

**UNIVERSIDADE FEDERAL DE SÃO CARLOS - UFSCar
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA - CCET
DEPARTAMENTO DE ENGENHARIA MECÂNICA - DEMec**

JUAN WESLEY DOS SANTOS

**PREVISÃO DA RUGOSIDADE SUPERFICIAL DE AÇOS
ENDURECIDOS ATRAVÉS DE REDE NEURAL ARTIFICIAL**



São Carlos - SP
2023

JUAN WESLEY DOS SANTOS

**PREVISÃO DA RUGOSIDADE SUPERFICIAL DE AÇOS
ENDURECIDOS ATRAVÉS DE REDE NEURAL ARTIFICIAL**

Trabalho de conclusão de curso apresentado ao curso de graduação em Engenharia Mecânica da Universidade Federal de São Carlos, para obtenção do título de bacharel em Engenharia Mecânica.

Orientador: Prof. Dr. Armando Ítalo Sette Antonialli

São Carlos - SP

2023



FUNDAÇÃO UNIVERSIDADE FEDERAL DE SÃO CARLOS

COORDENAÇÃO DO CURSO DE ENGENHARIA MECÂNICA - CCEMec/CCET

Rod. Washington Luís km 235 - SP-310, s/n - Bairro Monjolinho, São Carlos/SP, CEP 13565-905

Telefone: (16) 33519703 - <http://www.ufscar.br>

DP-TCC-FA nº 13/2023/CCEMec/CCET

Graduação: Defesa Pública de Trabalho de Conclusão de Curso

Folha Aprovação (GDP-TCC-FA)

FOLHA DE APROVAÇÃO

JUAN WESLEY DOS SANTOS

PREVISÃO DA RUGOSIDADE SUPERFICIAL DE AÇOS ENDURECIDOS ATRAVÉS DE REDE NEURAL ARTIFICIAL

Trabalho de Conclusão de Curso

Universidade Federal de São Carlos – Campus São Carlos

São Carlos, 05 de abril de 2023

ASSINATURAS E CIÊNCIAS

Cargo/Função	Nome Completo
Orientador	Armando Ítalo Sette Antonialli
Membro da Banca 1	Hugo Emanuel de Andrade Costa
Membro da Banca 2	Joao Vitor de Carvalho Fontes



Documento assinado eletronicamente por **Armando Ítalo Sette Antonialli, Docente**, em 05/04/2023, às 16:25, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Joao Vitor de Carvalho Fontes, Docente**, em 05/04/2023, às 16:25, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site <https://sei.ufscar.br/autenticacao>, informando o código verificador **0992836** e o código CRC **E0863FA8**.

Referência: Caso responda a este documento, indicar expressamente o Processo nº 23112.010297/2023-

Dedico este trabalho a minha
família, agradeço-os por todo o apoio e carinho
durante essa jornada.

Agradecimentos

Agradeço a minha família, pelo apoio durante toda a graduação, principalmente nos momentos de dificuldade.

Aos meus amigos, Rafael Faria, Rodrigo Jun e Lucas Brilhante por todo apoio durante os 5 anos de graduação, seja em trabalhos, provas ou até mesmo durante os momentos de diversão, com certeza foram um pilar fundamental para meu sucesso.

Ao meu amigo Gabriel Cioffi, que além de me ajudar no ambiente acadêmico, foi um grande amigo me ajudando em momentos difíceis pessoais durante esses últimos anos, hoje o considero como um irmão de sangue.

Ao Prof. Dr. Armando Ítalo Sette Antonialli, por ter aceito o desafio de ser meu orientador, por sempre ser paciente e prestativo quando solicitado e pelos momentos que me deu motivação para concluir o presente trabalho. Gostaria de agradecer também a todos os professores, técnicos e funcionários da UFSCar que me possibilitaram concluir minha graduação.

"Se quiser buscar realmente a verdade, é preciso que pelo menos uma vez em sua vida você duvide, ao máximo que puder, de todas as coisas."

René Descartes

Resumo

Integridade superficial é um conceito crítico no campo da engenharia mecânica, que se refere à qualidade e propriedades da superfície de um material após ter passado por um processo de fabricação. Portanto, o controle da qualidade da superfície do material é imprescindível, pois essa pode afetar de forma significativa o desempenho do mesmo, em aspectos como: resistência à fadiga, resistência ao desgaste, resistência à corrosão e propriedades mecânicas. O foco do presente trabalho foi desenvolver e treinar uma rede neural artificial para que essa seja capaz de prever a rugosidade superficial de um aço endurecido após torneamento cilíndrico, a partir de sua dureza e parâmetros de usinagem. Além disso, estudou-se o comportamento da rede neural para diferentes iterações e conjuntos de dados com o objetivo de otimizar o resultado. Para a validação da rede neural, foram usados dados experimentais obtidos anteriormente pelo grupo de pesquisa, para o Aço ferramenta O1. Por fim, foi possível desenvolver uma rede neural artificial, baseada em dados de vários aços endurecidos, encontrados na literatura, o que resultou em uma estimativa para rugosidade superficial do aço ferramenta O1, com erro aproximado de 20% e ainda foi possível determinar que a melhor combinação entre o volume de dados para treinamento e validação da rede neural está entre 45-60%.

Palavras-chave: Torneamento. Simulação. Machine Learning. Rugosidade. Parâmetros de usinagem.

Abstract

Surface integrity is a critical concept in the field of mechanical engineering, which refers to the quality and properties of a material's surface after it has undergone a manufacturing process. Therefore, controlling the quality of the material surface is essential since it can significantly affect its performance in aspects such as fatigue strength, wear resistance, corrosion resistance, and mechanical properties. The focus of this study was to develop and train an artificial neural network to predict the surface roughness of hardened steel after cylindrical turning, based on its hardness and machining parameters. Additionally, the behavior of the neural network was studied for different iterations and datasets to optimize the results. Experimental data previously obtained by the research group for O1 tool steel were used to validate the neural network. Finally, it was possible to develop an artificial neural network based on data from various hardened steels found in the literature, resulting in an estimated surface roughness of the O1 tool steel with an approximate error of 20%. Furthermore, it was determined that the best combination of data volume for training and validating the neural network is between 45-60%.

Keywords: Turning. Simulation. Machine Learning. Roughness. Machining parameters.

Lista de Figuras

Figura 1 - Mecanismo de formação de cavaco	12
Figura 2 - Variação da máxima tensão com o ângulo de carregamento	13
Figura 3 - Limite de resistência à tração do ferro fundido para diferentes processos de usinagem	14
Figura 4 - Tensão de escoamento em função da velocidade de corte para o aço AISI 1045	15
Figura 5 - Esquema de uma rede neural multicamadas	16
Figura 6 - Representação gráfica do padrão Ra	18
Figura 7 - Variação do limite de resistência à tração e % de alongamento em função a velocidade de corte e avanço	20
Figura 8 - Limite de resistência à tração em função da velocidade de corte e avanço	20
Figura 9 - Resultado da avaliação de confiabilidade para e-commerce através de diferentes métodos	22
Figura 10 - Esquema da rede neural utilizada (3-7-7-1)	23
Figura 11 - Rede neural reestruturada para (4-4-1)	23
Figura 12 - Rede neural com 4 entradas e uma saída	25
Figura 13 - Resultados para a combinação 1	27
Figura 14 - Resultados para a combinação 2	28
Figura 15 - Resultados para a combinação 3	28
Figura 16 - Resultados para a combinação 4	29
Figura 17 - Resultado médio para cada combinação	29

