

MONITORAMENTO DA DUREZA DE PEÇAS NO FRESAMENTO EMPREGANDO MÁQUINA DE VETOR DE SUPORTE

Karoline Conceição da Fonseca Santos

Joel Martins Crichigno Filho

Departamento de Engenharia Mecânica, Universidade do Estado de Santa Catarina, Campus Universitário, Joinville-SC

karoline.conceicao27@gmail.com, joel.crichigno@udesc.br

Resumo: Neste trabalho o algoritmo Máquina de Vetor de Suporte foi utilizado para classificar parâmetros dos sinais de pressão sonora e de corrente elétrica do motor do eixo árvore no fresamento de peças com o intuito de identificar peças em classes diferentes de dureza. Os parâmetros foram analisados no domínio do tempo. Para o sinal da corrente elétrica do motor do eixo árvore foi avaliado o valor de RMS, enquanto para o sinal de pressão sonora, os parâmetros foram o valor de pico, RMS, fator de crista e curtose. Verificou-se a eficiência da classificação e o tempo de treinamento, diminuindo os parâmetros do sinal de pressão sonora, combinado com o sinal de RMS da corrente elétrica. Foi investigada também qual o melhor kernel entre o RBF, polinomial e sigmoid que melhor se adequou à classificação. O melhor resultado, em termos de classificação, foi obtido utilizando todos os 4 parâmetros da pressão sonora em conjunto com o sinal de RMS utilizando o kernel RBF.

Palavras-chave: Monitoramento; Fresamento; Máquina de Vetor de Suporte.

1. INTRODUÇÃO

Com o surgimento da filosofia da Indústria 4.0, o monitoramento dos processos de usinagem em tempo real tem uma importância fundamental para aumentar a eficiência da indústria. Sinais gerados durante o processo de usinagem podem ser relacionados com o estados da ferramenta de corte, a máquina-ferramenta ou até mesmo com as características do material da peça. Nos últimos anos vem crescendo a preocupação na identificação do material entre lote de peças para adaptar as condições de usinagem, ou na usinagem de peças híbridas, compostas por mais de um tipo de material.

A variação no tratamento térmico em lotes diferentes de peças pode resultar na variação de dureza e com isso na usinabilidade do material. Deste modo, os resultados de qualidade da peça usinada, bem como na vida da ferramenta de corte são influenciados. Isso acontece porque o tratamento térmico influencia na microestrutura e tamanho de grão, determinando a dureza do material. Por isso é importante detectar variações da propriedade do material das peças. Diferentes abordagens foram desenvolvidas no intuito de identificar, durante a usinagem, materiais específicos, classe e subclasse do material bem como materiais em lotes diferentes de peças Lutz et al. (2021), Lutz et al. (2021)b.

Durante o processo de usinagem a medição direta ou indireta de sinais ou grandezas geradas podem ser realizadas. Na medição direta resultados mais precisos são obtidos, porém interrompe-se o processo para realizar as medições ou o sistema de medição tem influência direta no processo de usinagem. Utiliza-se, por exemplo, microscópio ótico para a medição de desgaste da ferramenta, rugosímetro para a medição da qualidade superficial de uma peça, ou dinamômetro de força. Por outro lado, na medição indireta, mede-se uma grandeza que estão correlacionadas com aquelas que se quer monitorar Mohanraj (2020). As medições são realizadas em tempo real e o processo não é interrompido, utilizam-se por sensores como: de potência, dinamômetros, acelerômetro, de temperatura, de emissão acústica, etc, Souza (2015), Kothuru (2018).

Ao se utilizar sensores para monitorar um processo, uma grande quantidade de dados são gerados, tendo estes que ser adquiridos, transmitidos, tratados e correlacionados com diferentes estados do sistema. Para aumentar a rapidez e facilitar na tomada de decisão quanto ao estado do processo, a inteligência artificial vem sendo largamente utilizada com sucesso. Nesse contexto, algoritmos de aprendizado tem atraído muita atenção, auxiliando na resolução de problemas reais, envolvendo elevado número de variáveis. Por exemplo, o reconhecimento de imagem, voz, predição da dureza de material de peças, classificação de rugosidade, dentre outros Ouadah et al. (2022).

O algoritmo máquina de vetor de suporte (SVM) se destaca como ferramenta de classificação, pois ela maximiza a capacidade de generalização e minimizar os erros Niu (2017). Dependendo da aplicação, o SVM tem um comportamento melhor que a Rede Neural Artificial (RNA) e são capazes de substituí-las. Por exemplo, Çaydas et. al.

