.; WU, C.-S. Artificial neural networks for surface modification of cobalt based tungsten cemented carbide deposits. **Surface Engineering**, v.25, n. 1, 2009.

KATO, K.; ADACHI, K. Wear Mechanisms. In: **Modern tribology handbook**. [S.I.]: CRC Press LLC, 2001. cap 22.

KHALAJ, G. Artificial neural network to predict the effects of coating parameters on layer thickness of chromium carbonitride coating on pre-nitrided steels. **Neural Computing & Application**, v. 23, p. 779–786, 2013.

KHULLAR, P. **Evaluation of Erosion Wear of Turbine Steels in Hydropower Plants**. 2014. Dissertation (Master of Engineering, Mechanical Engineering)—Program of Engineering, Thapar University, Patiala - India, 2014.

KOIVO, H. N. **Neural Networks: Basics using MATLAB Neural Network Toolbox**. London: Matwork, 2015.

KRANTHI, G.; SATAPATHY, A. Evaluation and prediction of wear response of pine wood dust filled epoxy composites using neural computation. **Computational Materials Science**, v. 49, p. 609 - 614, 2014.

KUDRYAKOV, O.V.; VARAVKA, V.N. Mechanisms and Laws of Steel Surface Degradation during the Stages of Developed Droplet Erosion. **Journal of Surface Investigation**, v. 9, n. 1, p. 203–214, 2015.

LAKSHMINARAYANAN, A.K.; BALASUBRAMANIAN, V. Comparison of RSM with ANN in predicting tensile strength of friction stir welded AA7039 aluminium alloy joints. **Transactions of the Materials Research Society**, v.19, p. 9-18, 2009.

LALITHAMMA, G.A.; PUTTASWAMY, P.S., Literature Review of Applications of Neural Network in Control System, **International Journal of Scientific and Research Publications**, v. 3, 2013.

LEE, C.W.; HAN, J.H.; YOON, J.; SHIN, M.C.; KWUN, S.I. A study on powder

mixing for high fracture toughness and wear resistance of WC–Co–Cr coatings sprayed by HVOF. **Surface & Coatings Technology**, v. 204, p. 2223 - 2229, 2010.

LIMA, C. R. C.; TREVISAN, R. **Aspersão térmica: Fundamentos e Aplicações**. São Paulo: Artliber, 2007.

LINDGREN, M.; SUIHKONEN, R.; VUORINEN, J. Erosive wear of various stainless steel grades used as impeller blade materials in high temperature aqueous slurry. **Wear**, v. 328-329, p. 391 - 400, 2015.

LIU, H.; TIAN, H; LI, Y. F.; ZHANG, L. Comparison of four Adaboost algorithm based artificial neural network in wind speed predictions. **Energy Conversion and Management**, v. 92, p. 67- 81, 2015.

LYPHOUT, C.; FASTH, A.; NYLEN, P. Mechanical Property of HVOF Inconel 718 Coating for Aeronautic Repair. **Journal of Thermal Spray Technology**, v. 23, n.3, p.380-388, 2014.

MABBUTT, S.; PICTON, P.; SHAW, P.; BLACK, S. Review of Artificial Neural Networks (ANN) applied to corrosion monitoring. **Journal of Physics: 25th International Congress on Condition Monitoring and Diagnostic Engineering Conference Series**, 364, 2012.

MANUAL MATHEMATICA. **Neural network: Train and Analyze Neural Networks to Fit Your Data**. [S.I.]: Wolfram Research, 2015.

MARQUES, M. R. C.; ADRIANA A. A. E.; KELLEY C. R. S.; LUCIANA C. C. Evaluation of ion exchange resins for recovery of metals from electroplating sludge. **Polymers**, v.70, p. 2239–2255, 2013.

MARROCCO, T. **Development of improved cold spray and HVOF deposited**

coatings. 2008. Thesis (Phd Mechanical, Materials and Manufacturing Engineering).— Program of Mechanical, Materials and Manufacturing Engineering, University of Nottingham, Nottingham - India, 2008.

