

**Universidades Lusíada**

Reis, Rui Daniel Botelho

**Mapa de Kohonen adaptado aplicado à monitorização do desgaste de ferramentas de corte**

<http://hdl.handle.net/11067/4497>

**Metadados**

**Data de Publicação**

2018

**Resumo**

A monitorização das condições de corte é parte fundamental da maquinação e de outros processos de manufatura, existindo peças que se encontram em constante utilização, o que provoca o seu desgaste, tendo estas, de ser substituídas. Tanto nos processos de torneamento como nos de fresagem, um elevado nível de desgaste das ferramentas de corte condiciona uma operação adequada, utilizando-se normalmente a combinação de múltiplos sensores, em conjunto com um método de classificação apropriado, na mon...

Condition monitoring is a fundamental part of machining as well as other manufacturing processes where generally there are parts that wear out and have to be replaced. In turning or milling tool wear level is fundamental for proper machine operation and is often accessed through the use of multiple sensors combined with a reasoning method. The unique modeling capabilities of artificial neural networks in the presence of noisy information make them best candidates for condition monitoring. This p...

**Palavras Chave**

Inteligência artificial, Ferramentas de corte

**Tipo**

masterThesis

**Revisão de Pares**

no

**Coleções**

[ULF-FET] Dissertações

Esta página foi gerada automaticamente em 2024-04-19T21:11:16Z com informação proveniente do Repositório



**UNIVERSIDADE LUSÍADA – NORTE**  
*Campus, Vila Nova de Famalicão*

**Mapa de Kohonen Adaptado Aplicado à Monitorização  
do Desgaste de Ferramentas de Corte**

**Rui Daniel Botelho Reis**

Dissertação para obtenção do Grau de Mestre em  
Engenharia Electrónica e Informática

Faculdade de Engenharias e Tecnologias  
Fevereiro de 2018



**UNIVERSIDADE LUSÍADA – NORTE**  
*Campus, Vila Nova de Famalicão*

**Mapa de Kohonen Adaptado Aplicado à Monitorização  
do Desgaste de Ferramentas de Corte**

Autor:

**Rui Daniel Botelho Reis**

Orientador:

**Prof. Doutor Rui Gabriel Silva**

Dissertação para obtenção do Grau de Mestre em  
Engenharia Electrónica e Informática

Faculdade de Engenharias e Tecnologias  
Fevereiro de 2018

# Agradecimentos

Em primeiro plano, agradeço ao Professor Rui Silva pela cuidadosa orientação e atenção dada a este trabalho, em particular pela sua forma de direcionar e questionar o mesmo. Agradeço a sua amizade e consideração.

Da mesma forma, agradeço ao Professor Vítor Pereira pela ajuda prestada nesta dissertação, como no artigo apresentado em conferência Internacional do IEEE sobre este trabalho.

À Universidade Lusíada – Norte *Campus*, Vila Nova de Famalicão e aos seus funcionários.

Um agradecimento especial ao Bruno Ferreira com quem partilhei em simultâneo esta etapa académica e ao Pedro Regueiras, pelo vosso apoio e boa disposição.

Aos meus amigos que desde sempre estiveram ao meu lado.

À minha família em especial aos meus pais, à minha irmã, ao meu cunhado, ao meu sobrinho e aos meus avós por todos os esforços efetuados ao longo destes anos, por acreditarem sempre em mim e naquilo que faço e por todos os ensinamentos de vida. Espero poder retribuir e compensar todo o carinho, apoio e dedicação que, constantemente, me oferecem. A eles, dedico todo este trabalho.

# Resumo

A monitorização das condições de corte é parte fundamental da maquinação e de outros processos de manufatura, existindo peças que se encontram em constante utilização, o que provoca o seu desgaste, tendo estas, de ser substituídas. Tanto nos processos de torneamento como nos de fresagem, um elevado nível de desgaste das ferramentas de corte condiciona uma operação adequada, utilizando-se normalmente a combinação de múltiplos sensores, em conjunto com um método de classificação apropriado, na monitorização desse desgaste. As capacidades únicas de modelação na presença de informação com ruído fazem das redes neuronais artificiais candidatas apropriadas para a monitorização dessas condições. Esta dissertação introduz melhorias ao algoritmo *self-organizing map*, apresentando uma modificação do algoritmo, por forma a controlar a eficácia da memória, possibilitando que os neurónios com aprendizagem mais reduzida tenham também eles possibilidade de reter conhecimento. Posteriormente foram executados testes à capacidade de modelação da rede neuronal, de modo a determinar a influência do tempo, como um dos atributos, no desempenho da classificação. Os resultados obtidos apresentam uma melhoria significativa na classificação do desgaste da ferramenta de corte, aquando da utilização do tempo como atributo de classificação, como também um ganho do desempenho através das alterações do controlo do ritmo de aprendizagem da rede neuronal implementadas no algoritmo. As modificações no algoritmo de aprendizagem sugerem que a aprendizagem contínua é possível, pois evitam o *overfitting* da rede com dados anteriormente analisados, possibilitando, assim, que novas relações possam ser estabelecidas, sem que as relações anteriormente estabelecidas sejam desprezadas.

**Palavras-Chave:** Inteligência Artificial, Self-Organizing Maps, Condições de monitorização, Desgaste de ferramentas.

# Abstract

*Condition monitoring is a fundamental part of machining as well as other manufacturing processes where generally there are parts that wear out and have to be replaced. In turning or milling tool wear level is fundamental for proper machine operation and is often accessed through the use of multiple sensors combined with a reasoning method. The unique modeling capabilities of artificial neural networks in the presence of noisy information make them best candidates for condition monitoring. This paper presents enhancements to the self-organizing map neural network where a modified learning algorithm is used to control the effectiveness of memory usage through the reduction of the learning rate in raw memory areas. Further modeling ability tests of the neural network were produced to test the influence of time as a feature in classification performance. Results show significant improvements in tool wear classification through the use of time as a feature as well as gained performance with memory learning rate control. The modified learning algorithm suggest that online continuous learning is possible by avoiding over fitting from previously seen data suggesting therefore the accommodation of new data patterns without forgetting previous ones.*

**Keywords**— *Artificial Intelligence; Tool Wear; Condition Monitoring; Self-Organizing Map.*

# Índice

AGRADECIMENTOS.....	II
RESUMO .....	III
ABSTRACT.....	IV
ÍNDICE .....	V
LISTA DE FIGURAS .....	VI
LISTA DE TABELAS .....	VII
LISTA DE SIGLAS .....	VIII
1. INTRODUÇÃO .....	1
OBJETIVOS .....	2
METODOLOGIA .....	3
ESTRUTURA .....	3
2. REVISÃO BIBLIOGRÁFICA .....	4
SELF-ORGANIZING MAP .....	5
SISTEMAS DE MONITORIZAÇÃO DO PROCESSO DE CORTE .....	8
EXTRAÇÃO E SELEÇÃO DE ATRIBUTOS .....	9
3. TRABALHO EXPERIMENTAL E DESENVOLVIMENTO .....	12
APPARATUS.....	13
PROCEDIMENTO EXPERIMENTAL.....	14
EXTRAÇÃO DE ATRIBUTOS .....	15
ALGORITMOS DE APRENDIZAGEM .....	17
ALGORITMO DESENVOLVIDO .....	19
4. RESULTADOS E DISCUSSÃO.....	20
5. CONCLUSÃO E TRABALHOS FUTUROS.....	25
REFERÊNCIAS .....	27
APÊNDICES.....	34
APÊNDICE 1 – ARTIGO PUBLICADO E APRESENTADO NA CONFERÊNCIA INTERNACIONAL IEEE, ETFA’2017 (EMERGING TECHNOLOGIES AND FACTORY AUTOMATION), EM LIMASSOL - CHIPRE. .....	35
APÊNDICE 2 –FLUXOGRAMA DO ALGORITMO DESENVOLVIDO. ....	42
APÊNDICE 2.1 –FLUXOGRAMA DO MÉTODO DE CÁLCULO DA DISTÂNCIA EUCLIDIANA.....	43
APÊNDICE 2.2 –FLUXOGRAMA DO MÉTODO DE ATUALIZAÇÃO DOS PESOS .....	45

# Lista de Figuras

Figura 1 - Esquema representativo dos Mapas de Kohonen. Adaptado de Carrasco Kind & Brunner, 2014.....	6
Figura 2 – Pseudocódigo .....	8
Figura 3 - Apparatus Experimental .....	13
Figura 4 -Evolução do desgaste do flanco para diferentes pastilhas de corte. ....	15
Figura 5 - Atributo da amostra - Força tangencial em relação ao tempo de corte.....	16
Figura 6 - Atributos Analisados. ....	17
Figura 7 - Classificação de mapa de saída de amostra sem aprendizagem adaptativa - símbolos maiores representam valores de desgaste superiores .....	21
Figura 8 - Teste da classificação da amostra em relação aos valores medidos - Execução SOM direta sem utilização do tempo como atributo.....	21
Figura 9 - Teste a classificação da amostra em relação aos valores medidos - Execução SOM direta com utilização do atributo tempo. ....	22
Figura 10 - Classificação de mapa de saída de amostra com aprendizagem adaptativa - símbolos maiores representam valores de desgaste superiores. ....	22
Figura 11 - Teste da classificação da amostra em relação aos valores medidos - Execução SOM adaptativo sem utilização do tempo como atributo. ....	23
Figura 12 - Teste da classificação da amostra em relação aos valores medidos - Execução SOM adaptativo com utilização do atributo tempo. ....	23

## **Lista de Tabelas**

Tabela 1 - Instrumentação .....	14
Tabela 2 - Erro Relativo Percentual de classificação .....	24

## Lista de Siglas

DM	Data Mining
LVQ	Linear Vector Quantization
RNA	Rede Neuronal Artificial
SMPC	Sistema de Monitorização do Processo de Corte
SOM	Self-Organizing Map

# 1. Introdução

Com os mais recentes avanços das tecnologias de informação e vastos incrementos de fontes de dados globais, a informação tem sido gerada a uma escala sem precedentes. Esta geração maciça de dados, proporciona a descoberta de novos valores, elevando os desafios que advém da gestão e análise dos mesmos, dando ênfase a um novo conceito, comumente referido como *big data*.

*Data mining* (DM) é considerada a chave fundamental na análise do *big data*, consistindo na aplicação de técnicas de aprendizagem automática adaptadas a sistemas de gestão de dados, que permitem analisar e explorar base de dados com um grande número de instâncias, sendo uma inovação tecnológica que tem grande potencial para suporte à investigação científica e empresarial (Folorunso & Ogunde, 2005), para tal, estas aplicações utilizam modelos estatísticos complexos e algoritmos sofisticados, possibilitando deste modo a descoberta de padrões significativos e informações úteis nas mesmas. A análise pode ser de dois tipos: análise descritiva e análise de previsão. A análise descritiva transforma a coleção de dados em informação significativa para afins de relatórios, monitorização e visualização, enquanto a análise de previsão permite fazer previsões futuras sobre tendências e comportamentos, usadas como suporte de decisões. Através da utilização de DM é possível executar tarefas, como tais: previsão, classificação, deteção de relações, modelação explícita, *clustering*, deteção de desvio, sendo que as técnicas de DM mais utilizadas são: Redes Neurais; Árvores de Decisão; Algoritmos Genéticos; Sistemas Periciais; e Métodos Regressivos (Folorunso & Ogunde, 2005).

A maquinação é um subprocesso do processo de manufatura na qual uma ferramenta de corte é utilizada para remover material de um bloco de metal, de modo a obter a geometria desejada. A maioria dos componentes utilizados na engenharia como por exemplo engrenagens, parafusos, porcas, entre outros, são produzidos através do processo de

maquinação. Os principais processos de maquinação convencional são: torneamento, fresagem, furação, extrusão, laminagem e forjamento (Stephenson & Agapiou, 2016). O desgaste de ferramentas é um problema crítico nos processos maquinação uma vez que faz aumentar os custos de produção. Este problema pode causar imperfeições de acabamento na superfície ou ainda influenciar as tolerâncias das peças diminuindo desta forma a qualidade do produto. Deste modo é necessária uma forma que possa prever o desgaste das ferramentas de corte e a vida útil das mesmas resultando uma otimização dos parâmetros de corte das máquinas por forma a reduzir os custos de produção e melhorar a qualidade do produto. Para tal é comum a utilização de sistemas de monitorização do processo de corte (SMPC). Estes sistemas têm a capacidade de obter dados de múltiplos sensores implementados nas máquinas de corte e relacionar os mesmos com o valor do desgaste das ferramentas de corte. Apesar dos sistemas de monitorização já terem sido extensivamente estudados, algumas limitações persistem no que diz respeito à sua performance durante condições reais de manufatura. A utilização de sistemas de aprendizagem automática neste tipo de monitorização é uma mais-valia uma vez que permite analisar o elevado número de dados obtidos pelos SMPC e fazer previsões sobre o estado das máquinas ou ferramentas.

Algumas das técnicas de DM permitem ainda que a previsão seja efetuada em contínuo, uma vez que estas técnicas de aprendizagem automática estão continuamente a aprender novas relações, tendo ainda capacidade de lidar com o ruído presente nos sinais obtidos em condições reais de manufatura.

## **Objetivos**

Apesar dos sistemas de monitorização do processo de corte já terem vindo a ser estudados melhorias à sua performance podem ser efetuadas, tanto em relação aos métodos de DM utilizados como em relação aos atributos que melhor representam o desgaste das ferramentas de corte. Esta dissertação introduz melhorias ao algoritmo *self-organizing map* (SOM), apresentando uma modificação do algoritmo base, por forma a controlar a eficácia da memória, possibilitando que os neurónios com aprendizagem mais reduzida tenham também eles possibilidade de aprender e estabelecer novas relações. É também proposto a verificação da viabilidade de utilizar o atributo de tempo de corte como um dos atributos no desempenho da classificação do desgaste de ferramenta de corte. A performance do algoritmo é posteriormente testada com dados recolhidos de experiências e é aferida a validade da sua pertinência.

## **Metodologia**

De modo a cumprir os objetivos proposto, o trabalho desenvolvido foi subdividido em diversas etapas. Inicialmente foi realizada uma pesquisa da bibliografia existente para verificar o estado da arte do SOM e sobre outras matérias relevantes para a dissertação, tais como inteligência artificial e os SMPC. Posteriormente foi desenvolvido o algoritmo do SOM em que foram implementadas as alterações ao nível da aprendizagem da rede neuronal artificial (RNA). Sendo que ao mesmo tempo foi efetuada a aquisição de dados do SMPC para testar o comportamento do SOM, aquando da introdução dos objetivos propostos. Com todos os dados necessários obtidos, foram realizados testes para verificar o desempenho da classificação do desgaste da ferramenta. Devido à existência de dados sobre o tempo de corte foi ainda acrescentado um objetivo à dissertação, que se prendia como a utilização deste atributo como um dos atributos para classificação do desgaste, e como este influenciaria a classificação.

## **Estrutura**

A dissertação encontra-se estruturada em cinco capítulos. No primeiro capítulo são apresentados o âmbito de estudo e os objetivos propostos. O segundo capítulo aborda uma reflexão ao estado da arte, tanto do SOM, como dos SMPC. O terceiro capítulo apresenta a metodologia implementada no trabalho experimental, desde a obtenção de dados do SMPC para análise até ao algoritmo desenvolvido para validação das propostas desta dissertação. No quarto capítulo faz-se uma exposição dos resultados obtidos e uma comparação do desempenho de classificação do desgaste das ferramentas de corte entre as diferentes abordagens testadas. O quinto capítulo aborda considerações finais que foram retiradas dos resultados de classificação obtidos no capítulo anterior e como estas podem contribuir para a investigação científica. São ainda referidas algumas das limitações verificadas durante a realização deste estudo. Em apêndice encontra-se o algoritmo desenvolvido (Apêndice 2Apêndice 2Apêndice 2) bem como o artigo apresentado em conferência internacional sobre este trabalho (Apêndice 1).