(2012) relatou que SVM superou RNA para a previsão da rugosidade no processo de torneamento. Krishnakumar *et al.* (2018), comparou SVM, árvores de decisão, naive bayes e RNA para classificar a condição da ferramenta de corte no processo de usinagem e constatou que SVM medindo sinais de emissão acústica e vibração teve melhor desempenho. Asilturk *et al.* (2012), aplicou redes neurais e regressão vetorial de suporte (SVR) para prever a rugosidade da peça e a força de corte com base nos sinais de vibrações. Quando compararam RNA e SVR observaram ambos os modelos tiveram um bom desempenho, porém o coeficiente de determinação de SVR foi de 92,7% tendo este uma boa acurácia. Portanto, existe vários relatos na literatura que SVM tem superado RNA. Essa eficiência está relacionada com a definição dos parâmetros na fase de modelagem Niu, D. (2017), Krishnakumar et al. (2018), Kothuru et al. (2018), Asilturk et al. (2012), Borith et al. (2020).

SVM tem por objetivo, separar os dados em classes através de hiperplanos de separação usando uma função que tem como foco encontrar o classificador que minimiza o erro esperado, maximizando a margem de separação entre os pontos mais próximos. Este tem a capacidade de lidar com dados linearmente separáveis e não separáveis. SVM é um algoritmo que busca um hiperplano que separe os dados entre classes distintas tendo como foco o reconhecimento de padrões, Brusamarello et al., (2022), Negri (2013), Souza (2019). Por exemplo, ao aplicar um hiperplano, que diferencia muito bem as classes que são linearmente separáveis, a ocorrência de um hiperplano faz com que exista a separação de duas classes.

Porém, existem dados que não podem ser separados somente por hiperplanos, neste caso são SVM linearmente não separável. Para transformar esse conjunto de dados em linearmente separável é necessário aplicar uma função matemática, por exemplo, a função Kernel Brusamarello et al. (2022).

A função kernel converte o problema não separável em problema separável, baseando nas transformações de dados extremamente complexas através do mapeamento para um espaço de maior dimensão. A probabilidade de trabalhar com dados linearmente não separáveis são mais altas Scholkopf et al. (2002), Souza (2019). As funções kernel mais comuns são: sigmoidal, polinomial e função base radial (RBF). A escolha do kernel e seus hiperparâmetro pode afetar o desempenho do classificador.

Dentre esses 3 Kernels, o RBF vem se destacando na solução de problemas reais. O kernel polinomial tem a necessidade de usar o hiperparâmetro Gamma (γ) e o grau (d) fazendo com que aumente o desempenho e complexidade do classificador, Lorena, C (2007), Guimarães (2016), Souza (2019), Brusamarello et al. (2022); PANG et al. (2011). Por outro lado, o kernel sigmoidal, depende dos valores dos hiperparâmetros empregados e pode ter um comportamento parecido com kernel rbf PANG et al. (2011).

Antes de alimentar o algoritmo os dados, este têm que ser divididos em dados de treinamento e teste. O algoritmo aprende a característica do modelo com o conjunto de dados do treinamento, os dados de teste são utilizados para verificar a eficácia do modelo. Essa técnica pode ser usada tanto para classificação (classificação por categoria), quanto para regressão (preditor próximo aos dados das amostras). A aplicação prática deste trabalho consiste em determinar em tempo real, a variação de dureza do material da peça, e com isso, servir como entrada em um outro modelo para ajustar as velocidade de corte com o intuito de se manter a vida da ferramenta constante, conforme planejada.

2. MONITORAMENTO DO PROCESSO

2.1. Através da corrente elétrica

O monitoramento medindo a corrente elétrica do motor do eixo-árvore tem a vantagem de não influenciar o processo de usinagem, sendo portanto facilmente utilizado. Alguns autores investigaram a relação entre a corrente elétrica do motor do eixo-árvore e os resultados de processos. Por exemplo, Liu *et al.* (2022) demonstraram que o aumento do sinal de corrente do motor está relacionado com o desgaste da ferramenta. Silva *et al.* (2021) estudaram a potência do eixo árvore no fresamento frontal utilizando um sistema de baixo custo. Eles observaram que o aumento da profundidade de corte e do avanço levou ao aumento da potência, pois maior força de corte é necessário para remover uma maior quantidade de material.

As máquinas-ferramenta modernas apresentam motores de acionamento independentes para os movimentos de corte e avanço, com isso a potência de corte pode ser diretamente medida no motor elétrico do eixo-árvore da máquina. Segundo Alexander (2013) a corrente elétrica I em uma fase do motor trifásico pode ser calculada em função da potência de acionamento e esse, por sua vez, é proporcional à potência de corte. Desconsiderando o fator de potência do motor elétrico, o rendimento mecânico do acionamento do motor do eixo-árvore e aproximando a força de média de corte no fresamento utilizando a equação de Kinzle, a corrente do motor de acionamento do eixo árvore é proporcional à

$$I \sim \frac{K_{c11} b \bar{h}^{1-m_c} v_c}{V} \quad (2)$$

onde $K_{c1.1}$ é a pressão específica de corte, mc é expoente da equação de Kinzle, b o comprimento da aresta ativa de corte e h a espessura média do cavaco considerando os dentes engajados, v_c a velocidade de corte V é a tensão.