Lista de Tabelas

Tabela 1 - Dados para verificação final da rede neural

26

Sumário

1. Introdução	12
1.1. Integridade superficial e comportamento mecânico	12
1.1.2. Rede neural artificial.....	15
1.2. Objetivos	17
2. Revisão Bibliográfica	18
2.1. Integridade superficial	18
2.2. Redes Neurais Artificiais Aplicadas para solução de problemas diversos	21
2.3. Redes neurais aplicadas para previsão da rugosidade superficial.....	22
3. Materiais e Métodos.....	25
4. Resultados e Discussão.....	27
5. Conclusões e Sugestões para Trabalhos Posteriores.....	31
Referências.....	32
Apêndice A – Dados utilizados para treinamento e validação da rede neural.....	34

1. Introdução

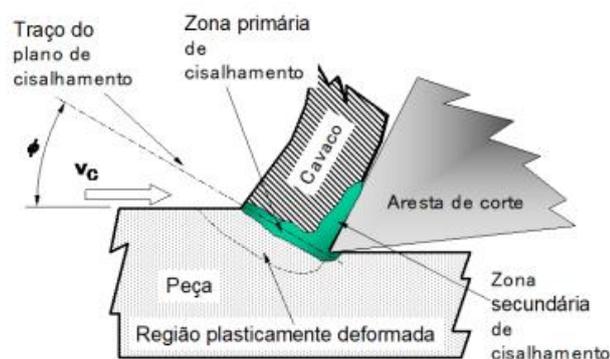
Atualmente, em função do alto consumo de recursos naturais e produção de resíduos, várias áreas de estudo se voltaram a não apenas criar algo novo, mas sim olhar de forma diferente para partes antes negligenciadas de processos, com o objetivo de aumentar sua eficiência e diminuir os rejeitos.

Trazendo esse tópico para o contexto da engenharia mecânica, mais especificamente para engenharia de manufatura, pode-se elencar o cavaco como um dos principais rejeitos dessa área. Nesse sentido, operações de usinagem estão tornando-se crescentemente evitáveis, e, exceto pela obtenção de tolerâncias apertadas, os diferentes processos de conformação mecânica se mostram como alternativa de substituição viável em se tratando da produção de grandes lotes. De qualquer forma, esses processos envolvem matrizes de aço ferramenta endurecido que, por sua vez, costumam ser usinadas. Por isso, o estudo de melhora de eficiência para a fabricação de tais matrizes se faz imperativo.

1.1. Integridade superficial e comportamento mecânico

Segundo Ferraresi (1970), a formação de cavaco ocorre a partir da penetração da ferramenta na peça, que faz com que o material seja recalçado contra a superfície de saída da ferramenta. Esse processo vai ocorrendo de forma progressiva até que o estado de tensão seja suficientemente grande para que ocorra o deslizamento de uma porção do material, que cisalha e, posteriormente, escorrega pela superfície de saída da ferramenta, como pode ser observado na Figura 1.

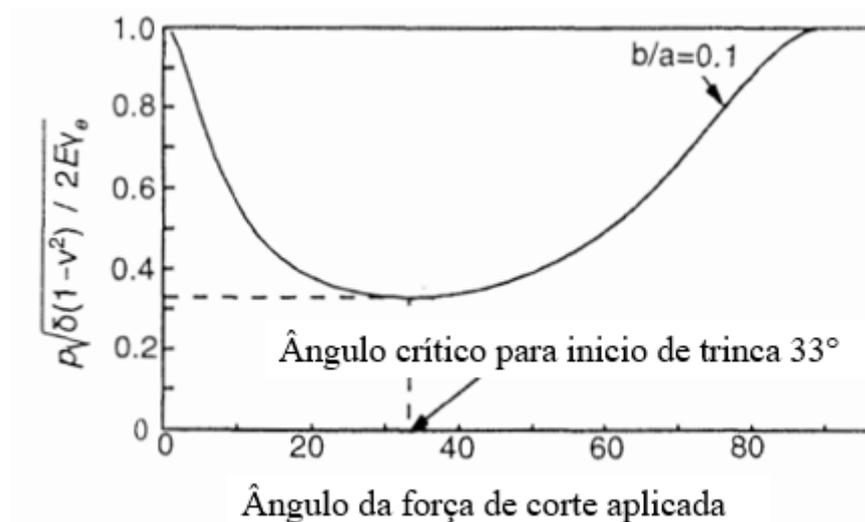
Figura 1 – Mecanismo de formação de cavaco.



Fonte: Machado *et al.* (2015).

Essa teoria explica muito bem o que ocorre para materiais dúcteis, que formam cavacos contínuos; porém, no contexto deste trabalho, trata-se de um aço endurecido e, portanto, um material frágil. A formação de cavaco não se dá por cisalhamento puro e, conseqüentemente, a tensão máxima não ocorre em um plano inclinado a 45° com relação à direção de sollicitação (ELBESTAWI et al., 1996). O grande problema para o caso de materiais frágeis é que existe um fenômeno acentuado de propagação de trincas dependendo do ângulo no qual essas tensões são aplicadas, como pode-se ver na Figura 2¹. E, ainda que o carregamento não seja máximo para um ângulo de 33°, nesse exemplo, há formação de trincas.

Figura 2 – Variação da máxima tensão com o ângulo de carregamento.



Fonte: Adaptado de Elbestawi *et al.* (1996).

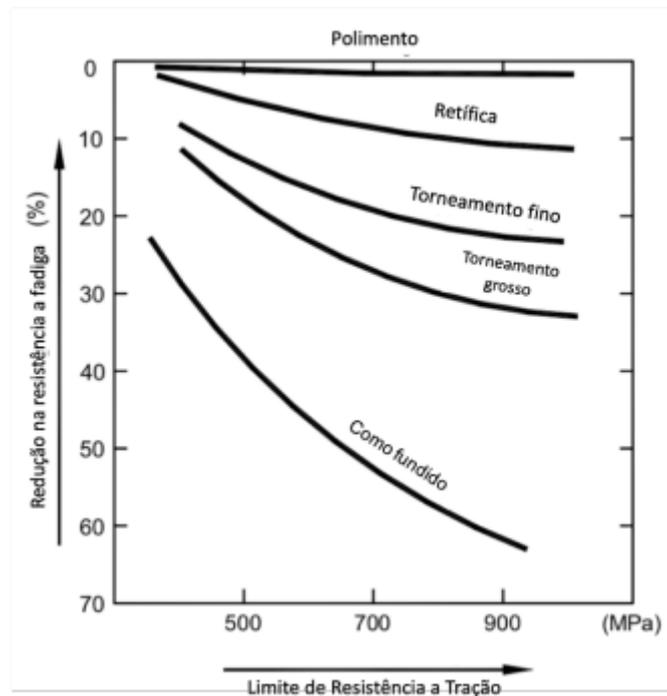
Para encontrar esse ângulo na prática, é utilizada a equação do fator de energia de tensão superficial de Sih (1974). Essa equação não será aqui explicitada pois o objetivo deste trabalho não é de fato calcular esse ângulo e sim ajustar um modelo computacional que correlacione parâmetros de entrada na usinagem com o estado de superfície do material.

Segundo Darwin et al. (2010) a integridade superficial de um material, além de influenciar em fatores geométricos, pode também alterar comportamento mecânico, como pode ser observado na Figura 3, onde é demonstrado os valores do limite de resistência à tração (LRT) para diferentes processos de acabamento para o ferro fundido, ao observar processos

¹A variáveis do eixo das ordenadas são: ρ é a pressão de corte; ν é o coeficiente de Poisson; E é o módulo de Young; δ é um elemento infinitesimal de volume; γ_e é a energia de deformação por unidade de área e b/a é a razão de raios da elipse que constitui o elemento infinitesimal.

que geram uma rugosidade maior é possível notar um LRT menor, o contrário também é verdadeiro.