## 2. Revisão Bibliográfica

A maioria dos sistemas de manufatura é composto por peças que estão sujeitas a desgaste, existindo posteriormente a necessidade de as mesmas serem substituídas. Uma das operações de manufatura que maior contributo traz para a transformação dos materiais é aquela em que a peça é moldada através da remoção de material, tal como operações de torneamento e fresagem. A monitorização das condições de corte deste tipo de operações tem vindo a evoluir ao longo dos últimos anos. Contudo, existe ainda muito por explorar até que se obtenham sistemas que não requeiram intervenção humana e com uma performance otimizada (Ambhore, Kamble, Chinchankar, & Wayal, 2015). Estes processos complexos estão condicionados por um número significativo de variáveis como, por exemplo, os parâmetros de corte, o tipo de corte, ou as características da máquina de corte, os quais contribuem para a dificuldade na determinação do nível de desgaste das ferramentas de corte, limitando a eficiência das operações e substituição (Ambhore et al., 2015; Siddhpura & Paurobally, 2013).

Diferentes abordagens têm sido aplicadas para a monitorização do desgaste de ferramentas, sendo que todas elas tem vantagens e limitações, de que são exemplo as redes neuronais (Dimla & Lister, 2000), os sistemas periciais (Silva, Reuben, Baker, & Wilcox, 1998), os algoritmos genéricos, entre outros. Tendo em conta o ruído e as variações das condições existentes durante o processo de corte, uma abordagem preferencial para a monitorização é a utilização de diferentes sensores e atributos, sempre com o objetivo de serem obtidos sistemas com melhor desempenho (M. S. H. Bhuiyan, Choudhury, & Dahari, 2014; Duro, Padget, Bowen, Kim, & Nassehi, 2016; Prasad, Prabha, & Kumar, 2017; Segreto, Simeone, & Teti, 2013; Shao et al., 2013; Silva et al., 1998; Wang, Guo, & Yang, 2013). Para modelar a complexidade do processo de corte é comum a utilização de técnicas

de inteligência artificial, como as redes neuronais (Ambhore et al., 2015; Shahin, 2014; Siddhpura & Paurobally, 2013). Estas superam os modelos diretos através de modelação matemática, dando assim uma abstração não linear do processo de desgaste (Pérez-Canales, Álvarez-Ramírez, Jáuregui-Correa, Vela-Martínez, & Herrera-Ruiz, 2011).

O SOM tem tido uma grande sucesso ao nível das suas aplicações (Kohonen, 2013; Olszewski, 2014; Sarlin, 2013; Silva, 2010) e tem apresentado uma melhor performance quando comparado com outras RNA, sendo que a sua aprendizagem não é supervisionada, evitando-se assim a aprendizagem de atributos que com ela não estão relacionados, produzindo assim uma topologia de saída que coloca na mesma área classificações semelhantes (Kohonen, 1990). A aprendizagem não supervisionada é particularmente utilizada em ambientes industriais visto não ser viável uma classificação prévia de todos os dados objeto de análise, os quais requerem tempo, são de difícil aplicação, e dispendiosos (Potočnik & Govekar, 2017). É necessário reconhecer que a aprendizagem não supervisionada é adequada para agrupar dados com base em informações intrínsecas, enquanto que uma aprendizagem supervisionada requer que para todos os dados exista a indicação da classificação forçando, desta forma, o estabelecimento de relações entre os atributos e as classificações predeterminadas, dando origem a uma degradação na performance no processo de modelação, o que conseqüentemente leva a uma menor capacidade de adaptação (Yuwono et al., 2015).

### **Self-Organizing Map**

O SOM é um modelo de RNA (Kohonen, 1998) que tem como principais características a quantificação vetorial, o uso de uma aprendizagem competitiva e não supervisionada. Desenvolvida pelo Professor Teuvo Kohonen em 1982 pode ser também designada por *Kohonen Maps* (Kohonen, 1982). É um algoritmo que faz o mapeamento ordenado de uma distribuição de elevada dimensão, numa matriz de baixa dimensão, convertendo estatisticamente relações complexas e não lineares, em relações geométricas representadas em baixas dimensões, possibilitando desta forma a interpretação dos dados de elevada dimensão (Kohonen, 1998). Como faz utilização de uma aprendizagem não supervisionada significa que não necessita que haja uma relação pré-definida entre as entradas e a saída do sistema. Também tem como característica diferenciadora de outras RNA a utilização de uma função designada por função vizinhança que permite que a topologia do mapa seja preservada.

O SOM tem sido aplicado como ferramenta de classificação nas mais variadas áreas das quais podemos destacar reconhecimento da fala (Leinonen, Hiltunen, Torkkola, & Kangas, 1993); processamento de imagem (J.-H. Chen, Su, Cao, Hsu, & Lu, 2017; Manikopoulos, 1993); diagnóstico médico (Aoki, Mashimo, & Nakamura, 2015; Farnood Ahmadi, 2016; Skupin, Biberstine, & Börner, 2013; Wandeto, Nyongesa, Rémond, & Dresp-Langley, 2017); análise financeira (G Deboeck, 1998; Guido Deboeck & Kohonen, 1998; Kiviluoto & Bergius, 1998; Schmitt & Deboeck, 1998; Tulkki, 1998); área ambiental, animal e alimentar (I.-T. Chen, Chang, & Chang, 2017; Nanda, Sahoo, & Chatterjee, 2017; Tsai, Huang, Cheng, Shao, & Chang, 2017); astronomia (Bazarghan, 2012); meteorologia (Nigro, Cassano, Wille, Bromwich, & Lazzara, 2017). O artigo de Teuvo Kohonen, Oja, Simula, Visa, & Kangas (1996) fornece avaliações parciais de algumas aplicações que podem beneficiar do SOM.

O SOM é composto tipicamente por duas camadas, o vetor de entrada e o mapa de saída, sendo uma de alta e outra de baixa dimensão, respetivamente. Estas camadas são completamente conectadas como representado na Figura 1.

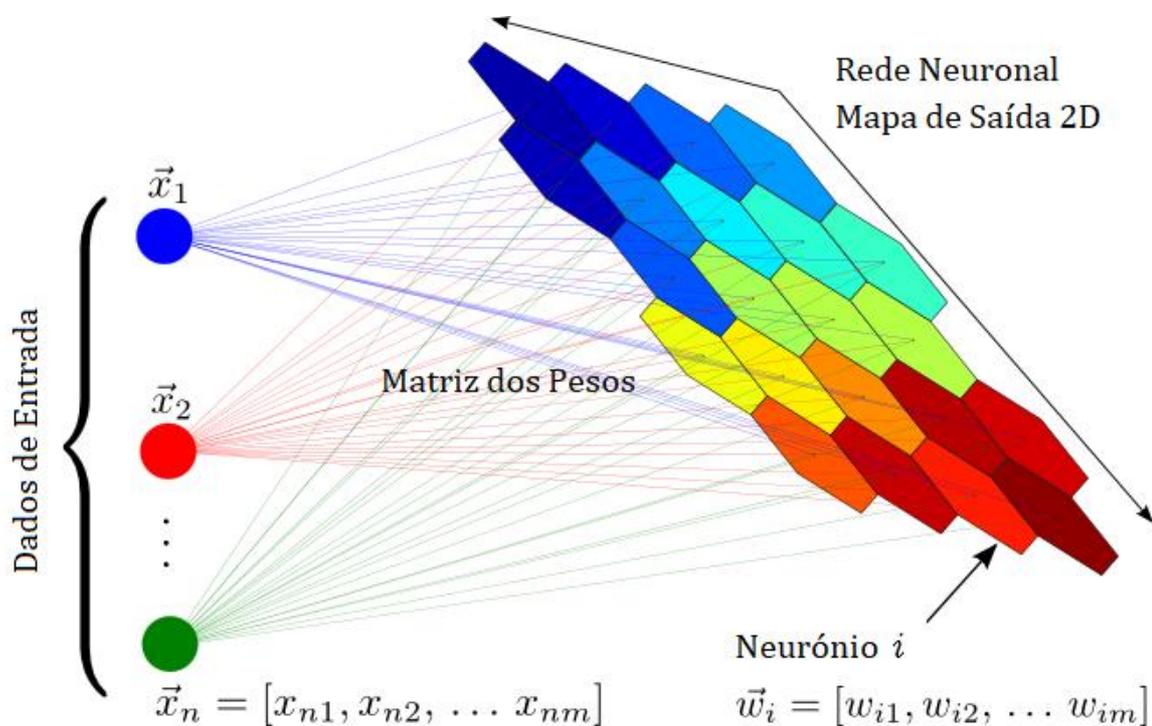


Figura 1 - Esquema representativo dos Mapas de Kohonen. Adaptado de Carrasco Kind & Brunner, 2014

No mapa de saída nenhum dos neurónios está conectado com outros, independentemente das suas posições relativas. Para cada neurónio do mapa de saída é efetuado o cálculo da distância Euclidiana ao vetor de entrada. O neurónio que obtiver o menor valor de distância é considerado de neurónio vencedor, sendo desta forma obtido o neurónio da camada SOM que melhor representa o valor do vetor de entrada, podendo ser considerado como o centroide da vizinhança topológica (Cai, Yin, & Man, 2013). Durante o treino o peso do neurónio da camada SOM com a menor distância é ajustado para que este represente ainda de forma mais precisa o valor do vetor de entrada (DeSieno, 1988; Kohonen, 1990). Os valores dos pesos dos neurónios vizinhos do neurónio vencedor são também atualizados para que estes também representem melhor o valor do vetor de entrada, mas numa menor proporção, ordenando topologicamente o mapa de saída.

O SOM tem vindo a ser amplamente utilizado em monitorização integrada e classificação de operações, apresentando resultados viáveis (Kohonen, 2013; Olszewski, 2014; Silva, Baker, Wilcox, & Reuben, 2000). O algoritmo geralmente executa uma quantização do vetor de acordo com a Equação 1, onde  $w_o^i$  são os pesos de neurónios de entrada,  $i$ , e neurónios de saída,  $o$ . Os vetores de entrada,  $x$ , são apresentados a cada iteração,  $t$ , e os pesos são atualizados através da função de gradiente descendente que faz com que as saídas se aproximem dos padrões de entrada.

$$w_o^i(t + 1) += \lambda(t)\varphi_{(c,o)}(t)[x_i(t) - w_o^i(t)] \quad (1)$$

O SOM utiliza esta função semelhante ao algoritmo designado por Linear Vector Quantization (LVQ) e adiciona uma preservação da topologia através de uma função vizinhança,  $\varphi_{(c,o)}$ . Esta função inclui uma função de ritmo de aprendizagem que vai diminuindo a cada iteração,  $\lambda(t)$ , sendo que ainda adiciona um fator de vizinhança que diminui sempre que a distância ao neurónio vencedor vai aumentando, de acordo com a Equação 2.

$$\varphi_{(c,o)}(t) = e^{-\frac{\|N_c - N_o\|}{2\sigma}} \quad (2)$$

O algoritmo de treino segue normalmente etapas padrão, dadas pelo seguinte pseudocódigo (Figura 2).

Os pesos da rede neuronal são inicializados com valores aleatórios entre 0 e 1. Quando um vetor da base de dados é apresentada à rede é calculada a distância euclidiana para todos os neurónios da rede. O neurónio que for mais similar com os valores do vetor de entrada é considerado como neurónio vencedor. O peso deste neurónio como o peso dos neurónios que se encontram na sua vizinhança definida pela Equação 2 são posteriormente atualizados para que estes representem melhor o vetor de entrada, através da aplicação da Equação 1. A magnitude da alteração vai sendo cada vez menor estando esta dependente do número de iterações e da distância a que os neurónios se encontram do neurónio vencedor.

```
initialize weights to random values
for each epoch
    select random feature vector,  $x_i$ 
    determine the winner neuron,  $N_o$ 
    update weights in the neighborhood of  $N_o$  according to (1)
end select
end for
```

Figura 2 – Pseudocódigo

## **Sistemas de Monitorização do Processo de Corte**

Sensores, atributos e tomadas de decisões têm vindo a ser extensivamente exploradas, dando origem a um vasto uso de SMPC (Dimla Snr., 2000; Duro et al., 2016; Girardin, Rémond, & Rigal, 2010). A maioria dos sistemas apresentam limitações que devem ser exploradas e melhoradas tendo em vista a superação das mesmas. As limitações estão relacionadas com o facto de a sua performance ser elevada quando são executadas em condições ideais como por exemplo ambientes controlados onde o nível de ruído é muito baixo e onde não existe normalmente uma análise sensível no que toca às condições de corte ou variabilidade do material. Este trabalho aborda maioritariamente algumas melhorias em relação à classificação através do melhoramento do desempenho da modelação da RNA escolhida, para que se consiga lidar com dados recolhidos em condições reais de maquinação, visto serem dados que normalmente apresentam um nível considerável de ruído. As melhorias do desempenho são alcançadas com uma abordagem de aprendizagem adaptada, bem como através da utilização do tempo como atributo de classificação, um atributo óbvio para treino e modelação, dado o evidente papel do tempo no desgaste de uma ferramenta de corte.

## **Extração e Seleção de Atributos**

A monitorização de desgaste de ferramentas de corte aparenta ser uma forma de reproduzir o comportamento sensorial humano no processo de decisão mediante diferentes condições, assemelhando-se ao processamento de diferentes informações detetadas num processo de tomada de decisão pelo operador.

Nos SMPC são vários os sensores/atributos que têm vindo a ser considerados, conforme descrito nos parágrafos seguintes.

### **Emissões acústicas**

Durante o processo de corte as peças sofrem deformações, sendo que parte da energia libertada é sob a forma de emissões acústicas (som) (Ambhore et al., 2015). Estudos efetuados demonstram que os sons emitidos durante o processo de corte podem ser um dos atributos a ser utilizado para classificação do desgaste da ferramenta de corte. Contudo, os sensores utilizados para recolha de informação (microfone) são muito suscetíveis a ruídos e interferências sendo portanto recomendável apenas usar este tipo de sensor num SMPC em combinação com outros tipos de sensores (M. Bhuiyan, Choudhury, & Nukman, 2012; M. S. H. Bhuiyan et al., 2014; H. V. Ravindra, Srinivasa, & Krishnamurthy, 1997).

### **Temperatura**

No processo de corte de metal as peças estão sujeitas a constantes fricções, provocando um aumento significativo da temperatura na ferramenta de corte gerada pelas mesmas. Como a distribuição da temperatura não é uniforme, logo não é possível obter com exatidão a quantidade de calor transferido. No entanto, pensa-se que a quantidade de calor removida é tão alta como 90% do calor gerado global, o que implica que menos de 10% do calor é absorvido ou disperso através da ferramenta e do material da peça de trabalho (Boothroyd & Knight, 1989). Esta limitação faz com que este parâmetro, apesar de ser um bom indicador do desgaste da ferramenta de corte (Chow & Wright, 1988), seja de difícil obtenção com relativa exatidão, quando aplicada em SMPC, devido a inacessibilidade da área de corte da peça (Chinchanikar & Choudhury, 2014; Dimla Snr., 2000).

## **Forças de corte**

As variações de fricção que ocorrem entre o flanco da ferramenta de corte e a peça de trabalho provocam desgaste na ferramenta de corte, sendo que quando ocorre um aumento da fricção implica que a força necessária para torneamento/fresagem da peça também aumente de forma gradual (Dornfeld & DeVries, 1990; Ko & Cho, 1994). Deste modo a força de corte é geralmente considerada como sendo um dos indicadores mais significativos na classificação do desgaste das ferramentas (Ghasempoor, Jeswiet, & Moore, 1999; Oraby & Hayhurst, 1991; H. V. Ravindra, Srinivasa, & Krishnamurthy, 1993; Rizal, Ghani, Nuawi, & Haron, 2013; Sikdar & Chen, 2002; Yao, Fang, & Arndt, 1990), sendo amplamente utilizada como atributo de análise nos SMPC (Ambhore et al., 2015; Dimla Snr., 2000).

## **Métodos Óticos**

Análise em tempo real do desgaste é efetuada através da análise tanto da ferramenta de corte como através da análise do acabamento da superfície da peça a torner ou fresar. Esta análise pode ser efetuada de vários modos, sendo os que normalmente selecionados são camaras de alta resolução que visualizam diretamente a ferramenta de corte (Chethan, Ravindra, gowda, & Bharath Kumar, 2015) ou através da utilização de feixes laser e tentar interpretar o índice de reflexão e refração quando este incide sobre a peça a ser trabalhada (Martin, Brandon, Grosvenor, & Owen, 1986). Este tipo de análise é considerado como não sendo viável para utilização nos SMPC, uma vez que são sistemas com custos elevados, tanto de aquisição como de manutenção, pois, caso não estejam devidamente calibrados, estes apresentam um alto nível de imprecisão (Cuppini, D'Errico, & Rutelli, 1986; Oguamanam, Raafat, & Taboun, 1994; Shiraishi, 1988; Wong, Nee, Li, & Reisdorf, 1997).