Da relação acima é possível observar que a corrente do motor do eixo árvore é proporcional à pressão específica de corte $K_{c1.1}$, que depende diretamente das propriedades do material usinado. Portanto, a variação da dureza do material da peça tende a alterar os valores de corrente.

2.2. Monitoramento através da pressão sonora

Os sinais sonoros gerados durante a usinagem dar indicativos do estado do processo ou da ferramenta de corte durante a remoção de material.

O engajamento do dente da ferramenta no material da peça é uma fonte sonora, gerando ruído de duas maneiras. Na primeira, o impacto do dente da fresa excita a estrutura do sistema ferramenta/peça/sistema de fixação/máquina-ferramenta fazendo com que este vibre. A vibração do sistema pode provocar uma variação nas propriedades do fluido no contorno produzindo as variações de pressão e densidade que irão provocar a propagação do som. As características dinâmicas do sistema mecânico e da força de corte são fundamentais para o surgimento de ruído no processo de corte.

Devido à característica da força de corte no fresamento, que pode gerar harmônicos e esses coincidirem com uma ou mais frequências de ressonância da estrutura, amplificando a vibração, e com isso a pressão sonora, nessas frequências. A variação de dureza da peça tende a modificar as forças de corte e com isso a amplitude das frequências de excitação, influenciando na pressão sonora, He (2022).

A Figura 1 exemplifica um sinal de força de corte no fresamento, que devido a uma baixa penetração radial, atua como uma força impulsiva, de curta duração, excitando a estrutura em uma ampla faixa de frequência. Deste modo, um harmônico ou mais, pode coincidir com uma ou mais frequências de ressonância da estrutura, amplificando a vibração, e com isso a pressão sonora, nessas frequências. A variação de dureza da peça tende a modificar as forças de corte e com isso a amplitude das frequências de excitação, influenciando na pressão sonora, He (2022).




Figura 1. Exemplo do processo de produção de um sinal de vibração simplificado (He et al. 2022).

Outra fonte sonora é devido à formação do cavaco. O efeito do atrito, da adesão e do descolamento do cavaco sobre a ferramenta, a deformação plástica do material, a fratura do cavaco, a colisão do cavaco contra a peça ou a ferramenta, bem como uma possível mudança de fase também são causadores de ruídos. Esses efeitos geram o que são chamados de “emissão acústica”, o que são entendidas como ondas elásticas que se propagam na superfície do sistema na faixa de frequência em torno de 20-2000 kHz. Segundo Pandiyan (2022) essas ondas podem ser captadas por sensores de emissão acústica instalados diretamente na estrutura do sistema, ou algumas faixas de frequência que são propagadas para o ar podem ser captadas por microfones.

A variação na dureza da peça terá influência tanto na frequência e na amplitude de vibração do som emitido Wegener (2021). Neste contexto, Kothuru *et al.* (2017) e Raja *et al.* (2011), estudaram o monitoramento da condição da ferramenta utilizando as informações adquiridas através do som. Por exemplo, Lu *et al.* (2012), desenvolveram uma técnica para o monitoramento do desgaste da ferramenta com base na análise do sinal sonoro. Eles trabalharam com

uma faixa de frequência entre 20 kHz e 80 kHz. A faixa de frequência em torno de 40 KHz foi mais apropriada para detectar a condição da ferramenta. Em contrapartida, a frequência abaixo de 20 kHz não apresentou bons resultados.

Por outro lado, Rafezi *et al.* (2012), desenvolveram uma técnica para análise do desgaste da ferramenta e observaram que os componentes de frequência menores que 10 kHz são afetados pelo desgaste da ferramenta. Eles também analisaram a influência do ruído na análise do sinal e chegaram a conclusão que o espectro de frequência do ruído nas proximidades da máquina-ferramenta tem componentes de frequência menores que 2 kHz. Zhou *et al.* (2020), investigou o desgaste da ferramenta monitorando o sinal sonoro no processo de fresamento. Esses autores chegaram à conclusão que, os parâmetros extraídos no domínio do tempo e da frequência podem ser relacionados com o desgaste da ferramenta, mostrando-se viável para monitorá-lo.