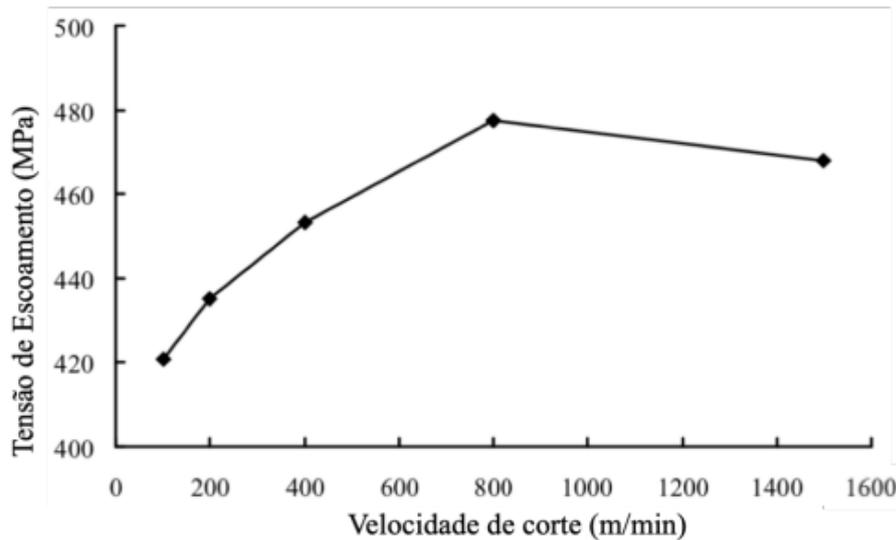
Figura 3 – Limite de resistência à tração do ferro fundido para diferentes processos de usinagem.



Fonte: Adaptado de Darvin et al. (2010).

Wang, Liu e Yang (2013), investigaram a tensão de escoamento em aço AISI 1045 (aço de médio carbono), utilizando-se a técnica de usinagem de alta velocidade em torneamento cilíndrico. Os resultados obtidos apresentados na Figura 4, vão de encontro ao Darvin et al. (2010), pois com velocidades de corte superiores, obtém-se usualmente rugosidades menores e o valor para tensão de escoamento apresenta aumento.

Figura 4 – Tensão de escoamento em função da velocidade de corte para o aço AISI 1045.



Fonte: Adaptado de Wang, Liu e Yang (2013).

Além disso, pode-se explicar a queda na tensão de escoamento após os 800 m/min, devido a alta temperatura durante o processo, o que diminui o fenômeno de encruamento do material.

Outra parcela que constitui a integridade superficial é dada pela tensão residual. Os estudos de Wu e Matsumoto (1990) e Suresh et al. (2013) demonstraram que as forças de corte elevadas necessárias para usinar aços endurecidos, em conjunto a altas temperaturas localizadas, geram tensões residuais trativas. Suresh et al. (2013) estende a análise ao efeito da resistência à fadiga, explicando que as tensões residuais trativas afetam negativamente este fator.

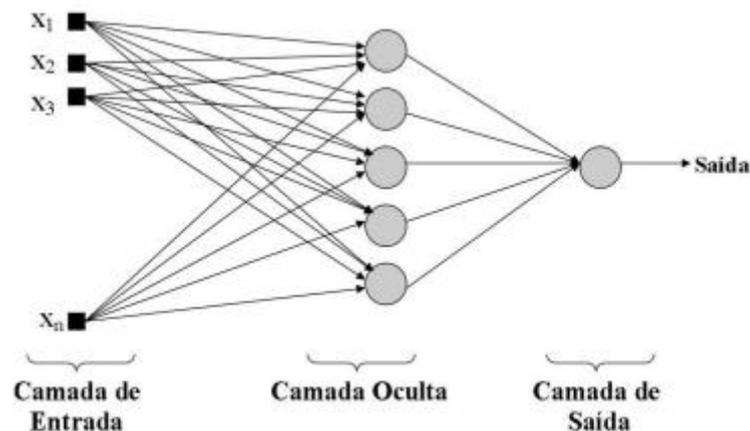
Posto isso, fica claro a importância de se estudar tal modelo, pois como explicado anteriormente durante a usinagem de materiais endurecidos suas propriedades mecânicas tanto estáticas quanto dinâmicas, podem ser drasticamente alteradas quando em comparação a materiais dúcteis.

1.1.2. Rede neural artificial

Atualmente, com recursos computacionais cada vez mais disponíveis, é possível utilizar de forma satisfatórias ferramentas cada vez mais complexas, para solução de problemas de igual complexidade. Um forte exemplo desse tipo de ferramenta, é a rede neural artificial.

Baseada no funcionamento do cérebro humano, a rede neural artificial, busca a solução de problemas complexos, utilizando a estrutura dos neurônios. Assim, a rede neural é constituída de forma geral por 3 camadas Figura 5, sendo elas, camada de entrada, camada oculta e camada de saída Gonçalves (2013). Pode-se entender as camadas como níveis de processamento da informação dentro da rede neural, e os neurônios como a quantidade de possibilidades de interação entre a entrada e a saída, ou seja, problemas mais complexos exigem mais neurônios.

Figura 5 – Esquema de uma rede neural multicamadas.



Fonte: Gonçalves (2013).

O grande desafio em uma rede neural, está na sua aprendizagem, haja visto que é necessário que o modelo de dados usado no seu treinamento seja representativo em relação à realidade do problema.

Além disso, existem formas de aprendizagem da rede, a mais comum é por comparação de erro em relação ao resultado esperado, a cada iteração a rede vai ajustando os pesos atribuídos internamente na camada oculta com o objetivo de diminuir o erro antigo até que seja alcançado o nível desejado, porém isso pode demandar um volume grande de dados, dependendo da complexidade do problema Gonçalves (2013).

No presente trabalho, estudou-se o efeito dessa variação de volume de dados nos valores de erro final, através da alteração da porcentagem de dados utilizados para treinamento e para validação da rede neural.

1.2. Objetivos

O objetivo principal do presente projeto é a elaboração e treinamento de uma rede neural capaz de prever a rugosidade superficial de aços endurecidos após torneamento cilíndrico dado sua dureza e parâmetros de usinagem tais como profundidade de corte, avanço e velocidade de corte. O objetivo geral contempla uma série de objetivos específicos, listados a seguir:

- Obter dados da literatura para treinar Rede Neural de forma satisfatória;
- Testar variações do conjunto de dados para treinamento da rede, para encontrar a faixa ideal de operação alisar os resultados dos experimentos;
- Análise dos valores de erro para dados experimentais com variação do volume de dados de treinamento.

2. Revisão Bibliográfica

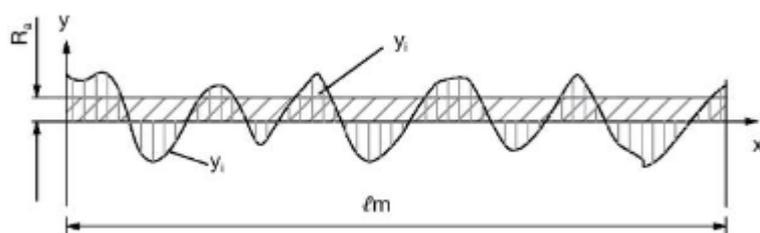
2.1. Integridade superficial

Para definir o estado de superfície dos metais é necessário dividi-lo em duas partes. A primeira parte leva em conta a geometria da superfície, e geralmente é mensurada através da rugosidade superficial. Já a segunda parte trata das alterações de propriedades do material, tais como tensão residual, dureza e microestrutura, é importante lembrar que essas propriedades são alteradas dependendo do processo pelo qual o material é submetido (JAVIDI, RIEGER e EICHLSEDER., 2008).