## **Vibração**

A vibração é uma característica inerente a praticamente todas as máquinas industriais. As variações das vibrações no processo de corte podem ser originadas por irregularidades da superfície ou desgaste da ferramenta de corte. Vários estudos efetuados (Abouelatta & Mádl, 2001; Alonso & Salgado, 2008; El-Wardany, Gao, & Elbestawi, 1996; Rajesh & Narayanan Namboothiri, 2010; Rotberg, Lenz, & Braun, 1987; Venkata Rao, Murthy, & Mohan Rao, 2013; Yao, Fang, & Arndt, 1991) demonstram que existe uma correlação entre o desgaste de ferramenta de corte e as vibrações produzidas, sendo considerado como dos sensores que não pode ser dispensado num SMPC (Dimla, Dimla E., 1998).

## **Energia consumida pelo motor**

Através da análise da energia consumida pelo motor é possível obter uma relação entre esta e o desgaste da ferramenta (Salgado & Alonso, 2007). Contudo, esta está dependente das condições de corte e da geometria da ferramenta de corte (Constantinides & Bennett, 1987). Devido ao desgaste também se relacionar com outros atributos, como é o caso com a potência do eixo, torque do motor e as forças de corte, a literatura propõe que é apenas necessário analisar um destes atributos, tendo-se dado preferência ao atributo das forças de corte para os SMPC (Rangwala & Dornfeld, 1987, 1990).

A literatura demonstra que os atributos mais credíveis e menos intrusivos utilizados por norma nos SMPC são a força, vibração e o som, que demonstram uma maior precisão no processo de desgaste da ferramenta (Dimla Snr., 2000; Yen, Lu, & Chen, 2013).

### **3. Trabalho Experimental e Desenvolvimento**

Através de resultados de estudos realizados, como também a sua credibilidade tendo em conta uma reduzida intrusão no processo de corte, podemos identificar os seguintes sensores como sendo os melhores candidatos para a monitorização das condições dos processos de corte como torneamento e fresagem: medição da força através de extensómetros posicionados no porta-ferramentas; microfone para aquisição de sons emitidos; e acelerómetros para a medição de vibrações (Silva, R., Wilcox, S. and Reuben, 2006). Também a utilização de múltiplos sensores deverá provar que é uma mais-valia na avaliação do desgaste da ferramenta uma vez que o ruído característico captado de cada um dos sensores quando usados individualmente conduziria com certeza a um insucesso do sistema de monitorização (Kuo, 2000; Siddhpura & Paurobally, 2013).

Em termos de atributos e parâmetros disponíveis que sejam credíveis também deveria ser considerado o facto de que a equação de Taylor é provavelmente a mais antiga tentativa para determinar a duração do tempo de vida de uma ferramenta sendo que é o padrão de maquinação absoluta a longo prazo ISO 3685 (ISO 3685, 1993), definido por esta mesma equação. Esta equação indica-nos uma estimativa do tempo de vida de uma determinada ferramenta dependendo do material que está a ser cortado como também das variáveis das condições de corte. Apesar do seu uso limitado é indiscutível afirmar que tanto a velocidade de corte como o tempo de corte têm um grande impacto na vida de uma ferramenta. Uma vez que o tempo é determinante no processo de desgaste de uma ferramenta, e como está facilmente disponível em máquinas modernas, é recomendável o seu uso como atributo para a construção do modelo na aprendizagem da rede neuronal.

Apesar dos sistemas de monitorização já terem sido extensivamente estudados, algumas limitações persistem no que diz respeito à sua performance durante condições reais de manufatura. Existem vários aspetos que podem vir a melhorar a classificação do desgaste da ferramenta, tendo em vista o suporte a fabricas autónomas. Este trabalho explora o impacto que dois desses fatores causam na performance da classificação do nível de desgaste da ferramenta de corte, nomeadamente o uso da variável do tempo como um fator decisivo e intuitivo para aumentar a performance do modelo criado pela rede neuronal e o de controlo do ritmo de aprendizagem entre os neurónios, de modo a que a nova informação possa ser relacionada facilmente, sem que exista degradação na informação anteriormente aprendida. Este trabalho descreve o uso de técnicas de aprendizagem automática para sistemas de monitorização e propõe a introdução de melhorias, demonstradas com suporte em trabalho experimental e verificando a sua viabilidade através de teste de aprendizagem do SOM.

### Apparatus

O trabalho experimental que suporta o estudo apresentado foi executado num torno mecânico modificado que incorporava os seguintes sensores: extensómetros colocados no porta-ferramentas para medir a força de avanço e tangencial; acelerómetro para medir as vibrações verticais colocado na torreta; e um microfone colocado perto da pastilha de corte. A disposição do *apparatus* experimental está identificada na Figura 3.

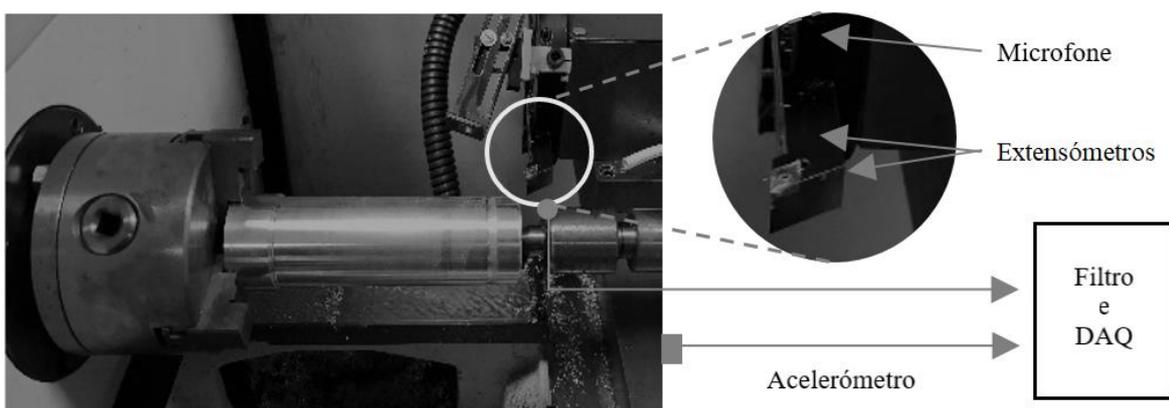


Figura 3 - Apparatus Experimental

## Procedimento Experimental

O trabalho experimental executado no torno mecânico serve de base para o trabalho desenvolvido. Os dados foram adquiridos através da maquinação de um bloco de aço macio em condições de produção realistas, que consistiam numa velocidade de corte de 350m/min, uma força de avanço de 0,25 rev/min e uma profundidade de corte de 1mm, com uma pastilha de corte de carboneto de tungstênio e cobalto.

Os sinais não tratados de todos os sensores apresentados na Tabela 1, foram recolhidos a 20 kHz, sendo que os valores medidos do desgaste das pastilhas de corte e a aquisição de dados foram efetuados com intervalos de 2 minutos, tendo em conta que a vida expectável para cada uma da pastilha de corte é de aproximadamente 15 minutos. Os dados foram recolhidos de quatro pastilhas de corte produzindo um conjunto de 33 dados não tratados. O comprimento de cada amostra é de 512 pontos, sendo adquiridos aproximadamente no meio da barra.

**Tabela 1 - Instrumentação**

Sensor	Descrição
Acelerómetro	Kistler 1, 5108
Microfone	ECM-1028, amplificador
Extensómetros	Duas meias pontes de <i>Wheatstone</i> , construído a partir de dois extensómetros, um em cada um dos lados do porta-ferramentas.

## Extração de Atributos

Cada registo de 512 pontos foi processado com o objetivo de gerar atributos para serem usados na etapa de classificação. Um total de 12 atributos foram recolhidos dos dados do som e da vibração: desvio absoluto; média; *kurtosis*; *skewness* e ainda a energia na frequência de bandas (2.2-2.4 e 4.4-4.6 kHz) obtidas através dos respetivos espectros. Duas características adicionais foram apresentadas através das forças médias de avanço e tangencial. A maioria dos atributos extraídos, como também as forças medidas, apresentam um nível de ruído muito elevado que podem estar associados com o torno, interfaces, interferências eletromagnéticas, ou ainda de outras fontes não identificadas. Os dados apresentados na Figura 4 determinam a evolução do desgaste de 4 pastilhas de corte onde é possível verificar a variabilidade e imprevisibilidade associados à monitorização do desgaste da ferramenta de corte.

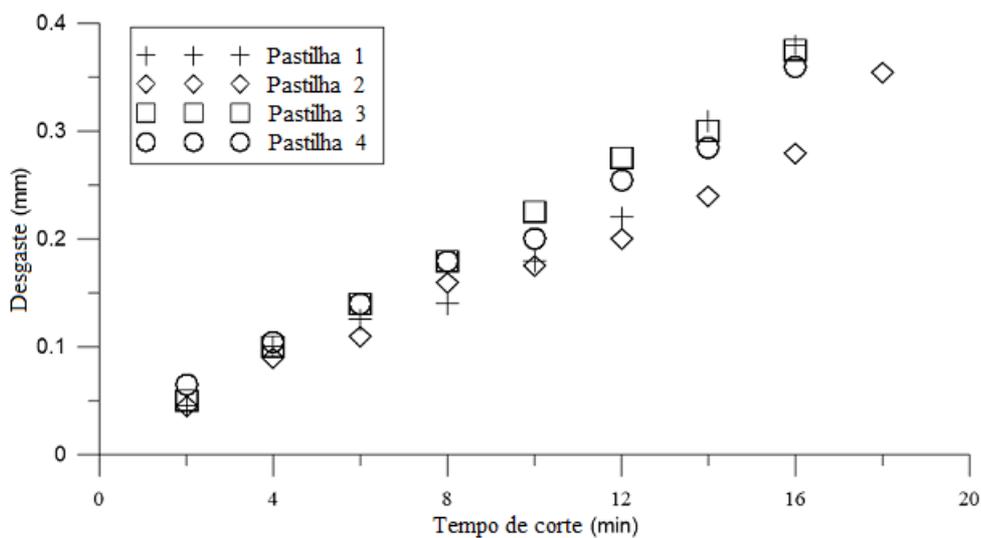


Figura 4 -Evolução do desgaste do flanco para diferentes pastilhas de corte.

Através da Figura 5 verifica-se que a força tangencial tem de forma geral um comportamento consistente e aumenta com o tempo de corte. Apesar de consistente pode-se ver que os dados têm muito ruído e não é possível estabelecer uma relação direta com o desgaste da ferramenta de corte, pois o gradiente de aumento do desgaste para diferentes pastilhas de corte é diferente.

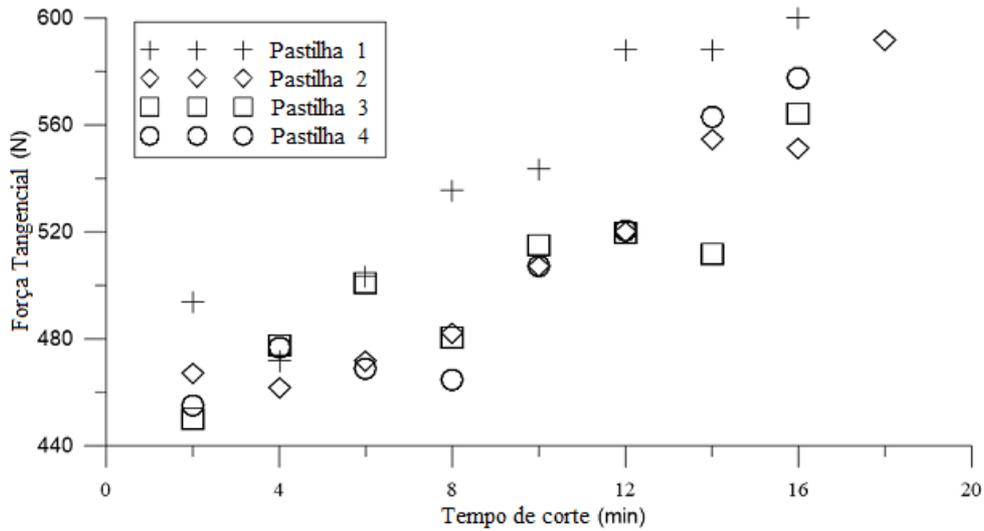


Figura 5 - Atributo da amostra - Força tangencial em relação ao tempo de corte.

Os resultados obtidos através dos parâmetros estatísticos e frequência, como também as forças são de difícil interpretação quando considerados em separado para cada uma das pastilhas analisadas, pois algumas não apresentam aparente correlação entre elas, e outras nem sequer uma correlação com o desgaste da pastilha de corte. Isto pode ser superado tendo em conta que as redes neurais têm habilidade para extrair informação mesmo quando esta se encontra dispersa, visto que apresenta um comportamento subjacente não transparente às técnicas tradicionais de modelação matemática.

Todos os outros atributos também parecem exibir uma ligeira correlação com o desgaste da ferramenta de corte. Apesar do facto de não existir uma correlação óbvia para o desgaste da ferramenta, os atributos contêm informação relativa à evolução da dinâmica de corte devido ao desgaste da pastilha. O processo de corte é conhecido por ser um processo que apresenta um elevado grau de complexidade, não sendo possível definir as suas importâncias relativamente à classificação do desgaste da pastilha de corte. Todos as características analisadas na Figura 6 foram utilizadas como atributos para treino do SOM.

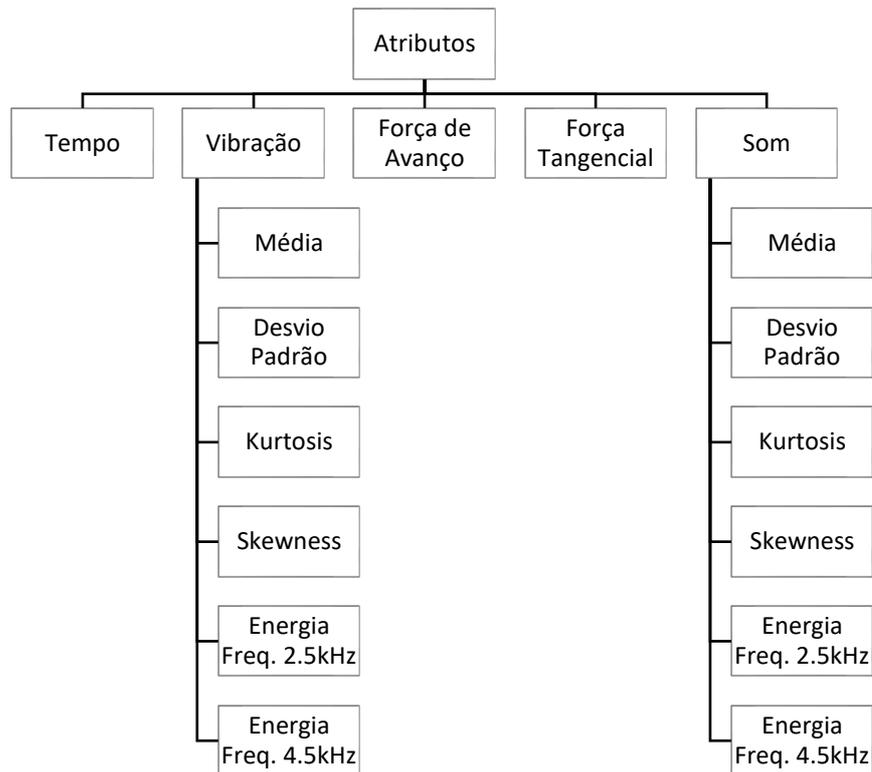


Figura 6 - Atributos Analisados.