3. MATERIAIS E MÉTODOS

Os experimentos foram realizados no Laboratório Dinâmica da Usinagem na UDESC de Joinville em um centro de usinagem vertical Romi D600. A máquina-ferramenta possui rotação máxima do fuso de 10.000 rpm e potência de 15 KW. A Figura 2 apresenta o aparato experimental utilizado no qual é possível ver o conjunto peça/ferramenta, o sistema de aquisição de dados da corrente do motor do eixo-árvore e de pressão sonora.




Figura 2. Aparato experimental

Corpos de aço AISI 4340 foram utilizados neste trabalho no intuito de testar o algoritmo de Máquina de Vetor de Suporte. Este material foi utilizado porque é amplamente empregado na fabricação de eixos, bielas, virabrequins, engrenagens e peças com alta solicitação mecânica, entre outros. Além disso, é de fácil aquisição, sendo possível obter uma homogeneidade de dureza ao longo da seção transversal em grandes seções. Os corpos de provas de formato cilíndrico com diâmetro de 114,3 mm foram cortados em comprimentos de 50 mm de altura. A dureza do material, antes do tratamento térmico, variou entre 17 HRC e 20 HRC. Os mesmos foram tratados termicamente na empresa Tecnotempera. O tratamento térmico normalmente empregado para esse tipo de material é a têmpera e o revenimento foi empregado para reduzir a fragilidade.

Para a realização do tratamento por têmpera foi necessário realizar uma austenitização à uma temperatura variando de 850°C - 870 °C. O revenimento foi realizado imediatamente após a têmpera. As durezas obtidas para os corpos de prova foram 32HRC, 36HRC, 42HRC e 45HRC.

Os corpos de prova foram usinados com uma fresa de topo de diâmetro 32 mm modelo R390-032B32-11 do fabricante Sandvik Coromant, com dois inserto de metal duro do fabricante R390-11T308M-PM1010 (Sandvik Coromant), com recobrimento de TiAlN depositado pelo processo PDV (Physical Vapor Deposition). O comprimento em balanço foi de 64,5mm de comprimento. Esta ferramenta foi escolhida com o intuito de se ter um sistema o mais rígido possível para minimizar a ocorrência de vibração regenerativa.

Os parâmetros de corte utilizados para realizar os ensaios foram, velocidade de corte de v_c 200 m/min, avanço f 0,1 mm/dente, a profundidade do corte axial a_p 2mm e a profundidade radial a_e 10mm. Para o melhor aproveitamento do material dos corpos de prova, decidiu-se usinar somente 25% da circunferência. A trajetória da ferramenta foi

circular, de modo a manter a_e constante. O sentido de corte foi concordante, ou seja, inicia com espessura máxima de cavaco até essa espessura chegar ao seu valor mínimo. A Figura 3 ilustra a trajetória da ferramenta.




Figura 3. Trajetória de usinagem

Pelo fato de serem de baixo custo, ter conversor A/D, capacidade de processamento e tamanho reduzido, os microcontroladores do tipo Arduino, ESP8266, Raspberry Pi vem se tornando bastante atrativos para serem empregados no monitoramento de processos de usinagem.

Um microcontrolador pode ser considerado como um pequeno computador num único circuito integrado o qual contém um núcleo de processador, memória e periféricos programáveis de entrada e saída, Santos (2020). Uma estrutura básica de um microcontrolador pode ser descrita por um processador baseado na arquitetura RISC, memória ROM, um sistema de *clock* e uma unidade de controle para entrada e saída, conversor A/D, conversor D/A, etc Lima (2021).

Para a aquisição dos sinais monitorados foram utilizados dois microcontroladores de placa única. Decidiu-se utilizar uma placa ESP8266 NodeMCU DEVKIT 1.0. NodeMCU é uma plataforma de internet das coisas, de baixo custo e open-source. Esta placa permite, ainda, que o microcontrolador se conecte a uma rede sem fio. A placa conta com CPU 32-bit RISC Tensilica Xtensa LX106 rodando a 80 MHz, o que é o suficiente para adquirir os sinais de corrente do motor do eixo-árvore, processar e enviar os resultados. A placa conta ainda com armazenamento 4 MBytes. Um sensor de efeito hall SCT-013-100 da Beijing Yaohuadechang Electronic Co., ligada a placa ESP8266 para a medição da corrente. O sinal foi adquirido no domínio do tempo e utilizando a biblioteca EmonLib (Energy Monitoring Library) o valor de RMS foi calculado em cada ciclo, utilizando a linguagem C no arduino idle. Esse procedimento de medição de corrente utilizando arduino segue de maneira análoga ao experimento apresentado Souza *et al.* (2017). O sinal de corrente adquirido pela placa é processado, sendo calculado o valor de RMS em cada ciclo e enviado em tempo real para o PC via Wifi, utilizando o protocolo de comunicação MQTT (*MQ Telemetry Transport*).