Em geral, os objetos são projetados idealmente, para terem uma ou mais superfícies planas, porém ao passarem por processos de usinagem, tais superfícies, são submetidas a diferentes ferramentas, taxa de avanço, velocidade de corte, temperaturas, dentre outras variações dentro da etapa de fabricação. Dessa forma, são geradas irregularidades na superfície da peça, essas irregularidades definem a rugosidade superficial da peça em questão, ou seja, a rugosidade superficial é definida micro irregularidades provenientes do processo de corte na superfície da peça (Fracaro., 2017).

Além disso, existem diversos parâmetros para se medir a rugosidade superficial, porém neste trabalho utilizaremos o padrão Ra (roughness average), que pode ser definido como a média aritmética absoluta dos valores medidos para o comprimento dos picos e vales, encontrados na peça ao longo do comprimento axial de medição (NBR ISO 4287, 2002), exemplificado na Figura 6.

Figura 6 – Representação gráfica do padrão Ra.



Fonte: Fracaro (2017).

Portanto, podemos calcular Ra, utilizando a Equação 1:

$$R_a = \frac{1}{l_m} \int_0^{l_m} |y(x)| dx \quad (1)$$

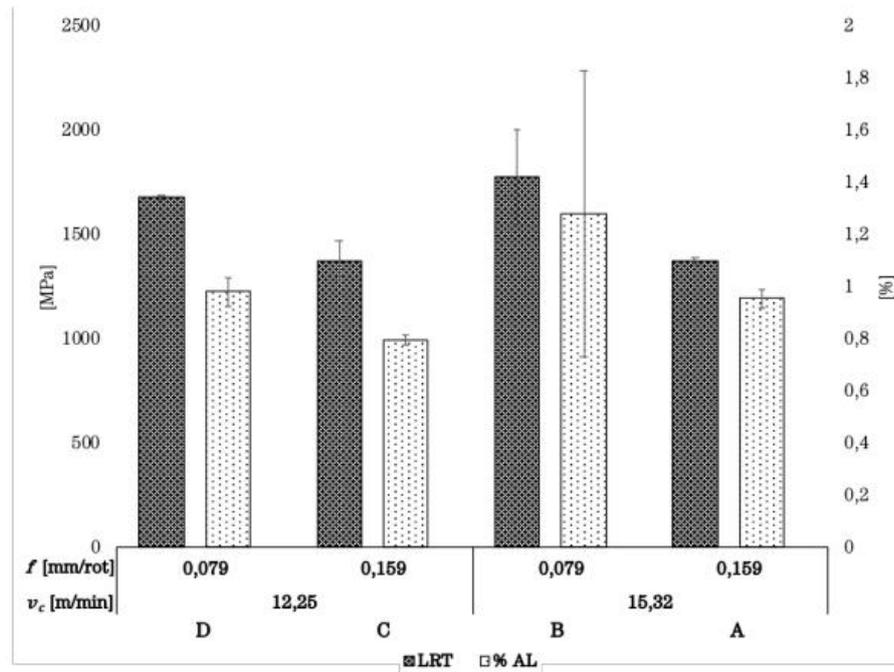
Davim, Gaitonde e Karnik (2008), estudaram os efeitos dos parâmetros de usinagem, tais como, profundidade de corte, avanço e velocidade de corte no acabamento superficial durante o torneamento cilíndrico externo de um aço de médio carbono DIN-9SMnPb28. Dessa forma, o estudo foi conduzido variando em três níveis cada parâmetro, onde foi possível concluir que, a profundidade de corte tem pouca influência sobre a rugosidade superficial da peça, em contrapartida quanto maior a velocidade de corte e menor o avanço, melhor vai ser o resultado do acabamento superficial, ou seja, um menor valor para rugosidade superficial Ra.

Em sua investigação, Bashir et al. (2018) analisou os resultados obtidos quanto ao estado de superfície do aço O1, após torneamento cilíndrico externo utilizando CBN (nitreto de cúbico de boro). Como conclusão, obteve-se que quanto maior a velocidade de corte e menor o avanço, menor serão os valores resultantes para a rugosidade superficial Ra. Sivaraman e Prakash (2020), também estudaram o torneamento do aço O1, porém utilizaram uma ferramenta com inserto de metal duro recoberto por TiAlN (Nitreto de Titânio e Alumínio), além dos parâmetros de usinagem, investigaram os efeitos do uso de fluido de corte durante o torneamento. Por fim, pode-se concluir que quanto maior a velocidade de corte, menor o avanço e utilizando a mínima quantidade de fluido, atinge-se os melhores resultados para rugosidade superficial Ra.

GANDIA (2020) em seu trabalho estudou os efeitos da rugosidade superficial em relação às propriedades mecânicas, mais especificamente o limite de resistência à tração (LRT), utilizando corpos de provas de aço O1. Portanto, para obter diferentes rugosidades superficiais para os corpos de prova, variou-se velocidade de corte, avanço e profundidade de corte, como visto anteriormente são parâmetros que influenciam diretamente no acabamento da peça.

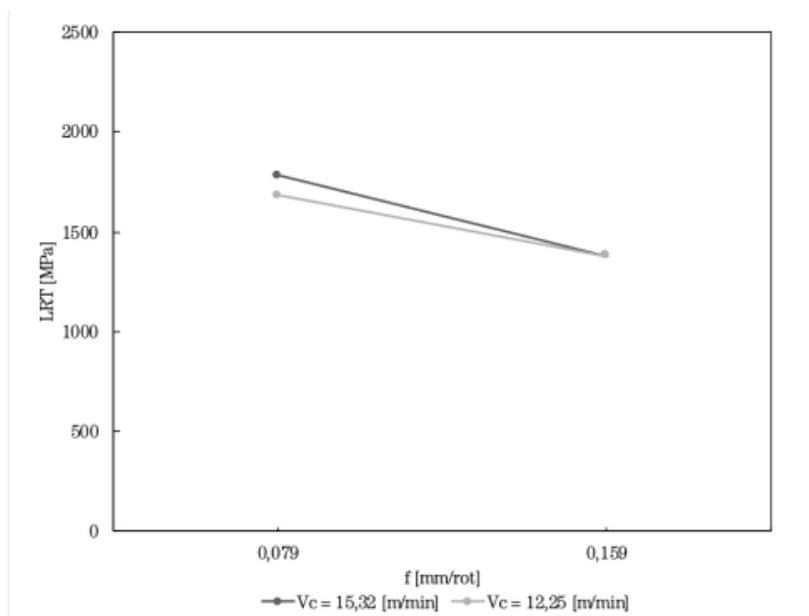
Posteriormente, foram realizados ensaios de tração para verificação do LRT de cada corpo e os resultados obtidos podem ser vistos da Figura 7 e Figura 8.

Figura 7 – Variação do limite de resistência à tração e % de alongamento em função a velocidade de corte e avanço.



Fonte: GANDIA (2020).

Figura 8 – Limite de resistência à tração em função da velocidade de corte e avanço.



Fonte: GANDIA (2020)

Portanto, entende-se que os parâmetros de usinagem influenciam na rugosidade superficial, que por sua vez influencia nas propriedades mecânicas da peça, ou seja, os parâmetros de usinagem são responsáveis pela alteração da integridade superficial do material em sua totalidade, alterando assim, fatores extremamente importantes para um projeto mecânico.