### Algoritmos de Aprendizagem

Algoritmos de aprendizagem no que respeita às redes neuronais têm vindo a ser extensivamente explorados, tendo em conta diferentes abordagens onde os aspetos relativos à sua estrutura e adaptabilidade foram tidos em consideração (Jing, 2012; Meng & Pei, 2014). Aprender novos modelos ou preservar informação mais antiga pode ser alcançada através de alterações do algoritmo como por exemplo a criação de novos neurónios com estruturas que variem com o tempo (Araujo & Rego, 2013; Xing, Shi, Shen, Zhou, & Zhao, 2016) ou ainda apenas abrandando o ritmo de aprendizagem nos neurónios vizinhos do neurónio vencedor (Piastra, 2013; Shah-Hosseini & Safabakhsh, 2003). Com a implementação da primeira abordagem apresentada implica que a rede neuronal fique cada vez maior sendo que esta pode nunca vir a ser otimizada. A segunda abordagem já demonstrou ter uma melhor performance comparativamente com outras abordagens mais tradicionais sendo que permite que neurónios que não são frequentemente vencedores tenham a oportunidade de serem representativos de novas informações. Esta abordagem permite no geral uma melhor distribuição topológica no reconhecimento de novos padrões. Contudo, não previne ou penaliza o facto de poder ocorrer um reforço da aprendizagem

repetidamente num mesmo neurónio. Este trabalho visa a exploração de implementações alternativas ao nível do ritmo de aprendizagem. Contudo, continuando a controlar o ritmo de aprendizagem de um neurónio vencedor para que este perca gradualmente privilégios quanto mais vezes for vencedor, dando desta forma possibilidade a que neurónios que se encontrem perto, poderem representar padrões nas proximidades. O melhoramento proposto para o mecanismo de aprendizagem adaptativa reforça a capacidade da rede neural de assimilar novas informações inibindo a rede geral de se tornar bloqueada no que diz respeito à capacidade de utilização do espaço de classificação, assimilando sempre novos dados. Consequentemente, proporciona um melhor rearranjo do mapa de saída, distribuindo assim uniformemente os padrões da informação representada.

A Equação 3 permite o cálculo do ritmo de aprendizagem,  $\lambda_o(t)$ , considerando cada um dos neurónios, dado o neurónio vencedor da saída,  $o$ , sendo  $\eta$  o raio inicial da vizinhança e  $h_o$ , o número de vezes que o neurónio já foi considerado neurónio vencedor.

$$\lambda_o(t + 1) = \eta \cdot \lambda_o(t) \cdot e^{-\frac{h_o \cdot \|N_c - N_o\|}{t \cdot 2\sigma}} \quad (3)$$

O efeito combinado resulta na regra de aprendizagem para pesos de ligação apresentada na Equação 4 onde  $w_o^i$ , representa os pesos de neurónios de entrada,  $i$ , e neurónios de saída,  $o$  e  $\varphi_{(c,o)}$ , representa a função vizinhança. Os vetores de entrada,  $x$ , são apresentados a cada iteração,  $t$ , fazendo com que os pesos sejam atualizados por forma a que as saídas se aproximem dos padrões de entrada.

$$w_o^i(t + 1) = \lambda_o(t) \varphi_{(c,o)} [x_i(t) - w_o^i(t)] \quad (4)$$

O controle do ritmo de aprendizagem local assemelha-se à aprendizagem que ocorre em diferentes conjuntos das redes neuronais para diferentes conjuntos de dados, contemplando a característica fundamental do SOM, a ação de preservação da topologia.

## Algoritmo Desenvolvido

Tendo em conta a análise anterior e com base nas indicações descritas, o algoritmo desenvolvido segue os seguintes passos tendo este sido construído para o módulo de trabalho SOM. Uma vez que o SOM depende da normalização para evitar sobrecarga das variáveis, foram identificados os valores máximos e mínimos de cada um dos atributos, de modo a que a magnitude e variação relativa fossem preservadas. O algoritmo foi desenvolvido na íntegra, sem recurso a qualquer biblioteca no que se refere ao SOM.

O algoritmo para o SOM pode ser dividido em seis etapas.

- 1) Para cada nó são inicializados os pesos aleatoriamente com valores que variam entre 0 e 1.
- 2) É selecionado um vetor aleatório do conjunto de dados de treino sendo de seguida apresentado à rede.
- 3) São verificados todos os neurónios da rede para calcular qual destes tem uma representação dos pesos mais semelhante ao vetor de entrada, através da função da distância euclidiana,  $d_{ijk}$ , representada na Equação 5 em que  $x_i(t)$  representa o vetor de entrada e  $w_{ijk}(t)$  os pesos dos neurónios da rede neuronal. Este neurónio é designado vencedor.

$$d_{ijk} = \sum_{i=1}^N (x_i(t) + w_{ijk}(t))^2 \quad (5)$$

- 4) É calculado o raio da vizinhança para o neurónio vencedor segundo a Equação 2. Este valor pode ser inicialmente igual ao raio da rede, diminuindo a cada iteração.
- 5) Para cada neurónio que se encontre no raio do neurónio vencedor é feito o ajuste dos pesos para que estes representem melhor o vetor de entrada anteriormente selecionado (Equação 4). Quanto mais perto os neurónios estiverem do neurónio vencedor mais o seu peso será alterado, aproximando-se assim do neurónio vencedor.
- 6) Repetição do ponto 2) para N iterações

## 4. Resultados e Discussão

Com o propósito de testar a viabilidade da proposta apresentada foi desenvolvido e otimizado um programa utilizando a linguagem Java. Este algoritmo implementava o SOM na sua forma base, com as alterações propostas no capítulo anterior.

Do conjunto de dados utilizados, três das pastilhas de corte foram usadas para treinar a rede neuronal, sendo a quarta pastilha de corte utilizada para verificar e testar a performance da rede. O treino foi executado com recurso a 200 iterações em modo de treino *batch* para obtenção de melhores resultados. Ambas as versões do algoritmo foram executadas lado a lado para que existissem garantias de que apenas as modificações propostas para o ritmo de aprendizagem fossem realizadas. O mapa de saída corresponde a uma matriz de 10 por 10 neurónios.

O mapa topográfico representado na Figura 7 apresenta o mapa tipo de saída produzido durante o treino da rede neuronal. O método utilizado para interpolação do mapa e para proporcionar uma estimativa para neurónios que não tenham representação no mapa foi o método de *Kriging* usado num contexto geográfico. O mapa de contornos da Figura 7 apresenta a classificação obtida através da execução do algoritmo original para o SOM. O mapa de linhas de contorno representa os limites para diferentes níveis de desgaste das ferramentas de corte. Os símbolos que se encontram no mapa representam os conjuntos de características pertencentes a cada uma das amostras utilizadas para treino, onde o tamanho dos símbolos tem correlação direta com o nível de desgaste de ferramenta de corte.

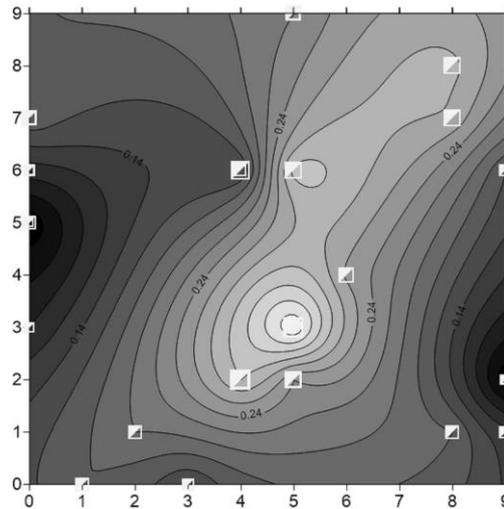


Figura 7 - Classificação de mapa de saída de amostra sem aprendizagem adaptativa - símbolos maiores representam valores de desgaste superiores

A Figura 7 revela a ocorrência de aprendizagem e que diferentes níveis de desgaste contidos da base de dados são posicionados em regiões vizinhas. Pode ser visto que algumas das linhas de contorno se encontram muito próximas revelando que o nivelamento do mapa faz reduzido aproveitamento do espaço de classificação.

A Figura 8 apresenta uma comparação entre os valores de classificação da amostra com aos valores reais do desgaste, estes valores correspondem aos vetores de atributos da quarta pastilha de corte, valores que não foram utilizados durante a aprendizagem. Pode ser visualizado que efetivamente ocorre a classificação do desgaste da ferramenta, contudo existem alguns erros de classificação que requerem atenção. Esta figura apresenta os resultados obtidos onde é utilizado o algoritmo original para o SOM e onde o tempo ainda não é considerado como atributo de classificação durante a aprendizagem.

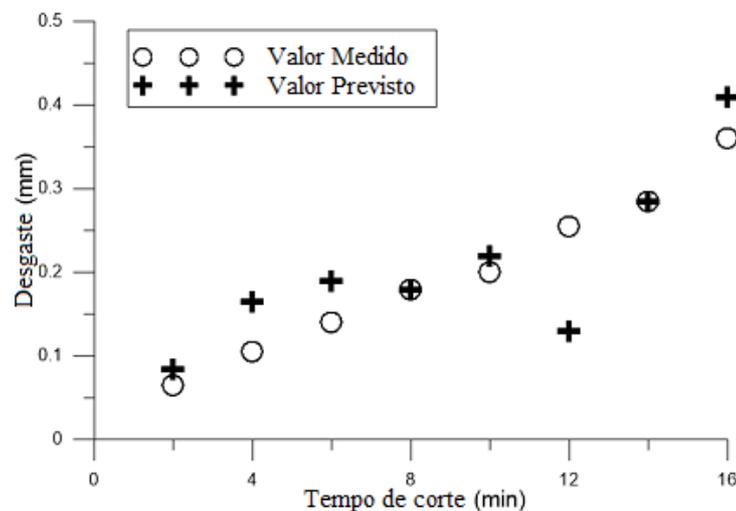


Figura 8 - Teste da classificação da amostra em relação aos valores medidos - Execução SOM direta sem utilização do tempo como atributo.

Os resultados apresentados na Figura 9 são referentes à implementação básica do algoritmo, estando incluído o tempo como atributo de classificação. No geral é possível verificar uma ligeira melhoria, sendo que, este impacto pode ser melhor observado no vetor da amostra pertencente aos dados adquiridos ao minuto 12 da vida da ferramenta de corte.

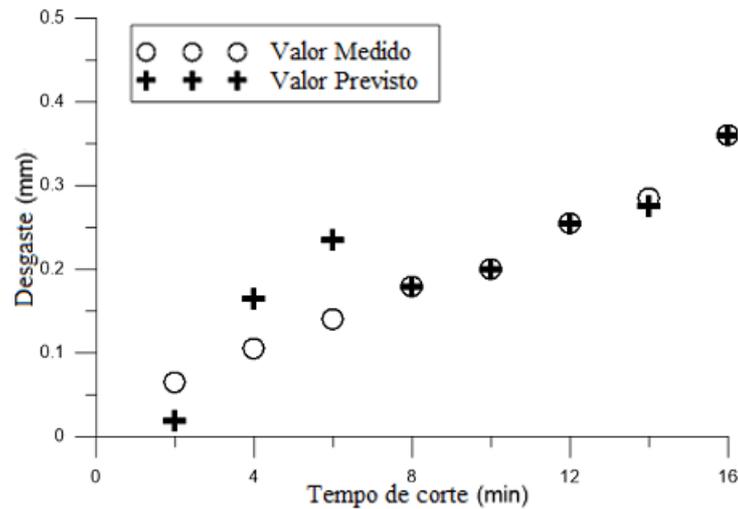


Figura 9 - Teste a classificação da amostra em relação aos valores medidos - Execução SOM direta com utilização do atributo tempo.

A implementação do algoritmo adaptativo do SOM, na qual é introduzida uma aprendizagem diferida segundo a regra proposta, é agora sujeita a estudo, sendo os resultados apresentados de seguida. Na Figura 10, o mapa de contornos apresenta uma ligeira melhoria da distribuição dos sets de dados quando comparado com a Figura 7, sendo ainda possível verificar que as linhas de contorno se encontram menos constrangidas a um único espaço.

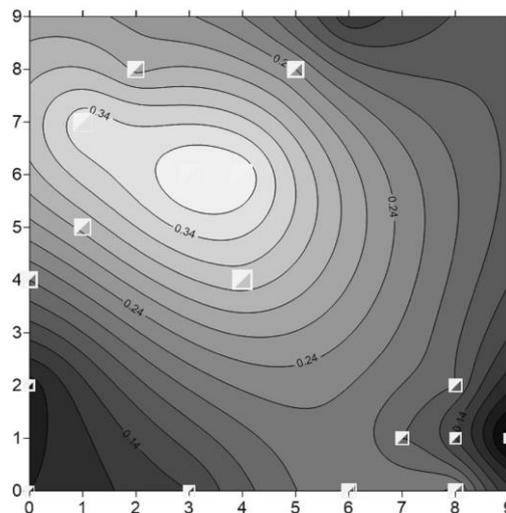


Figura 10 - Classificação de mapa de saída de amostra com aprendizagem adaptativa - símbolos maiores representam valores de desgaste superiores.

O impacto obtido com a utilização de uma aprendizagem diferida é significativo, como é retratado nas Figura 11 e Figura 12. Na Figura 11 existem três erros de classificação sendo que apenas dois dos vetores de atributos da amostra apresentam um desvio expressivo entre o valor de previsão e o valor medido do desgaste. Testes conduzidos com o algoritmo adaptado e subjacente a regra proposta para a atualização da aprendizagem, mostram que no geral foram verificadas melhorias, sendo que, o mapa reproduzido para as saídas apresenta uma distribuição mais homogênea quando comparado com os mapas anteriormente analisados. A inclusão do tempo como atributo, Figura 12, exibe também um impacto adicional e uma performance claramente superior, quando comparado com o vetor de dados onde não é incluído o tempo como atributo.

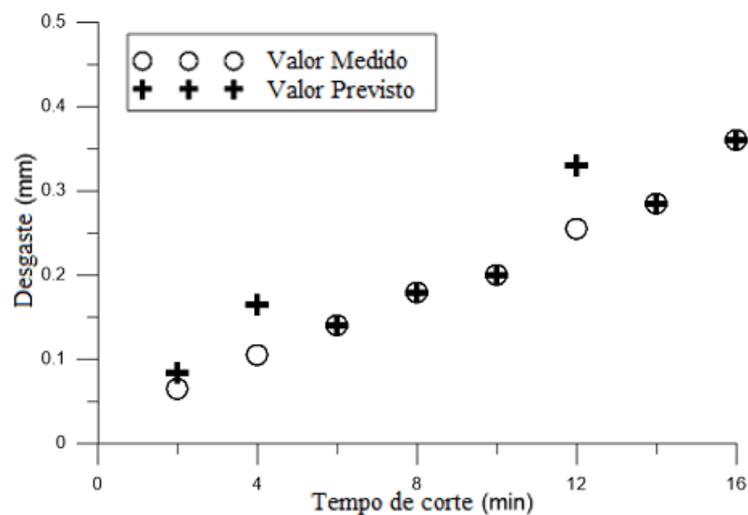


Figura 11 - Teste da classificação da amostra em relação aos valores medidos - Execução SOM adaptativo sem utilização do tempo como atributo.

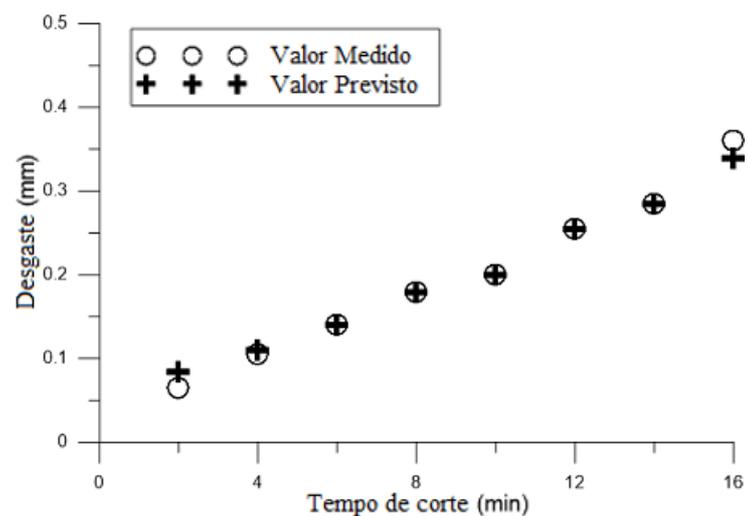


Figura 12 - Teste da classificação da amostra em relação aos valores medidos - Execução SOM adaptativo com utilização do atributo tempo.