MIGUEL, P.A.C. (Org.). **Metodologia de pesquisa para engenharia de produção e gestão de operações, recurso eletrônico.** 2.ed. Rio de Janeiro: ABEPRO, 2012.

MISHRA, S.C.; CHAITHANYA, M.; SATAPATHY, A.. Neural Network Analysis for Erosion Wear of Nickel - Aluminate Coatings on Steel by Plasma Spraying, 23rd National Symposium on Plasma Science & Technology. **Journal of Physics: Conference Series** 208, [S.I.] 2010.

MURUGAN, K. et al. Optimizing HVOF spray process parameters to attain minimum porosity and maximum hardness in WC–10Co–4Cr coatings. **Surface & Coatings Technology**, v., 247, p. 90–102, 2014.

MUTAIRI, S. A. et al. Microstructural characterization of HVOF/plasma thermal spray of micro/nano W C–12%Co powders. **Surface & Coatings Technology**, v. 264, p. 175–186, 2015.

NGUYEN, V.B. et al. A combined numerical–experimental study on the effect of surface evolution on the water–sand multiphase flow characteristics and the material erosion behavior. **Wear**, v. 319, n.1-2, p. 96 - 109, 2014.

NGUYEN, D. H.; WIDROW, B. Neural networks for self-learning control Systems. **IEEE Control Systems Magazine**, v. 10, n. 3, p.18-23, 1990.

NISTAL, A. et al. Flame spraying of adherent silicon coatings on sic substrates. **Surface & Coatings Technology**, v.270, p. 8-15, 2015.

OCHOA, D. M. L. **Estudo do desgaste erosivo corrosivo de aços**

inoxidáveis de alto nitrogênio em meio lamacento. 2007. Tese (Doutorado em Engenharia).— Programa de Pós-Graduação em Engenharia de Produção, Universidade de São Paulo, São Paulo - SP, 2007.

OKSA, M. et al. Optimization and Characterization of High Velocity Oxy-fuel Sprayed Coatings: Techniques. **Materials and Applications, Coatings**, v.1, p. 17-52, 2011.

OLIVEIRA, A. R. **Redes neurais artificiais aplicadas na detecção, classificação e localização de defeitos em linhas de transmissão.** 2005. Dissertação (Mestrado em Engenharia Elétrica).— Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Juiz de Fora, Juiz de Fora - MG, 2005.

OROZCO, M. C. S. **Tribocorrosion de Nuevos Materiales com Recobrimientos Duros.** [S.l.]: [s.n.], 2015. Trabalho de pesquisa de pós-doutorado, Projeto CAPES/MES – 131/11.

OZDEMIR, I.; OGAWA, K.; SATO, K. Iron boron based powders sprayed by high velocity spray processes. **Surface & Coatings Technology**, v. 240, p. 373–379, 2014.

PADHY, M.K.; SAINI, R.P. Effect of size and concentration of silt particles on erosion of Pelton turbine buckets. **Energy**, v. 34, p. 1477-1483, 2009.

PATNAIK, A. et al. Solid particle erosion wear characteristics of fiber and particulate filled polymer composites: A review. **Wear**, v. 268, n.1-2, p. 249–263, jan. 2010.

PAWLOWSKI, L. **The Science and Engineering of Thermal Spray Coatings.** 2.ed. London: John Wiley & Sons, 2008.

PHAM, D.T. An introduction to Artificial Neural Networks. In: **NEURAL Networks for**. [S.l.]: [s.n.], 1995.

PICAS, J. A. et al. Influence of HVOF spraying parameters on the corrosion resistance of WC–CoCr coatings in strong acidic environment. **Surface & Coatings Technology**, v. 225, p. 47–57, 2013.