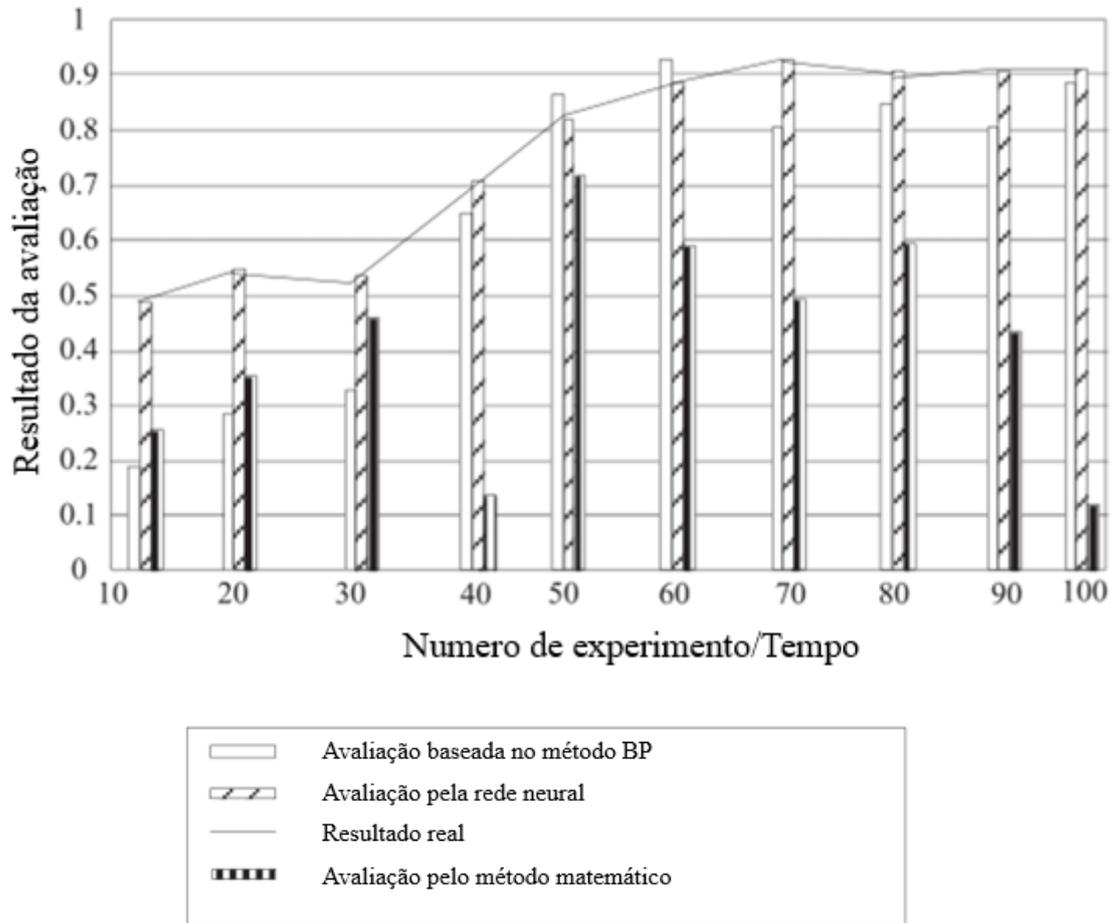
2.2. Redes Neurais Artificiais Aplicadas para solução de problemas diversos

A partir dos anos 80, após diversas pesquisas e trabalhos na área, as redes neurais passaram a ser entendidas e utilizadas tais como modelos estatísticos com a capacidade de previsão de resultados para problemas ditos complexos (Norvig e Russell., 2013). Com o avanço da tecnologia, essa ferramenta vem se tornando cada vez mais popular e sua aplicabilidade tornou-se extremamente abrangente.

Saldarriaga (2022), tinha o objetivo de usar uma rede neural para prever a transferência de calor dentro de um reator nuclear através do módulo de Nusselt. Para tal, ele utilizou uma estrutura multicamadas com 9 entradas e apenas uma saída. Além disso, utilizou 60 conjuntos de dados, sendo 60% para treinamento e 40% para testes e a seleção dos dados foi feita de forma aleatória. Ao final dos testes, foi possível obter um erro médio quadrático de $1,23.10^{-2}$ quando comparado aos dados experimentais. Dessa forma, foi possível estabelecer uma função capaz de performar melhor do que modelos matemáticos existentes para esse caso.

Yingzi e Zhaoji (2022) desenvolveram uma rede neural, para determinar o nível de confiança de um e-commerce, baseando-se em fatores como por exemplo mercado (Reputação do negócio, serviços prestados), ambiente (usabilidade, privacidade, segurança e etc), e social (sistema de garantia, recomendações e etc). A utilização de uma rede neural foi necessária, pois os modelos de previsão existentes têm baixa acurácia e eficiência. Finalmente, como é possível ver na Figura 9, o modelo proposto obteve êxito, pois ao longo das iterações observa-se uma estabilidade no resultado.

Figura 9 – Resultado da avaliação de confiabilidade para e-commerce através de diferentes métodos.



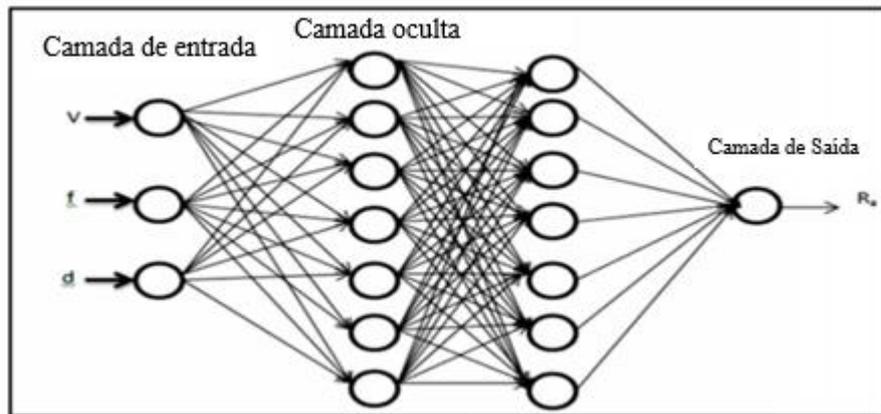
Fonte: Adaptado de Yingzi e Zhaoji (2022).

2.3. Redes neurais aplicadas para previsão da rugosidade superficial

Um dos campos de aplicação de ANN em usinagem, é a previsão do estado de superfície geralmente da peça. Como exemplificado no tópico 2.1, a integridade superficial da peça pode influenciar em propriedades mecânicas e além disso não ter uma boa previsão desses resultados causará custos desnecessários durante o processo de fabricação.

Arulraj et al. (2014) experimentaram a utilização de uma ANN multicamadas (3-7-7-1) como pode ser visto na Figura 10, para a previsão da rugosidade superficial de uma peça cilíndrica de aço H13.

Figura 10 – Esquema da rede neural utilizada (3-7-7-1).

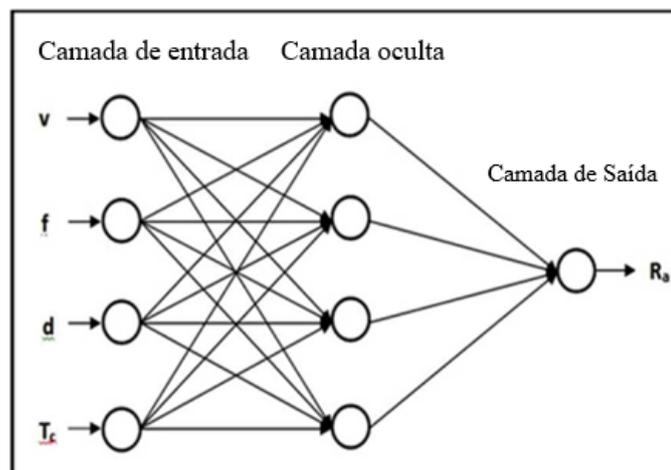


Fonte: Adaptado de Arulraj et al. (2014).