Através da análise dos resultados obtidos dos diferentes testes elaborados foi efetuado o cálculo do erro (Tabela 2). Este erro foi calculado para cada um dos valores do desgaste medidos tendo em consideração a equação do erro relativo percentual (Equação 6) tendo sido posteriormente efetuada a média do erro entre os oito pontos analisados. Através da Tabela 2 é possível verificar que quando comparada a execução SOM direta sem utilização do tempo como atributo com a execução SOM adaptativo com utilização do atributo tempo, ocorreu uma diminuição do erro de classificação superior a 20%.

$$Erro\ Relativo = \frac{|valor\ medido - valor\ classificação|}{valor\ medido} \times 100 \quad (6)$$

**Tabela 2 - Erro Relativo Percentual de classificação**

Execução SOM direta sem utilização do tempo como atributo - Figura 8	27,3%
Execução SOM direta com utilização do atributo tempo - Figura 9	24,4%
Execução SOM adaptativo sem utilização do tempo como atributo - Figura 11	13,2%
Execução SOM adaptativo com utilização do atributo tempo - Figura 12	4,8%

Estes resultados preliminares sugerem que através da inclusão do tempo como atributo no vetor de atributos para classificação do desgaste produz um impacto positivo significativo. Uma vez que este atributo é de fácil obtenção em máquinas e ferramentas modernas, é altamente aconselhável a sua utilização para que possa ser obtida uma melhor performance do sistema de monitorização.

## 5. Conclusão e Trabalhos Futuros

Esta dissertação revisita aspectos referentes às limitações dos sistemas de monitorização do desgaste de ferramentas de corte, em particular aos que podem ter uma relação direta com possíveis melhorias da performance sobre a classificação do estado de desgaste das ferramentas, tendo em consideração as condições industriais reais que ocorrem durante a sua operação. Os dados foram obtidos através da maquinação de um bloco de aço macio num torno mecânico, tendo sido utilizado um conjunto de sensores no qual estão incluídos um microfone, extensómetros, e acelerómetros, e o corte efetuado com as seguintes condições: velocidade de corte de 350m/min, uma força de avanço de 0,25 rev/min e uma profundidade de corte de 1mm, com uma pastilha de corte de carboneto de tungstênio e cobalto com o objetivo de elaborar testes para modelação e classificação do desgaste das ferramentas de corte. Com o propósito de classificação foi desenvolvido uma rede neuronal do SOM onde foram introduzidas alterações no que respeita às regras de aprendizagem.

Os atributos que suportam a monitorização apresentam-se contaminados com ruído, não tendo sido possível identificar relações diretas entre estes e o desgaste das ferramentas de corte. Apesar do ruído presente foi, contudo, ainda possível obter classificações para todas as amostras com um erro residual. Deve ser sublinhado que através da introdução do tempo como atributo de classificação foi possível alcançar melhorias significativas quanto à classificação. As alterações efetuadas nas regras de aprendizagem, que contemplam a inibição do reforço de um neurónio que frequentemente seja classificado como vencedor, também mostram bons resultados suportando a abordagem apresentada neste trabalho. A utilização de uma aprendizagem diferida apresentou melhorias na classificação do desgaste das ferramentas de corte, sendo que, pode ainda ser sugerido que os processos de aprendizagem que ocorrem nos seres humanos podem ser igualmente diferidos, permitindo deste modo uma aprendizagem contínua, sem mitigar a sua aptidão para classificar padrões anteriormente estabelecidos e acomodar novos em modo contínuo de aprendizagem.

Os resultados apresentados neste trabalho identificam melhorias que devem ser tidas em conta aquando da realização de trabalhos futuros, nomeadamente, experiências exaustivas contemplando um maior número de amostras, sendo ainda necessária efetuar uma análise de sensibilidade em relação aos parâmetros de aprendizagem da rede neuronal e às condições de corte.

# Referências

- Abouelatta, O. B., & Mádl, J. (2001). Surface roughness prediction based on cutting parameters and tool vibrations in turning operations. *Journal of Materials Processing Technology*, 118(1–3), 269–277. [https://doi.org/10.1016/S0924-0136\(01\)00959-1](https://doi.org/10.1016/S0924-0136(01)00959-1)
- Alonso, F. J., & Salgado, D. R. (2008). Analysis of the structure of vibration signals for tool wear detection. *Mechanical Systems and Signal Processing*, 22(3), 735–748. <https://doi.org/10.1016/j.ymsp.2007.09.012>
- Ambhore, N., Kamble, D., Chinchankar, S., & Wayal, V. (2015). Tool condition monitoring system: A review. *Materials Today: Proceedings*, 2(4–5), 3419–3428. <https://doi.org/10.1016/j.matpr.2015.07.317>
- Aoki, H., Mashimo, S., & Nakamura, H. (2015). Screening of Chronic Obstructive Pulmonary Disease by Using Self-Organizing Map. *IEEJ Transactions on Electronics, Information and Systems*, 135(8), 937–943. <https://doi.org/10.1541/ieejieiss.135.937>
- Araujo, A. F. R., & Rego, R. L. M. E. (2013). Self-organizing Maps with a Time-varying Structure. *ACM Comput. Surv.*, 46(1), 7:1--7:38. <https://doi.org/10.1145/2522968.2522975>
- Bazarghan, M. (2012). Application of self-organizing map to stellar spectral classifications. *Astrophysics and Space Science*, 337(1), 93–98. <https://doi.org/10.1007/s10509-011-0822-7>
- Bhuiyan, M., Choudhury, S., & Nukman, Y. (2012). Tool condition monitoring using acoustic emission and vibration signature in turning. *Proceedings of the World ...*, III, 2–6. Retrieved from [http://www.iaeng.org/publication/WCE2012/WCE2012\\_pp1612-1616.pdf](http://www.iaeng.org/publication/WCE2012/WCE2012_pp1612-1616.pdf)
- Bhuiyan, M. S. H., Choudhury, I. A., & Dahari, M. (2014). Monitoring the tool wear, surface roughness and chip formation occurrences using multiple sensors in turning. *Journal of Manufacturing Systems*, 33(4), 476–487. <https://doi.org/10.1016/j.jmsy.2014.04.005>
- Boothroyd, G. (Geoffrey), & Knight, W. A. (Winston A. (1989). *Fundamentals of Metal Machining and Machine Tools*. Marcel Dekker. Retrieved from [https://books.google.pt/books/about/Fundamentals\\_of\\_Metal\\_Machining\\_and\\_Mach.html?id=sMmqNKclBV8C&redir\\_esc=y](https://books.google.pt/books/about/Fundamentals_of_Metal_Machining_and_Mach.html?id=sMmqNKclBV8C&redir_esc=y)
- Cai, Q., Yin, Y., & Man, H. (2013). Learning spatio-temporal dependencies for action recognition. In *2013 IEEE International Conference on Image Processing, ICIP 2013 - Proceedings* (pp. 3740–3744). IEEE. <https://doi.org/10.1109/ICIP.2013.6738771>

- Chen, I.-T., Chang, L.-C., & Chang, F.-J. (2017). Exploring the Spatio-Temporal Interrelation between Groundwater and Surface Water by Using the Self-Organizing Maps. *Journal of Hydrology*. <https://doi.org/10.1016/j.jhydrol.2017.10.015>
- Chen, J.-H., Su, M.-C., Cao, R., Hsu, S.-C., & Lu, J.-C. (2017). A self organizing map optimization based image recognition and processing model for bridge crack inspection. *Automation in Construction*, 73, 58–66. <https://doi.org/10.1016/j.autcon.2016.08.033>
- Chethan, Y. D., Ravindra, H. V., Gowda, Y. T., & Bharath Kumar, S. (2015). Machine Vision for Tool Status Monitoring in Turning Inconel 718 using Blob Analysis. *Materials Today: Proceedings*, 2(4–5), 1841–1848. <https://doi.org/10.1016/j.matpr.2015.07.124>
- Chinchanikar, S., & Choudhury, S. K. (2014). Evaluation of Chip-tool Interface Temperature: Effect of Tool Coating and Cutting Parameters during Turning Hardened AISI 4340 Steel. *Procedia Materials Science*, 6, 996–1005. <https://doi.org/10.1016/j.mspro.2014.07.170>
- Chow, J. G., & Wright, P. K. (1988). On-Line Estimation of Tool/Chip Interface Temperatures for a Turning Operation. *Journal of Engineering for Industry*, 110(1), 56. <https://doi.org/10.1115/1.3187843>
- Constantinides, N., & Bennett, S. (1987). An investigation of methods for the on-line estimation of tool wear. *International Journal of Machine Tools and Manufacture*, 27(2), 225–237. [https://doi.org/10.1016/S0890-6955\(87\)80052-4](https://doi.org/10.1016/S0890-6955(87)80052-4)
- Cuppini, D., D'Errico, G., & Rutelli, G. (1986). Tool Image Processing with Applications to Unmanned Metal-Cutting: A Computer Vision System for Wear Sensing and Failure Detection. In S. Sottini & S. Trigari (Eds.), *Spie* (Vol. 701, pp. 416–422). <https://doi.org/10.1117/12.937096>
- Deboeck, G. (1998). Picking Mutual Funds with Self-Organizing Maps. In *Visual Explorations in Finance with Self-Organizing Maps* (pp. 39–58). [https://doi.org/10.1007/978-1-4471-3913-3\\_3](https://doi.org/10.1007/978-1-4471-3913-3_3)
- Deboeck, G., & Kohonen, T. (1998). *Visual explorations in finance : with self-organizing maps*. Springer finance. Springer London.
- DeSieno, D. (1988). Adding a conscience to competitive learning. In *Neural Networks, 1988., IEEE International Conference on* (pp. 117–124 vol.1). IEEE. <https://doi.org/10.1109/ICNN.1988.23839>
- Dimla, Dimla E., S. (1998, January 1). *Multivariate tool condition monitoring in a metal cutting operation using neural networks*. University of Wolverhampton. Retrieved from <http://wlv.openrepository.com/wlv/handle/2436/96291>
- Dimla, D. ., & Lister, P. . (2000). On-line metal cutting tool condition monitoring. *International Journal of Machine Tools and Manufacture*, 40(5), 769–781. [https://doi.org/10.1016/S0890-6955\(99\)00085-1](https://doi.org/10.1016/S0890-6955(99)00085-1)
- Dimla Snr., D. E. (2000). Sensor signals for tool-wear monitoring in metal cutting operations - a review of methods. *International Journal of Machine Tools and Manufacture*, 40(8), 1073–1098. [https://doi.org/10.1016/S0890-6955\(99\)00122-4](https://doi.org/10.1016/S0890-6955(99)00122-4)
- Dornfeld, D. A., & DeVries, M. F. (1990). Neural Network Sensor Fusion for Tool Condition Monitoring. *CIRP Annals - Manufacturing Technology*, 39(1), 101–105. [https://doi.org/10.1016/S0007-8506\(07\)61012-9](https://doi.org/10.1016/S0007-8506(07)61012-9)

- Duro, J. a., Padget, J. a., Bowen, C. R., Kim, H. A., & Nassehi, A. (2016). Multi-sensor data fusion framework for CNC machining monitoring. *Mechanical Systems and Signal Processing*, 66–67, 505–520. <https://doi.org/10.1016/j.ymsp.2015.04.019>
- El-Wardany, T. I., Gao, D., & Elbestawi, M. A. (1996). Tool condition monitoring in drilling using vibration signature analysis. *International Journal of Machine Tools and Manufacture*, 36(6), 687–711. [https://doi.org/10.1016/0890-6955\(95\)00058-5](https://doi.org/10.1016/0890-6955(95)00058-5)
- Farnood Ahmadi, F. (2016). Close range photogrammetry and self-organizing map for automatic diagnosing diseases. *Neural Computing and Applications*, 27(7), 1883–1891. <https://doi.org/10.1007/s00521-015-1980-2>
- Folorunso, O., & Ogunde, A. O. (2005). Data mining as a technique for knowledge management in business process redesign. *Information Management & Computer Security*, 13(4), 274–280. <https://doi.org/10.1108/09685220510614407>
- Ghasempoor, A., Jeswiet, J., & Moore, T. N. (1999). Real time implementation of on-line tool condition monitoring in turning. *International Journal of Machine Tools and Manufacture*, 39(12), 1883–1902. [https://doi.org/10.1016/S0890-6955\(99\)00035-8](https://doi.org/10.1016/S0890-6955(99)00035-8)
- Girardin, F., Rémond, D., & Rigal, J. F. (2010). Tool wear detection in milling-An original approach with a non-dedicated sensor. *Mechanical Systems and Signal Processing*, 24(6), 1907–1920. <https://doi.org/10.1016/j.ymsp.2010.02.008>
- ISO 3685 (1993). International Organization for Standardization.
- Jing, X. (2012). Robust adaptive learning of feedforward neural networks via LMI optimizations. *Neural Networks*, 31, 33–45. <https://doi.org/10.1016/j.neunet.2012.03.003>
- Kiviluoto, K., & Bergius, P. (1998). Maps for Analyzing Failures of Small and Medium-sized Enterprises. In *Visual Explorations in Finance with Self-Organizing Maps* (pp. 59–71). [https://doi.org/10.1007/978-1-4471-3913-3\\_4](https://doi.org/10.1007/978-1-4471-3913-3_4)
- Ko, T. J., & Cho, D. W. (1994). Cutting state monitoring in milling by a neural network. *International Journal of Machine Tools and Manufacture*, 34(5), 659–676. [https://doi.org/10.1016/0890-6955\(94\)90050-7](https://doi.org/10.1016/0890-6955(94)90050-7)
- Kohonen, T. (1982). Self-organized formation of topologically correct feature maps. *Biological Cybernetics*, 43(1), 59–69. <https://doi.org/10.1007/BF00337288>
- Kohonen, T. (1990). The Self Organizing Map. *Proceedings of IEEE*, 78, 1464–1480.
- Kohonen, T. (1998). The self-organizing map. *Neurocomputing*, 21(1–3), 1–6. [https://doi.org/10.1016/S0925-2312\(98\)00030-7](https://doi.org/10.1016/S0925-2312(98)00030-7)
- Kohonen, T. (2013). Essentials of the self-organizing map. *Neural Networks*, 37, 52–65. <https://doi.org/10.1016/j.neunet.2012.09.018>
- Kohonen, T., Oja, E., Simula, O., Visa, A., & Kangas, J. (1996). Engineering applications of the self-organizing map. *Proceedings of the IEEE*, 84(10), 1358–1383. <https://doi.org/10.1109/5.537105>
- Kuo, R. J. (2000). Multi-sensor integration for on-line tool wear estimation through artificial neural networks and fuzzy neural network. *Engineering Applications of Artificial Intelligence*, 13(3), 249–261. [https://doi.org/10.1016/S0952-1976\(00\)00008-7](https://doi.org/10.1016/S0952-1976(00)00008-7)