Para a captação do sinal sonoro foi utilizado um microfone omnidirecional modelo INMP441 da InvenSense conectado diretamente a um Raspberry Pi Zero, a frequência de amostragem de 44,1 KHz.

Essa placa foi utilizada porque tem maior capacidade de processamento e pelo fato de ser possível armazenar o sinal adquirido em cartão SD instalado na própria placa. INMP441 é um microfone omnidirecional de alto desempenho que possui interfase de comunicação I2S, que é um padrão de barramento serial utilizado na conexão de dispositivos com áudio digital. O algoritmo desenvolvido por Hrisko, J. (2020), que utiliza a biblioteca Pyaudio, foi adaptado para ser utilizado nesse trabalho. Decidiu-se utilizar o sinal digital fornecido pelo microfone em escala digital. Durante o experimento, os dados da pressão sonora são gravados no cartão SD na placa. Após cada experimento esses dados são enviados para o computador via WiFi para tratamento utilizando o software Python.

A estratégia de processamento de sinal empregada neste trabalho consiste em filtrar, segmentar e extrair parâmetros do sinal medidos. Na primeira etapa, a filtragem digital é empregada para evitar os ruídos de alta frequência e as oscilações do sinal, provocado por algum evento mecânico transitório, tais como, quebra de uma aresta ou variação da dureza da peça em determinados pontos. O sinal então deve ser segmentado, com o intuito de facilitar a análise. O mesmo intervalo de tempo, ou número de amostras é escolhido. Nesses segmentos ou janelas, são calculados os parâmetros que serão relacionados com o processo, podendo esses ser no domínio do tempo ou da frequência.

As condições de corte foram as mesmas para os quatro corpos de prova. A região utilizada para análise, foi a qual a ferramenta se encontrava em regime, ou seja, no período em que se manteve constante, em torno da metade da trajetória. Nesse intervalo, 8 janelas de dados dos sinais de pressão sonora foram escolhidas. Valores de RMS da corrente elétrica correspondentes nesses intervalos também foram considerados.

Para a implementação do SVM foi necessário definir a função kernel mais adequado (polinomial, RBF e sigmoide) e seus hiperparametro. Em relação a aplicação da função kernel avaliou o desempenho do classificador através da matriz de confusão e a métrica aplicadas foi acurácia. Além disso, analisou a quantidade de atributos com melhor desempenho tais como, RMS da corrente combinado valor de pico, RMS, fator de crista e curtose da pressão sonora com 5 atributos, 4 atributos (RMS da corrente, valor de pico, RMS e curtose da pressão sonora), 3 atributos (RMS da corrente, valor de pico, e curtose da pressão sonora) e 2 atributos (RMS da corrente e curtose da pressão sonora).

O método adotado para avaliar o desempenho do classificador SVM sucedeu através da matriz de confusão e a métrica aplicada foi a acurácia. Por exemplo, na Figura 4 nota-se uma matriz de confusão, os elementos da diagonal principal representam os dados classificados corretamente e todos os elementos fora da diagonal principal que tiveram previsões incorretas.

Figura 4 – Matriz de Confusão para classificação multiclasse.

		Classe real			
		Classe 1	Classe 2	Classe 3	Classe 4
Classe prevista	Classe 1	Classificação Correta	Classificação incorreta	Classificação incorreta	Classificação incorreta
	Classe 2	Classificação incorreta	Classificação Correta	Classificação incorreta	Classificação incorreta
	Classe 3	Classificação incorreta	Classificação incorreta	Classificação Correta	Classificação incorreta
	Classe 4	Classificação incorreta	Classificação incorreta	Classificação incorreta	Classificação Correta

A categorização dos dados para auxiliar no treinamento foi definida como padrão, nível de dureza A (32 HRC), B (36 HRC), C(32 HRC), e D). Além disso, o material empregado foi o aço 4340 e para implementação do SVM foi utilizado o Orange Canvas com a linguagem em Python.

3. RESULTADOS

Os valores dos parâmetros calculados da corrente e pressão sonora estão numa faixa ampla de valores, o que pode causar problemas para o treinamento da SVM. Por isso, foram normalizados para valores entre 0 e 1. Além disso, o treinamento foi realizado considerando o total dos cinco parâmetros extraídos dos sinais, tais como: RMS da corrente, valor de pico, RMS, fator de crista e curtose da pressão sonora. Foi empregando o Kernel RBF e sigmoid com os hiperparâmetro $C = 100$ e o $\gamma = 0,01$ e $C = 1$ e $\gamma = 0,01$ respectivamente. Na Tabela 1 é possível observar a matriz de confusão aplicando o Kernel RBF.