Posteriormente, captaram através de sensores os valores de saída, para uma combinação de 27 entradas diferentes, esses dados foram utilizados para treinamento da rede neural. Com esses dados em mãos foi gerada uma função para previsão da rugosidade, quando comparada aos dados experimentais essa função teve erros em torno de 4-10%.

Além disso, com o objetivo de diminuir o erro, decidiram investigar a influência da temperatura nesse experimento. Para isso, foi necessário alterar a estrutura da rede neural (4-4-1), conforme a Figura 11, adicionando a temperatura como uma entrada.

Figura 11 – Rede neural reestruturada para (4-4-1).



Fonte: Adaptado de Arulraj et al. (2014).

Por fim, foram capturados dados novamente para treinamento de rede neural, dessa vez capturando também a temperatura de corte. Dessa forma, ao final do experimento obtiveram erros em torno de 2-3%, o que mostrou influência da temperatura na previsão dos resultados.

Posto isto, observando os trabalhos realizados na área, é possível notar que o padrão de variáveis é o seguinte:

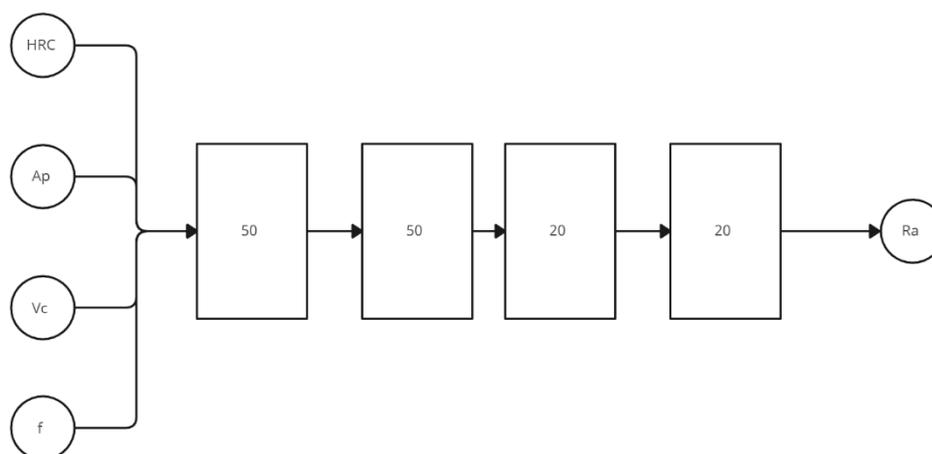
- Entradas: Velocidade de avanço (mm/rev), profundidade de usinagem (mm) e velocidade de corte (m/min).
- Saída: Rugosidade Ra (um).

3. Materiais e Métodos

Inicialmente, para a elaboração da rede neural foi utilizado o software Matlab, mais especificamente uma função chamada fitnet, função essa que permite a criação de uma rede neural artificial a partir de alguns parâmetros, como por exemplo, número de variáveis de entrada, quantidade de camadas, quantidade de neurônios e por fim quantidade de variáveis de saída.

Dessa forma, definiu-se para o presente trabalho que a rede neural artificial, terá 4 variáveis de entrada (Dureza (HRC), profundidade de corte (mm), velocidade de corte (m/min), avanço (mm/rot). Além disso, foi definido que haveria 4 camadas ocultas com 50,50,20 e 20 neurônios respectivamente e como saída foi definido o fator Ra (um) de rugosidade, na Figura 12 é possível ver um esquema da estrutura da rede neural.

Figura 12 – Rede neural com 4 entradas e uma saída.



Fonte: Autor (2023).

Portanto, com a rede neural completamente definida é necessário treiná-la com dados, e para tal utilizamos foram utilizadas 205 combinações de entradas e saídas como pode ser verificado no Apêndice A.

Vale salientar que, é necessário definir uma porcentagem dos dados para treinamento e uma porcentagem para validação da rede, porém decidiu-se variar essas porcentagens com o objetivo de encontrar a combinação que gerasse menor erro.

Por fim, para validação da rede foram utilizados os dados experimentais obtidos por Gandia (2020), conforme a Tabela 1.

Tabela 1 – Dados para verificação final da rede neural.

Combinação	Material	Dureza HRC	Ap (mm)	Vc (m/min)	f (mm/rot)	Ra (um)
1	O1	59	0,25	12,25	0,079	2,001
2	O1	59	0,25	12,25	0,159	2,084
3	O1	59	0,25	15,32	0,079	1,24
4	O1	59	0,25	15,32	0,159	2,03

Fonte: Autor (2023)

Dessa forma, para cada linha de resultados da tabela acima, foram realizadas 3 iterações na rede neural variando a porcentagem de dados de treinamento de 5 em 5, para evitar que a aleatoriedade de geração da rede fosse determinante no resultado.

4. Resultados e Discussão

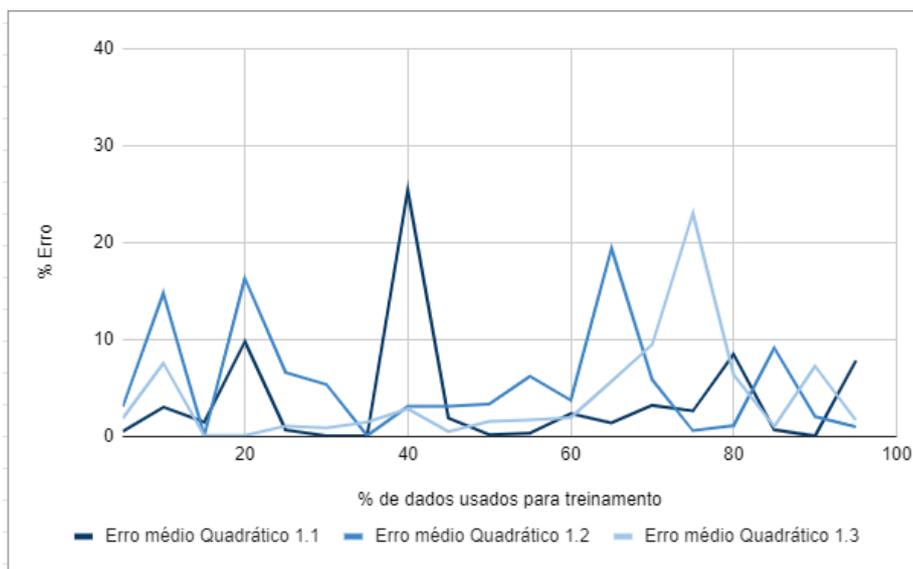
Nesta seção, serão apresentados os resultados das iterações realizadas na rede neural artificial, e para efeitos de verificação da acurácia do modelo, calculou-se o valor do erro médio quadrático de acordo com a Equação 2.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (2)$$

Onde n é o número de pontos medidos, Y_i é o valor real, \hat{Y}_i é o valor obtido.

Na Figura 13 é possível observar os resultados para as três iterações realizadas para a combinação 1, apresentada na Tabela 1.