- Leinonen, L., Hiltunen, T., Torkkola, K., & Kangas, J. (1993). Self-organized acoustic feature map in detection of fricative-vowel coarticulation. *The Journal of the Acoustical Society of America*, *93*(6), 3468–74. Retrieved from <http://www.ncbi.nlm.nih.gov/pubmed/8326072>
- Manikopoulos, C. N. (1993). Finite state vector quantisation with neural network classification of states. *IEE Proceedings F Radar and Signal Processing*, *140*(3), 153. <https://doi.org/10.1049/ip-f-2.1993.0022>
- Martin, K. F., Brandon, J. A., Grosvenor, R. I., & Owen, A. (1986). A Comparison of in-Process Tool Wear Measurement Methods in Turning. In *Proceedings of the Twenty-Sixth International Machine Tool Design and Research Conference* (pp. 289–296). London: Macmillan Education UK. [https://doi.org/10.1007/978-1-349-08114-1\\_37](https://doi.org/10.1007/978-1-349-08114-1_37)
- Meng, D., & Pei, Z. (2014). Dynamic adaptive learning algorithm based on two-fuzzy neural-networks. *Neurocomputing*, *125*, 88–94. <https://doi.org/10.1016/j.neucom.2012.07.048>
- Nanda, T., Sahoo, B., & Chatterjee, C. (2017). Enhancing the applicability of Kohonen Self-Organizing Map (KSOM) estimator for gap-filling in hydrometeorological timeseries data. *Journal of Hydrology*, *549*, 133–147. <https://doi.org/10.1016/j.jhydrol.2017.03.072>
- Nigro, M. A., Cassano, J. J., Wille, J., Bromwich, D. H., & Lazzara, M. A. (2017). A Self-Organizing-Map-Based Evaluation of the Antarctic Mesoscale Prediction System Using Observations from a 30-m Instrumented Tower on the Ross Ice Shelf, Antarctica. *Weather and Forecasting*, *32*(1), 223–242. <https://doi.org/10.1175/WAF-D-16-0084.1>
- Oguamanam, D. C. D., Raafat, H., & Taboun, S. M. (1994). A machine vision system for wear monitoring and breakage detection of single-point cutting tools. *Computers and Industrial Engineering*, *26*(3), 575–598. [https://doi.org/10.1016/0360-8352\(94\)90052-3](https://doi.org/10.1016/0360-8352(94)90052-3)
- Olszewski, D. (2014). Fraud detection using self-organizing map visualizing the user profiles. *Knowledge-Based Systems*, *70*, 324–334. <https://doi.org/10.1016/j.knosys.2014.07.008>
- Oraby, S. E., & Hayhurst, D. R. (1991). Development of models for tool wear force relationships in metal cutting. *International Journal of Mechanical Sciences*, *33*(2), 125–138. [https://doi.org/10.1016/0020-7403\(91\)90062-8](https://doi.org/10.1016/0020-7403(91)90062-8)
- Pérez-Canales, D., Álvarez-Ramírez, J., Jáuregui-Correa, J. C., Vela-Martínez, L., & Herrera-Ruiz, G. (2011). Identification of dynamic instabilities in machining process using the approximate entropy method. *International Journal of Machine Tools and Manufacture*, *51*(6), 556–564. <https://doi.org/10.1016/j.ijmachtools.2011.02.004>
- Piastra, M. (2013). Self-organizing adaptive map: Autonomous learning of curves and surfaces from point samples. *Neural Networks*, *41*, 96–112. <https://doi.org/10.1016/j.neunet.2012.07.007>
- Potočník, P., & Govekar, E. (2017). Semi-supervised vibration-based classification and condition monitoring of compressors. *Mechanical Systems and Signal Processing*, *93*, 51–65. <https://doi.org/10.1016/j.ymsp.2017.01.048>
- Prasad, B. S., Prabha, K. A., & Kumar, P. V. S. G. (2017). Condition monitoring of turning process using infrared thermography technique – An experimental approach. *Infrared Physics & Technology*, *81*, 137–147. <https://doi.org/10.1016/j.infrared.2016.12.023>
- Rajesh, V. G., & Narayanan Namboothiri, V. N. (2010). Flank wear detection of cutting tool inserts in turning operation: application of nonlinear time series analysis. *Soft Computing*, *14*(9), 913–919. <https://doi.org/10.1007/s00500-009-0466-5>

- Rangwala, S., & Dornfeld, D. (1987). *Integration of Sensors Via Neural Networks for Detection of Tool Wear States. Intelligent and Integrated Manufacturing Analysis and Synthesis. Presented at the Winter Annual Meeting of the American Society of Mechanical Engineers.* (Vol. 25). Retrieved from <http://www.scopus.com/inward/record.url?eid=2-s2.0-0023531716&partnerID=40&md5=288a77a9e7d2817cbf2eded7e59ad2db>
- Rangwala, S., & Dornfeld, D. (1990). Sensor Integration Using Neural Networks for Intelligent Tool Condition Monitoring. *Journal of Engineering for Industry*, 112(3), 219. <https://doi.org/10.1115/1.2899578>
- Ravindra, H. V., Srinivasa, Y. G., & Krishnamurthy, R. (1997). Acoustic emission for tool condition monitoring in metal cutting. *Wear*, 212(1), 78–84. [https://doi.org/10.1016/S0043-1648\(97\)00137-3](https://doi.org/10.1016/S0043-1648(97)00137-3)
- Ravindra, H. V., Srinivasa, Y. G., & Krishnamurthy, R. (1993). Modelling of tool wear based on cutting forces in turning. *Wear*, 169(1), 25–32. [https://doi.org/10.1016/0043-1648\(93\)90387-2](https://doi.org/10.1016/0043-1648(93)90387-2)
- Rizal, M., Ghani, J. A., Nuawi, M. Z., & Haron, C. H. C. (2013). The application of I-kaz<sup>TM</sup>-based method for tool wear monitoring using cutting force signal. *Procedia Engineering*, 68, 461–468. <https://doi.org/10.1016/j.proeng.2013.12.207>
- Rotberg, J., Lenz, E., & Braun, S. (1987). Mechanical Signature Analysis in Interrupted Cutting. *CIRP Annals - Manufacturing Technology*, 36(1), 249–252. [https://doi.org/10.1016/S0007-8506\(07\)62597-9](https://doi.org/10.1016/S0007-8506(07)62597-9)
- Salgado, D. R., & Alonso, F. J. (2007). An approach based on current and sound signals for in-process tool wear monitoring. *International Journal of Machine Tools and Manufacture*, 47(14), 2140–2152. <https://doi.org/10.1016/j.ijmachtools.2007.04.013>
- Sarlin, P. (2013). Self-organizing time map: An abstraction of temporal multivariate patterns. *Neurocomputing*, 99, 496–508. <https://doi.org/10.1016/j.neucom.2012.07.011>
- Schmitt, B., & Deboeck, G. (1998). Differential Patterns in Consumer Purchase Preferences using Self-Organizing Maps: A Case Study of China. In *Visual Explorations in Finance with Self-Organizing Maps* (pp. 141–156). [https://doi.org/10.1007/978-1-4471-3913-3\\_10](https://doi.org/10.1007/978-1-4471-3913-3_10)
- Segreto, T., Simeone, a., & Teti, R. (2013). Multiple sensor monitoring in nickel alloy turning for tool wear assessment via sensor fusion. *Procedia CIRP*, 12(Fig 2), 85–90. <https://doi.org/10.1016/j.procir.2013.09.016>
- Shah-Hosseini, H., & Safabakhsh, R. (2003). TASOM: A new time adaptive self-organizing map. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, 33(2), 271–282. <https://doi.org/10.1109/TSMCB.2003.810442>
- Shahin, M. a. (2014). State-of-the-art review of some artificial intelligence applications in pile foundations. *Geoscience Frontiers*, 1–12. <https://doi.org/10.1016/j.gsf.2014.10.002>
- Shao, C., Paynabar, K., Kim, T. H., Jin, J., Hu, S. J., Spicer, J. P., ... Abell, J. a. (2013). Feature selection for manufacturing process monitoring using cross-validation. *Journal of Manufacturing Systems*, 32(4), 550–555. <https://doi.org/10.1016/j.jmsy.2013.05.006>
- Shiraishi, M. (1988). Scope of in-process measurement, monitoring and control techniques in machining processes - Part 1: In-process techniques for tools. *Precision Engineering*, 10(4), 179–189. [https://doi.org/10.1016/0141-6359\(88\)90052-9](https://doi.org/10.1016/0141-6359(88)90052-9)

- Siddhpura, a., & Paurobally, R. (2013). A review of flank wear prediction methods for tool condition monitoring in a turning process. *International Journal of Advanced Manufacturing Technology*, 65(1–4), 371–393. <https://doi.org/10.1007/s00170-012-4177-1>
- Sikdar, S. K., & Chen, M. (2002). Relationship between tool flank wear area and component forces in single point turning. *Journal of Materials Processing Technology*, 128(1–3), 210–215. [https://doi.org/10.1016/S0924-0136\(02\)00453-3](https://doi.org/10.1016/S0924-0136(02)00453-3)
- Silva, R., Wilcox, S. and Reuben, R. (2006). Development of a system for monitoring tool wear using artificial intelligence techniques. *Proceedings of the Institution of Mechanical Engineers, Part B: J. Engineering Manufacture*, 220(B8), 1333–1346.
- Silva, R. G. (2010). Condition monitoring of the cutting process using a self-organizing spiking neural network map. *Journal of Intelligent Manufacturing*, 21(6), 823–829. <https://doi.org/10.1007/s10845-009-0258-x>
- Silva, R. G., Baker, K. J., Wilcox, S. J., & Reuben, R. L. (2000). the Adaptability of a Tool Wear Monitoring System Under Changing Cutting Conditions. *Mechanical Systems and Signal Processing*, 14(2), 287–298. <https://doi.org/10.1006/mssp.1999.1286>
- Silva, R. G., Reuben, R. L., Baker, K. J., & Wilcox, S. J. (1998). Tool wear monitoring of turning operations by neural network and expert system classification of a feature set generated from multiple sensors. *Mechanical Systems and Signal Processing*, 12(2), 319–332. <https://doi.org/10.1006/mssp.1997.0123>
- Skupin, A., Biberstine, J. R., & Börner, K. (2013). Visualizing the Topical Structure of the Medical Sciences: A Self-Organizing Map Approach. *PLoS ONE*, 8(3), e58779. <https://doi.org/10.1371/journal.pone.0058779>
- Stephenson, D. A., & Agapiou, J. S. (2016). Metal Cutting Theory and Practice. *Metal Cutting Theory and Practice*, 783. Retrieved from [https://www.researchgate.net/profile/Aprilian\\_Puji\\_Pranoto/publication/317081872\\_Metal\\_Cutting\\_Theory\\_And\\_Practice\\_3rd\\_by\\_D\\_A\\_Stephenson/links/592479d10f7e9b99795a45f8/Metal-Cutting-Theory-And-Practice-3rd-by-D-A-Stephenson.pdf](https://www.researchgate.net/profile/Aprilian_Puji_Pranoto/publication/317081872_Metal_Cutting_Theory_And_Practice_3rd_by_D_A_Stephenson/links/592479d10f7e9b99795a45f8/Metal-Cutting-Theory-And-Practice-3rd-by-D-A-Stephenson.pdf)
- Tsai, W.-P., Huang, S.-P., Cheng, S.-T., Shao, K.-T., & Chang, F.-J. (2017). A data-mining framework for exploring the multi-relation between fish species and water quality through self-organizing map. *Science of The Total Environment*, 579, 474–483. <https://doi.org/10.1016/j.scitotenv.2016.11.071>
- Tulkki, A. (1998). Real Estate Investment Appraisal of Buildings using SOM. In *Visual Explorations in Finance with Self-Organizing Maps* (pp. 128–140). [https://doi.org/10.1007/978-1-4471-3913-3\\_8](https://doi.org/10.1007/978-1-4471-3913-3_8)
- Venkata Rao, K., Murthy, B. S. N., & Mohan Rao, N. (2013). Cutting tool condition monitoring by analyzing surface roughness, work piece vibration and volume of metal removed for AISI 1040 steel in boring. *Measurement: Journal of the International Measurement Confederation*, 46(10), 4075–4084. <https://doi.org/10.1016/j.measurement.2013.07.021>
- Wandeto, J. M., Nyongesa, H., Rémond, Y., & Dresp-Langley, B. (2017). Detection of small changes in medical and random-dot images comparing self-organizing map performance to human detection. *Informatics in Medicine Unlocked*, 7, 39–45. <https://doi.org/10.1016/j.imu.2017.03.001>

- Wang, G., Guo, Z., & Yang, Y. (2013). Force sensor based online tool wear monitoring using distributed Gaussian ARTMAP network. *Sensors and Actuators, A: Physical*, 192, 111–118. <https://doi.org/10.1016/j.sna.2012.12.029>
- Wong, Y. S., Nee, A. Y. C., Li, X. Q., & Reisdorf, C. (1997). Tool condition monitoring using laser scatter pattern. *Journal of Materials Processing Technology*, 63(1–3), 205–210. [https://doi.org/10.1016/S0924-0136\(96\)02625-8](https://doi.org/10.1016/S0924-0136(96)02625-8)
- Xing, Y., Shi, X., Shen, F., Zhou, K., & Zhao, J. (2016). A Self-Organizing Incremental Neural Network based on local distribution learning. *Neural Networks*, 84, 143–160. <https://doi.org/10.1016/j.neunet.2016.08.011>
- Yao, Y., Fang, X. D., & Arndt, G. (1990). Comprehensive Tool Wear Estimation in Finish-Machining via Multivariate Time-Series Analysis of 3-D Cutting Forces. *CIRP Annals - Manufacturing Technology*, 39(1), 57–60. [https://doi.org/10.1016/S0007-8506\(07\)61002-6](https://doi.org/10.1016/S0007-8506(07)61002-6)
- Yao, Y., Fang, X. D., & Arndt, G. (1991). On-Line Estimation of Groove Wear in the Minor Cutting Edge for Finish Machining. *CIRP Annals - Manufacturing Technology*, 40(1), 41–44. [https://doi.org/10.1016/S0007-8506\(07\)61929-5](https://doi.org/10.1016/S0007-8506(07)61929-5)
- Yen, C. L., Lu, M. C., & Chen, J. L. (2013). Applying the self-organization feature map (SOM) algorithm to AE-based tool wear monitoring in micro-cutting. *Mechanical Systems and Signal Processing*, 34(1–2), 353–366. <https://doi.org/10.1016/j.ymsp.2012.05.001>
- Yuwono, M., Guo, Y., Wall, J., Li, J., West, S., Platt, G., & Su, S. W. (2015). Unsupervised feature selection using swarm intelligence and consensus clustering for automatic fault detection and diagnosis in Heating Ventilation and Air Conditioning systems. *Applied Soft Computing Journal*, 34, 402–425. <https://doi.org/10.1016/j.asoc.2015.05.030>

# Apêndices

**Apêndice 1 – Artigo publicado e apresentado na conferência internacional IEEE, ETFA'2017 (Emerging Technologies and Factory Automation), em Limassol - Chipre.**

# Adaptive Self-Organizing Map Applied to Lathe Tool Condition Monitoring

Silva, R.G. and Reis, R.

CLEGI – Faculdade de Engenharia e Tecnologias  
Universidade Lusíada – Norte  
Vila Nova de Famalicão, Portugal  
rsilva@fam.ulusiada.pt

**Abstract** — Condition monitoring is a fundamental part of machining as well as other manufacturing processes where generally there are parts that wear out and have to be replaced. In turning or milling tool wear level is fundamental for proper machine operation and is often accessed through the use of multiple sensors combined with a reasoning method. The unique modeling capabilities of artificial neural networks in the presence of noisy information make them best candidates for condition monitoring. This paper presents enhancements to the self-organizing map neural network where a modified learning algorithm is used to control the effectiveness of memory usage through the reduction of the learning rate in raw memory areas. Further modeling ability tests of the neural network were produced to test the influence of time as a feature in classification performance. Results show significant improvements in tool wear classification through the use of time as a feature as well as gained performance with memory learning rate control. The modified learning algorithm suggest that online continuous learning is possible by avoiding over fitting from previously seen data suggesting therefore the accommodation of new data patterns without forgetting previous ones.

**Keywords**— *Artificial Intelligence; Tool Wear; Condition Monitoring; Self-Organizing Map.*

## I. INTRODUCTION

Most manufacturing takes place with the intervention of tools that wear out and have to be replaced. One of the manufacturing operations that contributes significantly to the transformation of materials is the one by which material is shaped by material removal, such as turning or milling operations. Condition monitoring of these operations have evolved considerably in the last few years but there is still a lot of research to be conducted in order to achieve fully unmanned machining with optimized performance [1]. Such a complex process conditioned by a significant number of variables such as cutting parameters, tool and machined part materials, machine characteristics, to name a few, contribute significantly to the difficulty in determining the wear level of cutting tools and limiting the ability to perform adequate tool change operations [1], [2].

Condition monitoring has been proposed using many different approaches some of these with different success rates and limitations, such as neural networks [3], expert systems [4], genetic algorithms [5], Markov chains [6] and many others.

The work presented was partially supported by Fundação para a Ciência e a Tecnologia, Portugal. Grant Project UID/EMS/04005/2016.

Given the noisy and variable conditions during cutting a preferable approach to condition monitoring of the cutting process is the use of multiple features/sensors or attributes in order to achieve better system performance [4], [7]–[12]. To model the complexity of the cutting process it is common the use of artificial intelligence techniques such as neural networks [1], [2], [13], these outperform direct modeling through mathematical modeling given the underlying non-linear behavior of the cutting process [14]. The self-organizing map developed by Kohonen [15] has many successful applications [16]–[19] and gains advantage over other artificial neural networks since it performs learning in an unsupervised fashion, avoiding this way being forced to learn unrelated features producing a topological output that places similar classifications together [15]. Unsupervised learning is particularly suitable for an industrial environment since prior classification of data is not available or is otherwise time-consuming making it both difficult and expensive to label every single set of sampled information [20]. It should be noticed also that unsupervised learning is inherently suitable in clustering data based on intrinsic information alone whereas supervised learning, requiring that all data be labeled, generally forces often poorly process related features to match predetermined classifications degrading modeling performance and hence leading to a lower adaptability aptitude [6].