Tabela 1– Matriz de confusão da validação para o modelo com cinco atributos aplicando a função Kernel RBF

	A	B	C	D
A	6	0	0	0
B	0	5	1	0
C	0	0	6	0
D	0	0	0	5

Nota-se na Tabela 1 que o classificador obteve um erro ao categorizar o nível de dureza entre B e C, os dados com característica de B foram categorizados como C. Ao aplicar os mesmos *dataset* empregando a função Sigmoid, quantidade de erros foi maior quando comparado a RBF, como pode ser observado na Tabela 2.

Tabela 2 – Matriz de confusão para o modelo com cinco atributos aplicando a função Kernel Sigmoid.

	A	B	C	D
A	6	0	0	0
B	0	6	0	
C	0	3	3	0
D	0	0	0	5

Ainda sobre a Tabela 2 percebe-se que, o classificador obteve 3 erros ao categorizar o nível de dureza entre B e C, 3 amostras de C foram reconhecidas como B. Portanto, existe uma maior dificuldade em distinguir entre os níveis B e C. Isso pode ter ocorrido pois, foi empregado Sigmoid, existiu uma diminuição na acurácia tendo maior erro quando comparado RBF com os cinco parâmetros estatísticos. Com a metodologia aplicada utilizando RBF, o classificador obteve uma acurácia de 96%. Por outro lado, com Sigmoid a acurácia de 87%.

Na Tabela 3 é possível observar a matriz de confusão aplicando o Kernel polinomial utilizando os parâmetros RMS da corrente e valor de pico, RMS, fator de crista, curtose da pressão sonora e os hiperparâmetro $C = 1$; $\gamma = 0,01$ e $degree = 3$.

Tabela 3 – Matriz de confusão para o modelo com cinco atributos aplicando a função Kernel polinomial.

	A	B	C	D
A	6	0	0	0
B	0	5	1	
C	0	3	3	0
D	0	0	0	5

Da Tabela 3 é possível observar a quantidade de dados classificados corretamente que estão localizados na diagonal principal resultando em uma acurácia de 88%. Nota-se classificador teve dificuldade em tentar categorizadas entre os níveis de dureza B e C sendo que das 6 amostras de C, 3 foram categorizar como B e uma de B classificada como C. Desta forma, ao analisar a função Kernel aplicando cinco atributos, o que teve melhor desempenho na classificação das classes foi a RBF.

Investigado agora a influência da diminuição dos parâmetros estatísticos extraídos da pressão sonora sobre a classificação da SVM. Para isso foi utilizado o Kernel que melhor desempenho foi o RBF, com os hiperparâmetro $C = 100$ e $\gamma = 0,01$. Ao aplicar RMS da corrente e o valor de pico, RMS, e curtose da pressão sonora o classificador obteve uma acurácia de 87%. Na Tabela 4 é apresentada a matriz de confusão do erro.

Tabela 4 – Matriz de confusão para o modelo com quatro atributos aplicando a função kernel RBF

	A	B	C	D
A	5	1	0	0
B	1	5	0	
C	0	2	4	0
D	0	0	0	5

Com esta configuração foram obtidos 3 erros, 2 erro ao categorizadas o nível de dureza entre A e B, 1 amostra com característica de A foi reconhecido como B e uma de B foi classificado como A. Além disso, das 6 amostras de C uma foi categorizada como B e das 5 amostras de D todas foram classificadas corretamente. Portanto, houve dificuldade em distinguir o nível A, B e C ao aplicar 4 parâmetros estatísticos resultado em uma menor acurácia quando comparado com cinco atributos aplicando a função Kernel RBF.

Removendo ainda o valor de pico do treinamento, restando somente a curtose e o RMS do sinal de pressão sonora com o RMS da corrente do motor do eixo-árvore. Na Tabela 5 nota-se a matriz confusão para o classificador utilizando os quatro atributos, obtendo 4 erros ao categorizar por nível de dureza.

É possível observar que uma das amostras de A foi classificada como B, uma de B categorizados como A e das 6 amostras de C 4 foram classificadas corretamente e duas de C classificada como nível de dureza de B. Portanto, houve dificuldade em distinguir o nível A, B e C. Com isso, a acurácia foi de cerca de 84%. O baixo rendimento da precisão e da acurácia pode ter ocorrido devido à escolha dos parâmetros estatísticos ou a quantidade de atributos.

Tabela 5 – Matriz de confusão da validação para o modelo com três atributos aplicando a função kernel RBF

	A	B	C	D
A	5	1	0	0
B	1	5	0	0
C	0	2	4	0
D	0	0	0	2

A Tabela 6 apresenta a matriz de confusão empregando RMS da corrente e curtose da pressão sonora. É possível observar que obteve 5 erros. Sendo que, uma amostra de A foi reconhecida como B, das duas amostras de B uma foi classificada como A e a outra como C e duas amostras de C foram categorizadas como B chegando a uma acurácia de 80%.