PONTES, F. J. **Predição da vida de ferramentas e da rugosidade da peça por Redes Neurais RBF projetadas com uso da Metodologia de Projeto de Experimentos**. 2006. Dissertação (Mestrado em Engenharia de Produção).— Programa de Pós-Graduação em Engenharia de Produção, Universidade Federal de Itajubá, Itajubá – MG, 2006.

POWAR, A., DATE, P., Modeling of microstructure and mechanical properties of heat treated components by using Artificial Neural Network. **Materials Science & Engineering**, v. 628, p. 89–97, 2015.

RABINOWICZ, E. **Friction and Wear of Materials**. 2.ed. New York: John Wiley and Son, 1995.

RAJASEKARAN, B. et al. Thick tool steel coatings using HVOF spraying for wear resistance applications. **Surface & Coatings Technology**, v. 205, p. 2449–2454, 2010.

RAJENDRAN, V. et al. Effect of high temperature on the surface morphology and mechanical properties of nanostructured Al₂O₃–ZrO₂/SiO₂ thermal barrier coatings. **Surface & Coatings Technology**, v. 262, p. 154–165, 2015.

RAMESH, C.S.; KUMAR, R. S. Mathematical and Neural Network models for prediction of wear of mild steel coated with Inconel 718 – A Comparative Study. **International Journal of Scientific and Research Publications**, v. 2, n. 7, 2012.

REYES, M., A. et al. Tribocorrosion behavior of cemented carbide coatings obtained by high velocity oxygen fuel spraying. **International Journal of Surface Science and Engineering**, v. 9, p. 561-573, 2015.

RODRÍGUEZ, D. M. **Correlación de la microestructura con la tenacidad a la fractura em recubrimientos de barrera térmica (TBC) para aplicaciones en turbinas a gás.** Medellín – Antioquia, 2013. Disertación (maestría en Ingeniería-Materiales y Procesos) – El departamento de estudios de Posgrado en Ingeniería de Materiales, Universidad Nacional de Colombia, Medellín, Colombia, 2013.

ROSENBLATT. The perceptron: A probabilistic model for information storage and organization in the brain. **Psychological Review**, v. 65, p.386- 408, 1958.

RUMELHART, D. E.; HILTON, G. E.; WILLIAMS, R. J. Learning Internal Representations by Error Propagation, Parallel data processing. In: RUMELHART, D. E.; McClelland, J. L. (org.) **Basic mechanisms**. Cambridge, MA: MIT Press, 1986.v.1, cap. 8.

SAAEDI, J. et al. Effects of HVOF Process Parameters on the Properties of Ni-Cr Coatings. **Journal of Thermal Spray Technology**, v. 19, n.3, p.521-530, mar, 2010.

SAEIDI, S. **Microstructure, Oxidation & Mechanical Properties of As-sprayed and Annealed HVOF & VPS CoNiCrAlY Coatings.** Thesis (Doctor of Philosophy) - University of Nottingham, EUA, 2010.

SAINT GOBAIN. **Coating solutions, processos e materiais para aspersão térmica.** 2015. Disponível em: <www.coatingsolutions.saint-gobain.com>. Acesso em: 26 nov. 2015.

SHARMA, A.; KUMAR, A.; TYAGI, R. Erosive wear analysis of medium carbon dual phase steel under dry ambient condition. **Wear**, v. 334-335, p.91-98, jul. 2015.

SHI, K., WANG, C.; GROSS C.; CHUN, Y. W. Reversing the inverse hardness–toughness trend using W/VC multilayer coatings. **Surface & Coatings Technology**, v. 284, p.80-84, 2015.

SHIFEI, D. et al. Evolutionary artificial neural networks: a review. **Artificial Intelligence Review**, v. 39, n. 3, p.251-260, 2013.

SIDDHARTHA, B. A modified approach for better prediction of erosion wear of materials: Redefining the paradigms. **Materials and Design**, v. 47, p. 395–407, 2013.