Although condition monitoring has been extensively studied, some limitations persist concerning its performance under realistic machining conditions. There are innumerable aspects that can be enhanced in order to improve tool wear classification to support fully automated factories. This paper explores the impact of two factors in the performance of tool wear level classification, namely the use of time as a decisive and intuitive factor to enhance the model created by neural networks and the control of the learning rate among neurons so that knowledge can be incorporated easily without disrupting previous apprehended information. The paper first describes the use of artificial intelligence for condition monitoring and presented enhancements and later demonstrates through experimental work the improvements introduced with this approach and its feasibility for condition monitoring.

## II. CONDITION MONITORING

Sensors, features and decision making have been extensively explored giving place to the use of a wide range of

monitoring system's arrangements that populate the literature [12], [21], [22]. Most of the systems present limitations that should be further explored and enhanced in order to overcome the given limitations. Limitations are often related to the fact that performance is higher in ideal conditions such as low noise and controlled environments and often with no sensitivity analysis regarding cutting conditions or material variability. This work addresses improvements regarding classification through the enhancement of performance in the chosen neural network modeling working with noisy data acquired under realistic conditions. Performance enhancement is achieved with a modified learning approach as well as through the use of a time attribute, an important attribute for training and modeling given the evident role of time in wearing.

#### A. Feature Extraction and Selection

Condition monitoring is often perceived as an attempt to mimic human sensory behavior in that it resembles the processing of different sensed information into an intelligent decision making process. In tool wear monitoring sensors/features have taken into account vibration, sound, temperature, force and many other sources of information. Literature demonstrates that the most feasible and less intrusive sensor are force, vibration and sound that relate more accurately to the wear process of tools [21], [23]. Following previous research results as well as considering their feasibility regarding a reduced intrusion in the cutting process it is found that the following sensors are best candidates for condition monitoring of the cutting processes such as turning or milling: force measurement through load cells on the tool holder or torrent; microphone for sound emission acquisition; and, accelerometer for vibration measurement [24]. Also the use of multiple sensors should prove to be of great value towards tool wear evaluation since the noisy character of data captured by each sensor alone would lead to certain failure of the monitoring system, [2], [25].

In terms of attributes and feasible parameters available it should also be considered the fact that Taylor's tool life equation is probably the oldest attempt to determine the extent of a tool's life time and in fact the long-term absolute machinability standard ISO 3685 [26] is defined by this equation. This equation gives an estimate of the life time of a given tool depending on the material that it is cutting as well as cutting conditions. Despite its limited use it is indisputable that both cutting speed and cutting time play a strong impact on a tool's life. Since time is determinant on the wear process of tools, and easily available in modern machines, it is straightforward its usability as an attribute for model building in neural network learning.

#### B. Adaptive Learning

The Self-Organizing map has been widely used for embedded monitoring and classification tasks presenting generally good results [16], [19], [27]. The algorithm generally performs vector quantization according to (1), where  $w_o^i$  are the weights from input neurons,  $i$ , and output neurons,  $o$ . Input vectors,  $x$ , are presented each time,  $t$ , and weights are updated following a gradient descent function that approximates outputs to inputs patterns.

$$w_o^i(t+1) = \lambda(t)\varphi_{(c,o)}(t)[x_i(t) - w_o^i(t)] \quad (1)$$

The self-organizing algorithm takes this function, resembling the Linear Vector Quantization (LVQ) algorithm, and adds topographic preservation through a neighborhood function,  $\varphi_{(c,o)}$ . This function encloses a learning rate function, that gets smaller with time,  $\lambda(t)$ , and adds a neighborhood factor that gets smaller as the distance from the winner node gets greater, according to (2).

$$\varphi_{(c,o)}(t) = e^{-\frac{\|N_c - N_o\|}{2\sigma}} \quad (2)$$

The training algorithm normally follows the standard steps given by the following pseudo code.

```

initialize weights to random values
for each epoch
    select random feature vector,  $x_i$ 
    determine the winner neuron,  $N_o$ 
    update weights in the neighborhood of  $N_o$  according to (1)
end select
end for

```

Learning algorithms concerning neural networks have been extensively explored taking into account different approaches where aspects pertaining to their structure and adaptability were considered [28], [29]. Learning new patterns or preserving old information may be achieved through variations of this algorithm for example through the creation of new neurons through time-varying structures [30], [31] or by only slowing the learning rate of neurons in the neighborhood of the winner neuron [32], [33]. The first approach implies an ever growing neural network which might never be optimized. The second approach has proven to have a better performance than traditional approaches and enables neurons that do not often get to be the winner to have an opportunity to be representative of new information. Nevertheless, in the latest approach, the learning rate still gets slower in the neighborhood of the winner node as well as, in the following learning steps, all over the network. This approach allows for an overall better topological distribution of learned patterns but does not prevent or penalize the fact of reinforced learning might occur in the same neuron repeatedly. This paper explores an alternative implementation where learning rates are also altered in the neighborhood of the winning neurons but still controlling the learning rate of the winning neuron so that it does not lose privileges gradually the more it wins so that nearby neurons get a chance to be representative of nearby patterns. The proposed enhancement for the adaptive learning mechanism reinforces the neural network's ability to assimilate new information by inhibiting the overall network from becoming unbalanced. Hence, it should provide a better rearrangement of the output map uniformly distributing representative data patterns.

Eq. (4) provides the overall individual learning rate considering each of the neurons, given the output winner node,  $o$ .

$$\lambda_o(t+1) = \eta \cdot \lambda_o(t) \cdot e^{-\frac{h_o}{t} \frac{\|N_c - N_o\|}{2\sigma}} \quad (4)$$

The combined effect results in the following learning rule for connection weights:

$$w_o^i(t+1) = \lambda_o(t) \varphi_{(c,o)} [x_i(t) - w_o^i(t)] \quad (5)$$

Local learning rate control resembles the learning taking place in different sets of neural networks for different sets of data while still contemplating the fundamental characteristic of data while still contemplating the fundamental characteristic of self-organizing maps, the topology preservation action.

### III. EXPERIMENTAL SETUP AND FEATURE EXTRACTION

The experimental work to support this study has been conducted in a modified lathe incorporating the following sensors: strain gauges to measure feed and tangential force placed in the tool holder; accelerometer to measure vertical vibration placed in torrent; and, microphone placed near the cutting edge. The layout of the experimental apparatus is presented in Fig. 1.

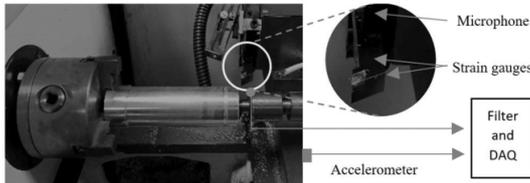


Fig. 1. Experimental Layout

#### A. Experimental Procedures

Experimental work was conducted in order to acquire sample data for this study. Data was acquired by machining a block of mild steel under realistic production conditions that consisted of a cutting speed of 350 m/min, a feed rate of 0.25 rev/min and a depth of cut of 1 mm, with a coated cemented carbide tip. The raw signals from all sensors were sampled at 20 kHz with tool wear and sensor data being acquired at intervals of 2 min, taking into account an expected tool life, for each insert, with a typical value of 15 min. Sample data was recorded for 4 inserts producing 33 sets of raw data. The length of each sample was 512 points, and these were acquired approximately in the middle of the bar.

#### B. Feature Extraction

Each 512 point record was processed to generate features used in the classification stage. A total of 12 features were extracted from the sound and vibration data: absolute deviation, average, kurtosis, skewness and the energy in the frequency bands (2.2-2.4 and 4.4-4.6 kHz) obtained from the power spectra. Two additional features were presented from the means of the feed and tangential forces. Most of the extracted features, as well as force measurement, exhibit a heavy influence of noise that could be associated with the cutting machine, interfaces, magnetic interference, and other sources not identified hereby. Data presented in Fig. 2 relative to the evolution of tool wear in 4 different tool tips are elucidative of the variability and unpredictability associated with monitoring tool wear.

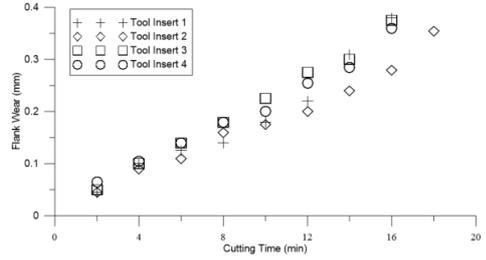


Fig. 2. Flank wear evolution for different tool tips

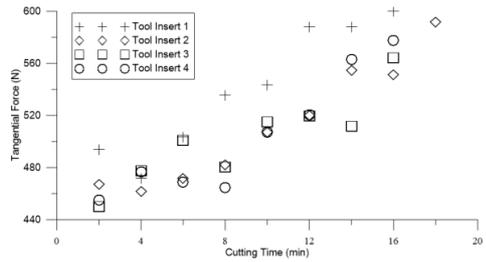


Fig. 3. Sample feature - Tangential force against cutting time

From Fig. 3 it can be seen that the tangential force has an overall consistent behavior and increases with cutting time. Although consistent it can be seen that data is noisy and a straightforward relationship to tool wear cannot be attained. The results obtained from the statistical and frequency parameters, as well as forces are somewhat difficult to interpret if considered one at a time, for each insert, as some did not appear to correlate, whilst others appeared to hold no correlation with tool wear. This can be overcome by taking into account the neural networks' ability to extract information from apparently scattered information that has an underlying behavior not transparent to traditional mathematical modeling techniques.

All other features also appeared to exhibit little correlation with flank wear. Despite the fact that no obvious correlation exists with tool wear it is thought that these attributes carry information pertaining to the evolution of cutting dynamics due to tool wear. The cutting process is well known for its complexity and it is not possible to precipitate on their importance towards tool wear classification. All features were used as attributes for training the self-organizing map.

### IV. CLASSIFICATION PERFORMANCE AND DISCUSSION

For the purpose of testing the feasibility of this approach a program was developed and optimized in Java that implements the modified self-organizing map neural network. The presented data sets pertaining to 3 of the tool tips were used for training the neural network and the remaining data pertaining to one unseen tip was used to test the network for performance. Training was conducted for 200 epochs on a batch mode for best results. Both versions, the original algorithm and the adaptive version, were implemented sideways so that the only

change was in the proposed learning rate modification. The output map is a 10 by 10 grid of neurons.

The topographic map shown in Fig. 4 presents the output mapping of the trained neural network where neurons that do not find a dataset match can be representative of some classification. The method used for interpolating the map and provide an estimate for unmapped neurons was the Kriging method used in geographical context. The contour map of Fig. 4 presents the classification map attained with the original algorithm for the self-organizing map. Contour lines represent the limits for different tool wear levels and different shades different tool wear levels. The symbols on the map, with different sizes, represent the different feature dataset pertaining to each of the samples used for training, where size correlates to wear level.

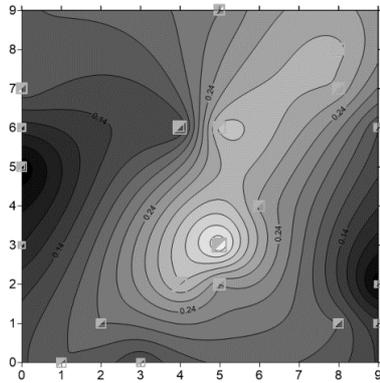


Fig. 4. Sample output map classification without adaptive learning – larger symbols represent higher flank wear values

In Fig. 4 self-organization takes place and reveals that learning occurs and different wear level representative datasets are placed in nearby regions. It can be seen that some of the contour lines are still close together revealing that leveling of the map is yet primary.

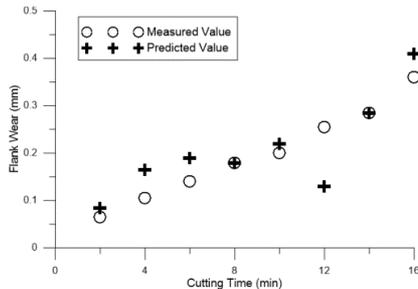


Fig. 5. Test sample classification against measured values – Straight SOM implementation without time

In Fig. 5 data is presented upon classification of unseen data feature vectors pertaining to the fourth tool tip. It can be seen that classification takes place but there are a few misclassifications that require attention. This figure presents classification results where the original self-organizing map

algorithm is used and where time is not considered during learning.

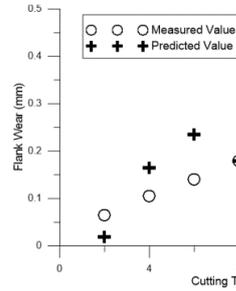


Fig. 6. Test sample classification against measured values – Straight SOM implementation with time

Results presented in Fig. 6 are for the same basic implementation of the algorithm but including the time attribute. Slight overall improvements can be observed and the impact of this feature can be better observed in the sample feature vector pertaining to data acquisition at 12 min tool life.

The new adaptive self-organizing map implementation, introducing deferred learning according to the proposed rule, is now studied and results are presented next. In Fig. 7 a contour map is shown where, when compared to Fig. 4, data sets distribution is slightly improved and contour lines are less constrained to a single space.

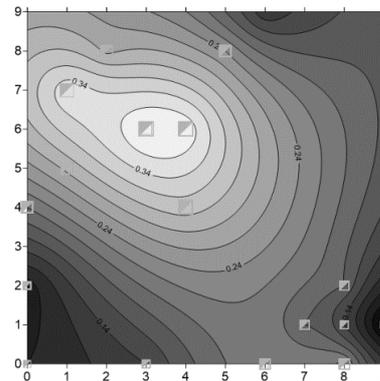


Fig. 7. Sample output map classification with adaptive learning – larger symbols represent higher flank wear values

The impact of deferred learning is significant and can be depicted in Fig. 8 and Fig. 9. In Fig. 8 there are three obvious misclassifications although only two of the sample feature vectors shown significant deviation of the predicted value from the measured one. Tests conducted with the adapted algorithm, and underlying proposed learning update rule, show an overall significant improvement and therefore the output map presents a more homogeneous distribution. The inclusion of time as an attribute, Fig. 9, has an additional impact and performance is clearly superior to that attained with the data feature vector with no time.

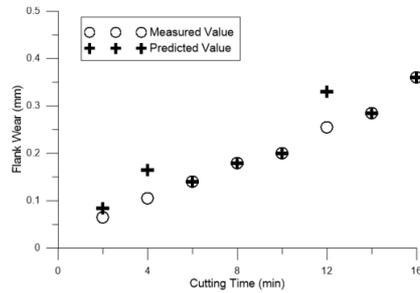


Fig. 8. Test sample classification against measured values – Adaptive SOM without time

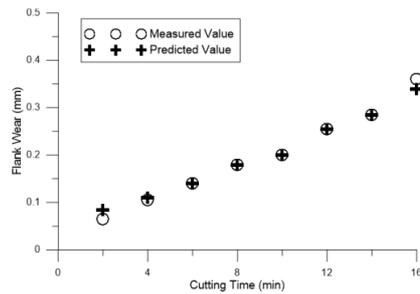


Fig. 9. Test sample classification against measured values – Adaptive SOM with time

These preliminary results suggest that the inclusion of time as a feature in the training feature vector has a significant impact. Since this attribute is readily available in modern turning centers it is advisable its use for better performance.

#### V. CONCLUSIONS AND FURTHER WORK

This article revisits the aspects pertaining to limitations of tool wear monitoring systems particularly those concerning the need for improved performance upon classification of tool wear state considering their operation under realistic industrial conditions. Data was collected from different sensors with a given set of cutting conditions using readily available instrumentation for the purpose of offline modeling and classification. For the purpose of classification a self-organizing map neural network was developed where changes on the learning rule were introduced.

The supporting monitoring features presented themselves intrinsically contaminated with noise and have no obvious relationship with tool wear as shown. Despite its noisy character classification was successfully attained in all sample feature vectors with residual error. It should be underlined that the introduction of time significantly improves classifications. The altered learning rule, contemplating inhibitory reinforcement of frequent winning neurons, has also shown good results that support the proposed enhancement. Deferred learning also improves tool wear classification as demonstrated and might suggest that the learning process taking place in humans might be also deferred allowing for a continuous learning without diminishing the ability to classify previously

learned patterns and accommodate new ones in continuous learning.