Tabela 6 – Matriz de confusão da validação para o modelo com dois atributos aplicando a função kernel RBF

	A	B	C	D
A	5	1	0	0
B	1	4	1	0
C	0	2	4	0
D	0	0	0	5

Percebe-se que a quantidade de parâmetros estatísticos no domínio do tempo com o tipo da função Kernel aplicada influência na classificação. Nota-se que quanto maior a quantidade de atributos maior o impacto. Com cinco atributos aplicando a função kernel RBF teve o melhor resultado quando comparado com a quantidade de atributos, chegando a obter 96% de acurácia. Além disso, quando se aplicou 4 atributos o classificar obteve 87% de acurácia e por fim com 2 atributos 80% de acurácia. Portanto, fica evidente que a quantidade de atributos influencia na confiabilidade dos resultados.

Uma questão importante é analisar a influência do número de parâmetros no tempo de treinamento da SVM. Para eliminar o efeito do hardware na velocidade de processamento, o tempo foi normalizado em relação ao obtido com 2 parâmetros. A Figura 5 mostra o tempo de treinamento normalizado em função do número de atributos utilizados. Dela, observa-se que aumentando o número de atributos, maior o tempo para treinamento. Quando a rede SVM foi treinada utilizando 5 atributos o tempo aumentou cerca de 18 % em relação ao treinamento da SVM utilizando 2 atributos, o que é aceitável dada a acurácia e a precisão obtidas.

Figura 5 – Tempo de treinamento para função kernel RBF.



Diante disso, a eliminação dos recursos no modelo SVM teve efeito na classificação, sendo que o melhor *dataset* resultou com a acurácia de 96%. É visível quando aumentar a quantidade de atributos o desempenho do classificador aumenta, esse resultado é devido a quantidade de informações relevantes na categorização das classes.

Com a análise dos resultados ao comparar a quantidade de atributos, utilizou para validação dos resultados a função kernel RBF com 5 atributos. Pode-se constatar que das 7 amostras para validação obteve 28,6% de erro, na Tabela 7 nota-se a matriz de confusão da validação, das 2 amostras de C a mesma foi categorizada como A.

Tabela 7 – Matriz de confusão da validação para o modelo com dois atributos aplicando a função kernel RBF

	A	B	C	D
A	2	0	0	0
B	0	1	0	
C	2	0	0	0
D	0	0	0	2

4. CONCLUSÃO

Aplicação de SVM para auxiliar no monitoramento da dureza de peça utilizando os dados do sinal corrente do motor do eixo-árvore e pressão sonora apresentou um ótimo desempenho. Diante dos resultados adquiridos ao empregar as funções kernel RBF, polinomial e sigmoid, o menor erro obtido foi com a função kernel RBF utilizando os hiperparâmetro $C = 100$ e o $\gamma = 0,01$. Portanto, o algoritmo teve bom desempenho para auxiliar na tomada de decisão no processo de usinagem visto que, ao empregar 5 atributos foi alcançado 96% de acurácia e 1 erro ao categorizar entre classe B e C, notando a eficácia na escolha dos parâmetros estatísticos no domínio do tempo no algoritmo. Ao empregar 5 atributos foi alcançado 96% de acurácia e 1 erro ao categorizar entre a classe B e C. além disso, foi possível notar que quanto menor a quantidade de atributo, menor a acurácia e maior a dificuldade de distinguir os dados por categoria. Em relação ao tempo necessário para treinar a SVM utilizando todos os parâmetros extraídos do sinal da pressão sonora, é observado um aumento de somente 18% quando é utilizado somente dois parâmetros. Diante disso, a proposta de trabalho pode facilitar a tomada de decisão durante o processo de fabricação pois, a mesma pode auxiliar não somente no processo de predição, mas também na classificação da dureza do material da peça e com isso no ajuste das condições de corte para se obter um mínimo desgaste da ferramenta de corte.

6. AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001. Estende-se ainda os agradecimentos à FAPESC no atendimento a pesquisa pelo edital PAP/FAPESC Nº 2019TR779.