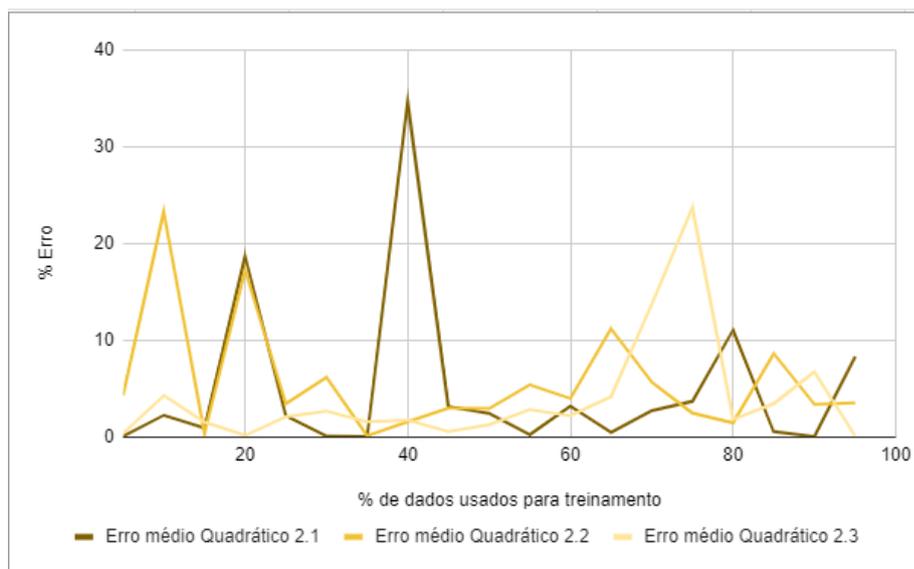
Figura 13 – Resultados para a combinação 1.



Fonte: Autor (2023).

A Figura 14 apresenta os resultados para a combinação 2.

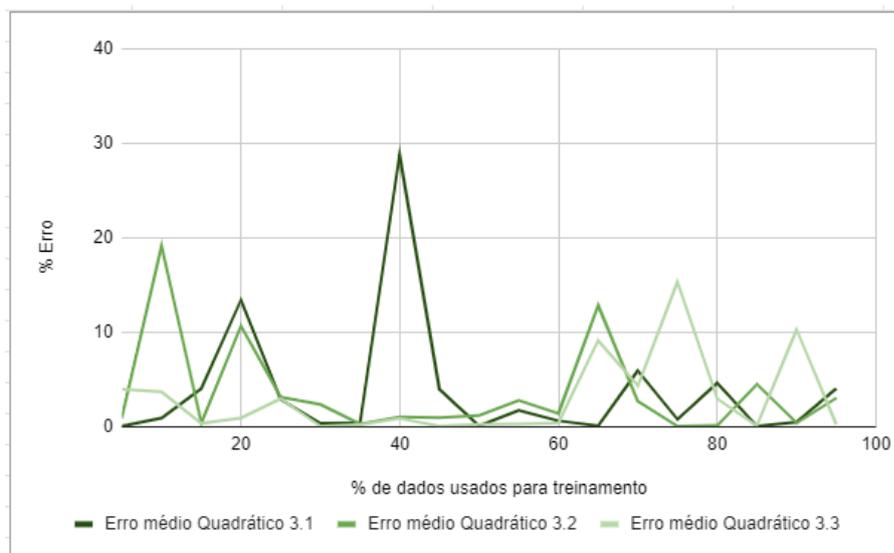
Figura 14 – Resultados para a combinação 2.



Fonte: Autor (2023).

Os resultados para a combinação 3 são apresentados na Figura 15.

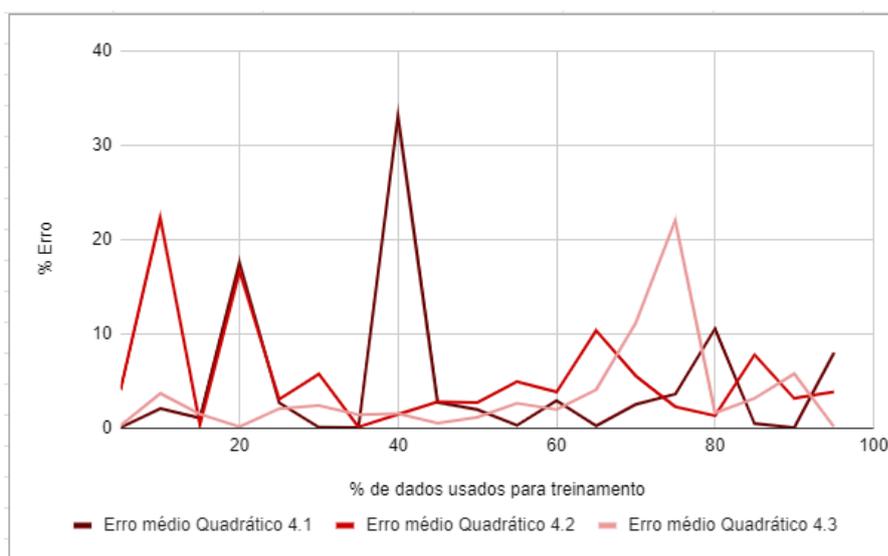
Figura 15 – Resultados para a combinação 3.



Fonte: Autor (2023).

Por fim, os resultados da combinação 4 estão apresentados na Figura 16.

Figura 16 – Resultados para a combinação 4.

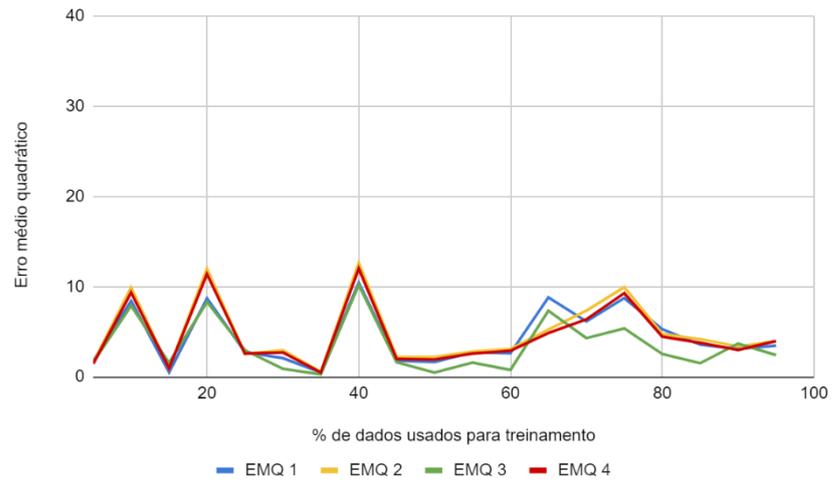


Fonte: Autor (2023).

Ao analisar os gráficos é possível observar que não se pode definir um intervalo específico no qual a porcentagem de dados para treinamento da rede neural é mais efetiva, pois para todos os 4 casos houve muita dispersão no erro para cada iteração.

Para diminuir a variação e analisar o comportamento geral da rede, foi calculado o erro médio quadrático dos 3 pontos para cada uma das combinações, conforme pode-se observar na Figura 17.

Figura 17 – Resultado médio para cada combinação.



Fonte: Autor (2023).

Ao analisar o gráfico, podemos observar que existem dois intervalos nos quais a rede se comporta de forma menos volátil entre (25-35%) e (45-60%).

5. Conclusões e Sugestões para Trabalhos Posteriores

Tendo como base os resultados obtidos através da rede neural para rugosidade superficial Ra, podem ser destacadas, de maneira objetiva, as seguintes conclusões:

- É possível a utilização de rede neural para previsão de rugosidade superficial, mesmo sem dados do material específico.
- A quantidade de dados para treinamento da rede neural deve ficar entre 45%-60%, gerando um erro médio quadrático de aproximadamente 20%.

Como evolução do presente Trabalho, pode-se obter mais dados para treinamento da rede neural, com maior variação da velocidade de corte, dessa forma os resultados tendem a ser mais abrangentes.

É possível, também, estudar mais detalhadamente os erros dentro do intervalo observado para treinamento da rede neural e assim determinar um ponto ótimo.

Além disso, é viável a alteração da rede neural, pode alterar o número de camadas ocultas, bem como a quantidade de neurônios e observar como isso influencia os resultados. Por fim, ainda é possível acrescentar variáveis de entrada como por exemplo a temperatura, para aproximar ainda mais o modelo da realidade.