The results presented in this paper support further exploration of the proposed improvements namely through extensive experiments contemplating more sample data as well as the performance of a sensitivity analysis regarding learning parameters of the neural network and cutting conditions.

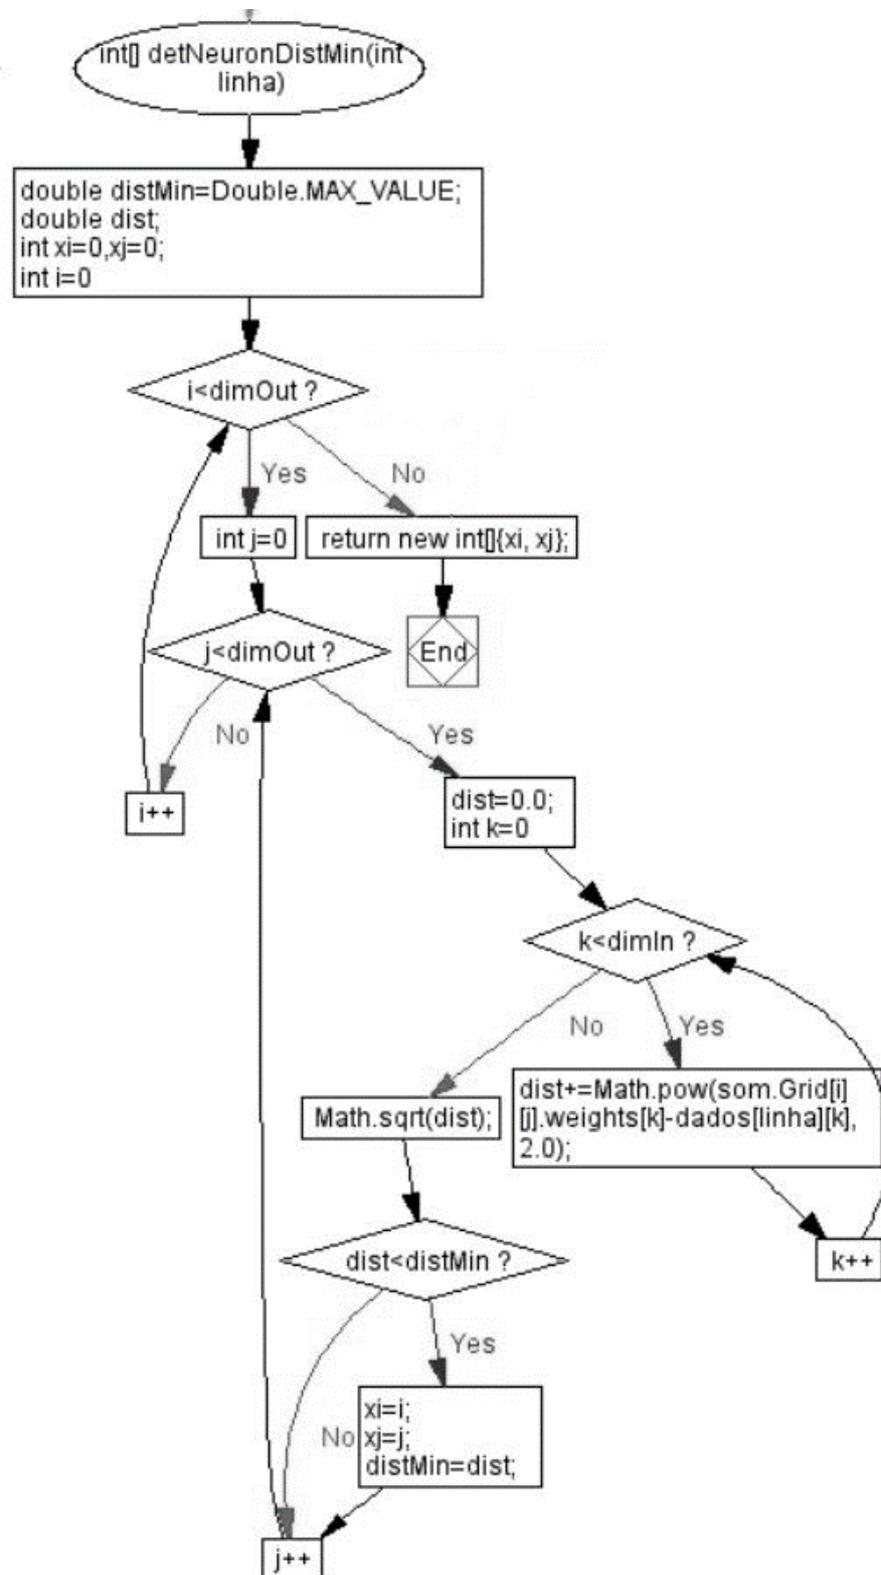
#### REFERENCES

- [1] N. Ambhore, D. Kamble, S. Chinchankar, and V. Wayal, "Tool condition monitoring system: A review," *Mater. Today Proc.*, vol. 2, no. 4–5, pp. 3419–3428, 2015.
- [2] A. Siddhpura and R. Paurobally, "A review of flank wear prediction methods for tool condition monitoring in a turning process," *Int. J. Adv. Manuf. Technol.*, vol. 65, no. 1–4, pp. 371–393, 2013.
- [3] D. Dimla and P. Lister, "On-line metal cutting tool condition monitoring," *Int. J. Mach. Tools Manuf.*, vol. 40, no. 5, pp. 769–781, 2000.
- [4] R. G. Silva, R. L. Reuben, K. J. Baker, and S. J. Wilcox, "Tool wear monitoring of turning operations by neural network and expert system classification of a feature set generated from multiple sensors," *Mech. Syst. Signal Process.*, vol. 12, no. 2, pp. 319–332, 1998.
- [5] M. Compare, F. Martini, and E. Zio, "Genetic algorithms for condition-based maintenance optimization under uncertainty," *Eur. J. Oper. Res.*, vol. 244, no. 2, pp. 611–623, 2015.
- [6] M. Yuwono, Y. Guo, J. Wall, J. Li, S. West, G. Platt, and S. W. Su, "Unsupervised feature selection using swarm intelligence and consensus clustering for automatic fault detection and diagnosis in Heating Ventilation and Air Conditioning systems," *Appl. Soft Comput. J.*, vol. 34, pp. 402–425, 2015.
- [7] T. Segreto, a. Simeone, and R. Teti, "Multiple sensor monitoring in nickel alloy turning for tool wear assessment via sensor fusion," *Procedia CIRP*, vol. 12, no. Fig 2, pp. 85–90, 2013.
- [8] C. Shao, K. Paynabar, T. H. Kim, J. Jin, S. J. Hu, J. P. Spicer, H. Wang, and J. a. Abell, "Feature selection for manufacturing process monitoring using cross-validation," *J. Manuf. Syst.*, vol. 32, no. 4, pp. 550–555, 2013.
- [9] M. S. H. Bhuiyan, I. a. Choudhury, and M. Dahari, "Monitoring the tool wear, surface roughness and chip formation occurrences using multiple sensors in turning," *J. Manuf. Syst.*, vol. 33, no. 4, pp. 476–487, 2014.
- [10] B. S. Prasad, K. A. Prabha, and P. V. S. G. Kumar, "Condition monitoring of turning process using infrared thermography technique – An experimental approach," *Infrared Phys. Technol.*, vol. 81, pp. 137–147, 2017.
- [11] G. Wang, Z. Guo, and Y. Yang, "Force sensor based online tool wear monitoring using distributed Gaussian ARTMAP network," *Sensors Actuators, A Phys.*, vol. 192, pp. 111–118, 2013.
- [12] J. a. Duro, J. a. Padget, C. R. Bowen, H. A. Kim, and A. Nassehi, "Multi-sensor data fusion framework for CNC machining monitoring," *Mech. Syst. Signal Process.*, vol. 66–67, pp. 505–520, 2016.
- [13] M. a. Shahin, "State-of-the-art review of some artificial intelligence applications in pile foundations," *Geosci. Front.*, pp. 1–12, 2014.
- [14] D. Pérez-Canales, J. Álvarez-Ramírez, J. C. Jáuregui-Correa, L. Vela-Martínez, and G. Herrera-Ruiz, "Identification of dynamic instabilities in machining process using the approximate entropy method," *Int. J. Mach. Tools Manuf.*, vol. 51, no. 6, pp. 556–564, 2011.

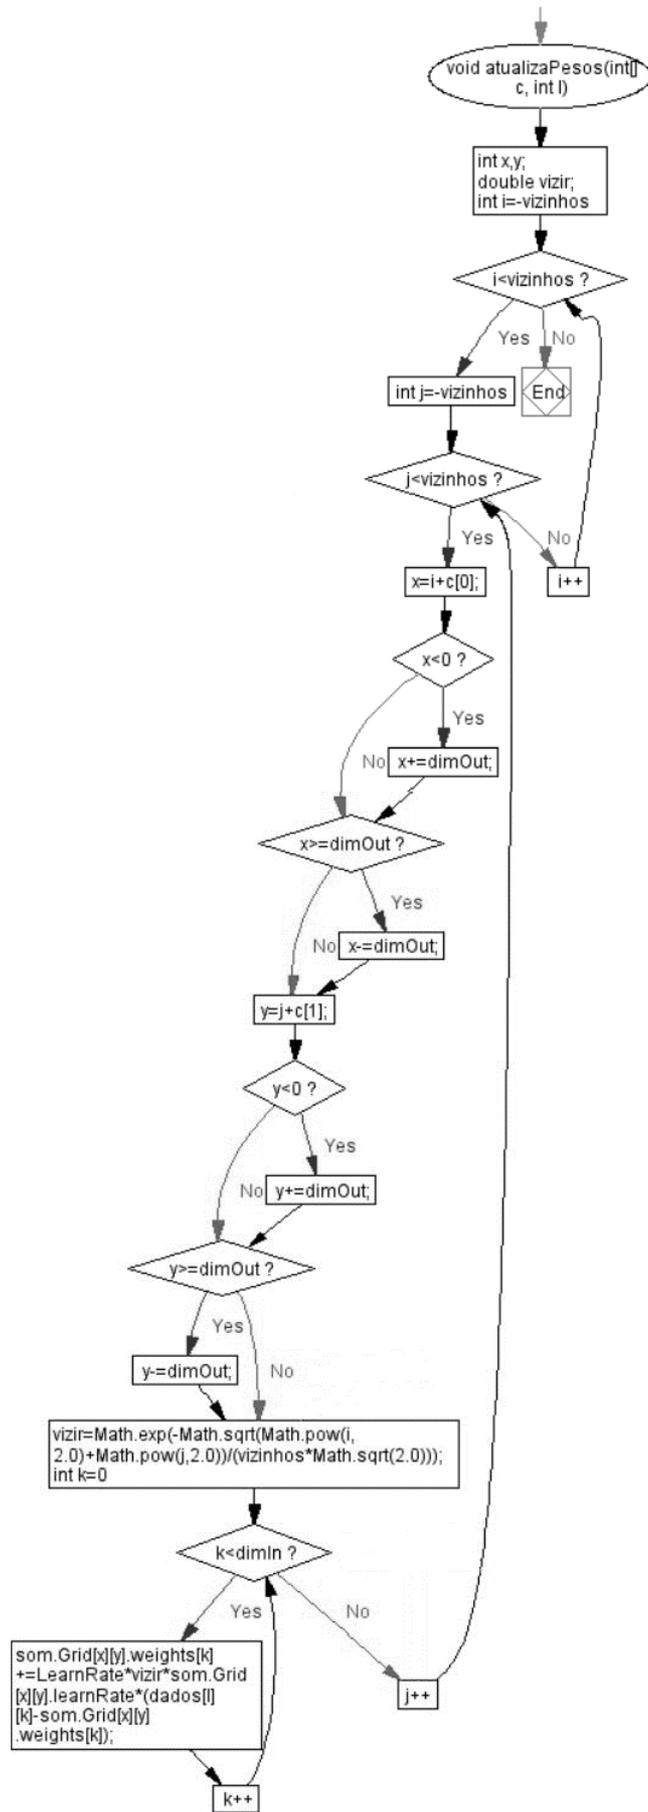
- [15] T. Kohonen, "The self organizing map," *Proc. IEEE*, vol. 78, pp. 1464–1480, 1990.
- [16] T. Kohonen, "Essentials of the self-organizing map," *Neural Networks*, vol. 37, pp. 52–65, 2013.
- [17] P. Sarlin, "Self-organizing time map: An abstraction of temporal multivariate patterns," *Neurocomputing*, vol. 99, pp. 496–508, 2013.
- [18] R. G. Silva, "Condition monitoring of the cutting process using a self-organizing spiking neural network map," *J. Intell. Manuf.*, vol. 21, no. 6, pp. 823–829, 2009.
- [19] D. Olszewski, "Fraud detection using self-organizing map visualizing the user profiles," *Knowledge-Based Syst.*, vol. 70, pp. 324–334, 2014.
- [20] P. Potočník and E. Govekar, "Semi-supervised vibration-based classification and condition monitoring of compressors," *Mech. Syst. Signal Process.*, vol. 93, pp. 51–65, 2017.
- [21] D. E. Dimla Snr. D.E., "Sensor signals for tool-wear monitoring in metal cutting operations - a review of methods," *Int. J. Mach. Tools Manuf.*, vol. 40, no. 8, pp. 1073–1098, 2000.
- [22] F. Girardin, D. Rémond, and J. F. Rigal, "Tool wear detection in milling-An original approach with a non-dedicated sensor," *Mech. Syst. Signal Process.*, vol. 24, no. 6, pp. 1907–1920, 2010.
- [23] C. L. Yen, M. C. Lu, and J. L. Chen, "Applying the self-organization feature map (SOM) algorithm to AE-based tool wear monitoring in micro-cutting," *Mech. Syst. Signal Process.*, vol. 34, no. 1–2, pp. 353–366, 2013.
- [24] R. Silva, R., Wilcox, S. and Reuben, "Development of a system for monitoring tool wear using artificial intelligence techniques," *Proc. Inst. Mech. Eng. Part B J. Eng. Manuf.*, vol. 220, no. B8, p. 1333–1346., 2006.
- [25] R. J. Kuo, "Multi-sensor integration for on-line tool wear estimation through artificial neural networks and fuzzy neural network," *Eng. Appl. Artif. Intell.*, vol. 13, no. 3, pp. 249–261, 2000.
- [26] *ISO 3685*. International Organization for Standardization, 1993.
- [27] R. G. Silva, K. J. Baker, S. J. Wilcox, and R. L. Reuben, "the Adaptability of a Tool Wear Monitoring System Under Changing Cutting Conditions," *Mech. Syst. Signal Process.*, vol. 14, no. 2, pp. 287–298, 2000.
- [28] X. Jing, "Robust adaptive learning of feedforward neural networks via LMI optimizations," *Neural Networks*, vol. 31, pp. 33–45, 2012.
- [29] D. Meng and Z. Pei, "Dynamic adaptive learning algorithm based on two-fuzzy neural-networks," *Neurocomputing*, vol. 125, pp. 88–94, 2014.
- [30] A. F. R. Araujo and R. L. M. E. Rego, "Self-organizing Maps with a Time-varying Structure," *ACM Comput. Surv.*, vol. 46, no. 1, p. 7:1–7:38, 2013.
- [31] Y. Xing, X. Shi, F. Shen, K. Zhou, and J. Zhao, "A Self-Organizing Incremental Neural Network based on local distribution learning," *Neural Networks*, vol. 84, pp. 143–160, 2016.
- [32] H. Shah-Hosseini and R. Safabakhsh, "TASOM: A new time adaptive self-organizing map," *IEEE Trans. Syst. Man, Cybern. Part B Cybern.*, vol. 33, no. 2, pp. 271–282, 2003.
- [33] M. Piastra, "Self-organizing adaptive map: Autonomous learning of curves and surfaces from point samples," *Neural Networks*, vol. 41, pp. 96–112, 2013.

**Apêndice 2 –Fluxograma do Algoritmo Desenvolvido.**

**Apêndice 2.1 – Fluxograma do Método de Cálculo da Distância Euclidiana.**



## **Apêndice 2.2 – Fluxograma do Método de Atualização dos Pesos**



Universidade Lusíada - Norte  
*Campus, Vila Nova De Famalicão*