SINGH, H. et al. Use of plasma spray technology for deposition of high temperature oxidation/corrosion resistant coatings- a review. **Materials and Corrosion**, v. 58, n. 2, p. 92-102, 2007.

SLOWIK A., Application of an Adaptive Differential Evolution Algorithm With Multiple Trial Vectors to Artificial Neural Network Training. **IEEE Transactions on Industrial Electronics**, v. 58, n. 8, p. 3160-3167, 2011.

SOLLICH, P. et al. Extensive parallel processing on scale-free networks. **Physical Review Letters**, v.113, n. 23, 2014.

SOUSA, J. C. S. **Metodologia para Otimização de Estrutura de Produtos da Linha Branca via Simulação Numérica Aliada ao Projeto de Experimentos**. ,2012. Dissertação (Mestrado em Engenharia Mecânica). —Programa de Pós-graduação em Engenharia Mecânica, Universidade Federal do Paraná, Curitiba, PR, 2012.

SOVEJA A. et al. Remelting of Flame Spraying PEEK Coating Using Lasers. **Journal of Thermal Spray Technology**, v. 19, p.439-447, 2010.

SPECHT, D. F. A general regression neural network. **IEEE Transactions on Neural Networks**, v. 2, n.6, p. 568-576, 1991.

SUN, Y. et al. Modeling the correlation between microstructure and the properties of the Ti-6Al-4V alloy based on an artificial neural network. **Materials Science and Engineering**, v. 528, p. 8757– 8764, 2011.

SUNDARARAJAN, G.; MANISH R. Solid particle erosion behaviour of metallic materials at room and elevated temperatures. **Tribology international**, v. 30. n. 5, p. 339 -359, 1997.

SUNDARARAJAN, G.; ROY, M.; VENLCATARAMAN, B. Erosion eficiência new erosion micromechanism. **Wear**, v. 140, n.2, p. 369-381, nov. 1990.

SURESH, A.; HARSHA, A.P.; GHOSH, M.K., Solid particle erosion studies on polyphenylene sulfide composites and prediction on erosion data using artificiaisneurais networks. **Wear**, v. 266, n.1-2, p.184–193, jan. 2009.

SUSKI, C. A. **Estudo do efeito de tratamentos e revestimentos superficiais na vida de ferramentas de conformação mecânica à frio**. Florianópolis - SC, 2004. Dissertação (Mestrado em Engenharia de Materiais) - Programa de Pós-Graduação em Engenharia Mecânica, Universidade Federal de Santa Catarina Florianópolis – SC, 2004.

SZYMAŃSKI, K.; HERNAS, A.; MOSKAL, G.; MYALSKA, H. Thermally sprayed coatings resistant to erosion and corrosion for power plant boilers: A review. **Surface & Coatings Technology**, v. 268, p. 153–164, 2015.

THERMAL SPRAY SOLUTIONS. **Esquema da camada aspergida sobre o**

substrato. 2015. Disponível em:<www.thermalsprayusa.com>. Acesso em: 2 fev. 2016.

THIRUVIKRAMAN, C.; BALASUBRAMANIAN, V.; SRIDHAR, K. Optimizing HVOF Spray Parameters to Maximize Bonding Strength of WC-CrC-Ni Coatings on AISI 304L Stainless Steel. **Journal of Thermal Spray Technology**, v. 23, n.5, p.860-875, mar. 2014.

TILLMANN, W. et al. Influence of the Spray Angle on the Properties of HVOF Sprayed WC-Co Coatings Using (210 + 2 μ m) Fine Powders. **Journal of Thermal Spray Technology**, v. 22, n.2, p. 1-12, mar. 2013.

TIPO de pistola hvof em operação. Disponível em:<ogramac.com.br/html/empresa.htm>. Acesso em: 25 fev. 2016.

TIPO de pistola HVOF. Disponível: <www.praxairsurfacetechologies.com/thermal-spr>. Acesso em: 25 fev. 2016.