7. REFERÊNCIAS

- ASILTURK, I; KAHRAMANLI, H; MOUNAYRI, H El. Prediction of cutting forces and surface roughness using artificial neural network (ann) and support vector regression (svr) in turning 4140 steel. **Materials Science and Technology**, Taylor & Francis, v. 28, n. 8, p. 980–986, 2012.
- BORITH, Taing et al. Prediction of machine inactivation status using statistical feature extraction and machine learning. **Applied Sciences**, Multidisciplinary Digital Publishing Institute, v. 10, n. 21, p. 7413, 2020.
- BRUSAMARELLO, Beatriz et al. **Deteção de falhas em rolamentos de motores de indução trifásicos baseada em máquina de vetores de suporte e redes de Bragg em fibra óptica**. Dissertação (Mestrado) — Universidade Tecnológica Federal do Paraná, 2022.
- ÇAYDA, S, Ula, s; EKICI, Sami. Support vector machines models for surface roughness prediction in cnc turning of aisi 304 austenitic stainless steel. **Journal of intelligent Manufacturing**, Springer, v. 23, n. 3, p. 639–650, 2012.
- GUIMARAES, Ana Paula Alves. **Utilização do algoritmo de aprendizado de máquinas para monitoramento de falhas em estruturas inteligentes**. Universidade Estadual Paulista (UNESP), 2016.
- HE, Dan; NI, Zexing; WANG, Xiufeng. Online grinding chatter detection based on minimum entropy deconvolution and autocorrelation function. **The International Journal of Advanced Manufacturing Technology**, Springer, p. 1–11, 2022.
- KOTHURU, Achyuth; NOOKA, Sai Prasad; LIU, Rui. Audio-based tool condition monitoring in milling of the workpiece material with the hardness variation using support vector machines and convolutional neural networks. **Journal of Manufacturing Science and Engineering**, American Society of Mechanical Engineers, v. 140, n. 11, p. 111006, 2018.

KRISHNAKUMAR, P; RAMESHKUMAR, K; RAMACHANDRAN, KI. Machine learning based tool condition classification using acoustic emission and vibration data in high speed milling process using wavelet features. **Intelligent Decision Technologies**, IOS Press, v. 12, n. 2, p. 265–282, 2018.

LORENA, Ana Carolina; CARVALHO, Andre CPLF De. Uma introducao as support vector machines. **Revista de Informatica Teorica e Aplicada**, v. 14, n. 2, p. 43–67, 2007.

NEGRI, Rogerio Galante. **Máquina de Vetores de Suporte Adaptativa ao Contexto: formalização e aplicações em Sensoriamento Remoto**. Tese (Doutorado) — (Computação Aplicada)-Instituto Nacional de Pesquisas, 2013.

NIU, Dongxiao; DAI, Shuyu. A short-term load forecasting model with a modified particle swarm optimization algorithm and least squares support vector machine based on the denoising method of empirical mode decomposition and grey relational analysis. **Energies**, Multidisciplinary Digital Publishing Institute, v. 10, n. 3, p. 408, 2017.

OUADAH, Abdelfettah; ZEMMOUCHI-GHOMARI, Leila; SALHI, Nedjma. Selecting na appropriate supervised machine learning algorithm for predictive maintenance. **The International Journal of Advanced Manufacturing Technology**, Springer, v. 119, n. 7, p. 4277–4301, 2022.

PANG, Hong-xia et al. Novel linear search for support vector machine parameter selection. **Journal of Zhejiang University SCIENCE C**, Springer, v. 12, n. 11, p. 885–896, 2011.

SCHOLKOPF, Bernhard et al. **Learning with kernels: support vector machines, regularization, optimization, and beyond**. [S.l.]: MIT press, 2002.

SOUZA, Jusley da Silva. **Análise de atributos de classificação para o diagnóstico de falhas em rolamentos baseado em SVM**. Dissertação (Mestrado)—Universidade Federal do Para, 2019 b.

WORKPIECE HARDNESS MONITORING IN MILLING USING SUPPORT VECTOR

Karoline Conceição da Fonseca Santos

Joel Martins Crichigno Filho

Departamento de Engenharia Mecânica, Universidade do Estado de Santa Catarina, Campus Universitário, Joinville-SC

karoline.conceicao27@gmail.com, joel.crichigno@udesc.br

Abstract. *In this work, the Support Vector Machine algorithm was used to classify parameters of sound pressure signals and electric current from the spindle motor in milling parts in order to identify parts in different classes of hardness. The parameters were analyzed in the time domain. For the electrical current signal of the spindle motor, the RMS value was evaluated, while for the sound pressure signal, the parameters were the peak value, RMS, crest factor and kurtosis. The efficiency of the classification and the training time were verified, decreasing the parameters of the sound pressure signal, combined with the RMS signal of the electric current. It was also investigated which is the best kernel among the RBF, polynomial and sigmoid that best suited the classification. The best result, in terms of classification, was obtained using all 4 sound pressure parameters together with the RMS signal using the RBF kernel.*

Keywords: *Monitoring; Milling; Support Vector Machine*

RESPONSIBILITY NOTICE

The author(s) is (are) the only responsible for the printed material included in this paper.