UNIVERSIDADE FEDERAL DO PARANÁ. Pistola de aspersão térmica a chama utilizando arame. Disponível em:<<http://demec.ufpr.br/laboratorios/labats>>. Acesso em: 2 fev. 2016.

VEERESH, G.B.K.; PRAMOD, R. Artificial Neural Networks for Predicting the Tribological Behaviour of Al7075-SiC Metal Matrix Composites. **International Journal of Material Science & Engineering**, v.10, n. 1, p. 59-91, 2014.

VEINTHAL, R. et al. Abrasive impact wear and surface fatigue wear behaviour of Fe-Cr-C PTA overlays. **Wear**, v. 301, n.1-2, p. 102-108, abr./mai. 2013.

VERA, M. C.A. et al. Solid particle erosion of a coating composed of clay in a polystyrene matrix. **Wear**, v.328, p.132-139, abr. 2015.

WANG, Q. et al. Wear and corrosion performance of WC-10Co4Cr coatings deposited by different HVOF and HVOF spraying processes. **Surface & Coatings Technology**, v. 218, p. 127–136, 2013.

WOOD, G. et al. Welding processes for wear resistant overlays. **Journal of Manufacturing Processes**, v. 16, p. 4-25, 2014.

YILDIRAN, Y. et al. Effect of Particle Impact Angle, Eroding Particle Size and Acceleration Pressure on the Solid Particle Erosion Behavior of 3003 Aluminum Alloy, ACTA PHYSICA polonica. **Proceedings of the 3rd International Congress**, Antalya, Turkey, v. 125, p. 523-525, 2014.

YILMAZ I; AND KAYNAR O. Multiple regression, ANN (RBF, MLP) and ANFIS models for prediction of swell potential of clayey soils. **Expert Systems with Applications**, v. 38, p. 5958-5966, 2011.

YUE, T. M., ZANG, H. Microstructure and wear resistance of compositionally graded Ti-Si Laser-clad coating. **Materials Research Innovations**, v. 19, n. 9, p. 9 - 13, 2015.

ZEILMANN, R.P. **Análise do comportamento de ferramentas de metal duro K10 revestidas com nitreto de titânio pelo processo físico da deposição por vapor no ensaio de torneamento**. 1997. Dissertação (Mestrado em Engenharia Mecânica) – Programa de Pós-Graduação em Engenharia Mecânica, Universidade Federal de Santa Catarina, Florianópolis – SC, 1997.

ZHANG, C. et al. Wear behavior of HVOF-sprayed Fe-based amorphous coatings. **Intermetallics**, v.29, p. 80 - 85, 2012.

ZHANG, H. et al. Predicting the fracture toughness of PNCs: A stochastic approach based on ANN and ANFIS. **Computational Materials Science**, v. 102, p. 304–313, 2015.

ZHANG, S.; ZHANG, X. Toughness evaluation of hard coatings and thin films. **Thin Solid Films**, v. 520, p. 2375–2389, 2012.

ZHAO, L. et al. Lugscheider, E. Influence of spray parameters on the particle in-flight properties and the properties of hvof coatings of wc-CoCr. **Wear**, v.185, p. 160-165, 2004.

ZHAO, Y. et al. Modeling the correlation between microstructure and the properties of the Ti–6Al–4V alloy based on an artificial neural network. **Materials Science and Engineering**, v. 528, p.8757– 8764, 2011.

ZHONG, Z.; CLOUSER, S. J., Nickel–tungsten alloy brush plating for engineering applications. **Surface & Coatings Technology**, v. 240, p. 380–386, 2014.

ZOIS, D. et al. Simplified Model for Description of HVOF NiCr Coating Properties Through Experimental Design and Diagnostic Measurements. **Journal of Thermal Spray Technology**, v. 22, n.2, p. 299-315, mar. 2013.

ZWASS, V. Neural Network. **Journal of Management Information Systems**, v. 32, p.1-3, 2015.