Referências

- ABNT, NBRISO. 4287. **Especificações geométricas do produto (GPS)-Rugosidade: Método do perfil-Termos, definições e parâmetros da rugosidade.** Associação Brasileira de Normas Técnicas, 2002.
- ARULRAJ, J. Gerald Anto; WINS, K. Leo Dev; RAJ, Anil. **Artificial neural network assisted sensor fusion model for predicting surface roughness during hard turning of H13 steel with minimal cutting fluid application.** Procedia Materials Science, v. 5, p. 2338-2346, 2014.
- BARTARYA, Gaurav; CHOUDHURY, S. K. **Effect of cutting parameters on cutting force and surface roughness during finish hard turning AISI52100 grade steel.** Procedia CIRP, v. 1, p. 651-656, 2012.
- BASHIR, K. et al. **Experimental investigation into effect of cutting parameters on surface integrity of hardened tool steel.** In: IOP PUBLISHING. IOP Conference Series: Materials Science and Engineering. [S.l.], 2018. v. 344, n. 1, p. 012020.
- BENSOUILAH, Hamza et al. **Performance of coated and uncoated mixed ceramic tools in hard turning process.** Measurement, v. 82, p. 1-18, 2016.
- ÇIÇEK, Adem et al. **Evaluation of machinability of hardened and cryo-treated AISI H13 hot work tool steel with ceramic inserts.** International journal of refractory metals and hard materials, v. 41, p. 461-469, 2013.
- DAVIM, J. P. et al. **Surface integrity in machining.** [S.l.]: Springer, 2010. v. 1848828742.
- DAVIM, J. P.; GAITONDE, V.; KARNIK, S. **Investigations into the effect of cutting conditions on surface roughness in turning of free machining steel by ann models.** Journal of materials processing technology, Elsevier, v. 205, n. 1-3, p. 16-23, 2008.
- DAVIM, J. Paulo; FIGUEIRA, Luis. **Machinability evaluation in hard turning of cold work tool steel (D2) with ceramic tools using statistical techniques.** Materials & design, v. 28, n. 4, p. 1186-1191, 2007.
- ELBESTAWI, M. A.; SRIVASTAVA, A. K.; EL-WARDANY, T. I. **A model for chip formation during machining of hardened steel.** CIRP annals, v. 45, n. 1, p. 71-76, 1996.
- FERRARESI, Dino. **Fundamentos da usinagem dos metais.** Editora blucher, 1970.
- FRACARO, Janaina. **Fabricação pelo processo de usinagem e meios de controle.** Intersaberes, Curitiba, Brazil, 2017.
- GAITONDE, V. N. et al. **Machinability investigations in hard turning of AISI D2 cold work tool steel with conventional and wiper ceramic inserts.** International Journal of Refractory Metals and Hard Materials, v. 27, n. 4, p. 754-763, 2009.
- GANDIA, G. C. **Investigação experimental da influência de parâmetros de usinagem sobre a resistência mecânica de um aço ferramenta endurecido,** 2020.

GONÇALVES, André Ricardo. **Redes neurais artificiais**. 1. ed. [s.l.]: [s.n.], 2013. Apostila utilizada como material didático na disciplina de Inteligência Artificial ministrada na Universidade Estadual de Campinas.

JAVIDI, A.; RIEGER, U.; EICHLSEDER, W. **The effect of machining on the surface integrity and fatigue life**. International Journal of fatigue, Elsevier, v. 30, n. 10-11, p. 2050–2055, 2008.

LIMA, J. G. et al. **Hard turning: AISI 4340 high strength low alloy steel and AISI D2 cold work tool steel**. Journal of Materials Processing Technology, v. 169, n. 3, p. 388-395, 2005.

NORVIG, Peter; RUSSELL, Stuart. **Inteligência artificial. Tradução: Regina Célia Simille de Macedo**. Consultoria Editorial e Revisão técnica: Dr. Flávio Soares Corrêa da Silva, Dra. Leliane Nunes de Barros and Dra. Renata Wassermann, v. 3, p. 13-31, 2013

RATH, Debabrata; PANDA, Sumanta; PAL, Kamal. **Prediction of surface quality using chip morphology with nodal temperature signatures in hard turning of AISI D3 steel**. Materials Today: Proceedings, v. 5, n. 5, p. 12368-12375, 2018.

SALDARRIAGA, Juan F. **Application of an artificial neural networks for predicting the heat transfer in conical spouted bed using the Nusselt module**. Heliyon, v. 8, n. 11, p. e11611, 2022.

SIH, G. C. , 1974, **Surface Layer Energy and Strain Energy Density for a Blunted Crack or Notch, Prospects of Fract. Mech.**, Noordhoff International Publishing, Leyden: 85-1 02

SIVARAMAN, V.; PRAKASH, S. **Optimization of cutting parameters in hard turning of aisi 01 steel using pvd tialn coated carbide insert**. International Journal of Mechanical and Production Engineering Research and Development (IJMPERD), TJPRC Pvt. Ltd., v. 10, 2020.

SRITHAR, A.; PALANIKUMAR, K.; DURGAPRASAD, B. **Experimental Investigation and Surface Roughness analysis on Hard Turning of AISI D2 Steel using Polycrystalline Cubic Boron Nitride (PCBN)**. Materials Today: Proceedings, v. 16, p. 1061-1066, 2019.

SURESH, R. et al. **State-of-the-art research in machinability of hardened steels**. Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture, SAGE Publications Sage UK: London, England, v. 227, n. 2, p. 191–209, 2013.

WANG, B.; LIU, Z.; YANG, Q. **Investigations of yield stress, fracture toughness, and energy distribution in high-speed orthogonal cutting**. International Journal of Machine Tools and Manufacture, Elsevier, v. 73, p. 1–8, 2013.

WU, D.; MATSUMOTO, Y. **The effect of hardness on residual stresses in orthogonal machining of aisi 4340 steel**. 1990.

YINGZI, Zhao; ZHAOJI, Yu. **Research on user trust evaluation of social e-commerce platform based on artificial neural network**. Optik, v. 271, p. 170193, 2022.

Apêndice A – Dados utilizados para treinamento e validação da rede neural

Referência	Material	Dureza HRC	Prof. de corte (mm)	Vc (m/min)	f (mm/rot)	Ra (um)
Arulraj, Wins e Raj (2014)	H13	43	0,5	75	0,05	1,28
Arulraj, Wins e Raj (2014)	H13	43	0,75	75	0,05	1,1
Arulraj, Wins e Raj (2014)	H13	43	1	75	0,05	1,58
Arulraj, Wins e Raj (2014)	H13	43	0,5	95	0,05	0,91
Arulraj, Wins e Raj (2014)	H13	43	0,75	95	0,05	1,03
Arulraj, Wins e Raj (2014)	H13	43	1	95	0,05	1,13
Arulraj, Wins e Raj (2014)	H13	43	0,5	115	0,05	1,38
Arulraj, Wins e Raj (2014)	H13	43	0,75	115	0,05	1,34
Arulraj, Wins e Raj (2014)	H13	43	1	115	0,05	1,45
Arulraj, Wins e Raj (2014)	H13	43	0,5	75	0,075	1,19
Arulraj, Wins e Raj (2014)	H13	43	0,75	75	0,075	1,09
Arulraj, Wins e Raj (2014)	H13	43	1	75	0,075	1,48
Arulraj, Wins e Raj (2014)	H13	43	0,5	95	0,075	1,45
Arulraj, Wins e Raj (2014)	H13	43	0,75	95	0,075	1,86
Arulraj, Wins e Raj (2014)	H13	43	1	95	0,075	1,82
Arulraj, Wins e Raj (2014)	H13	43	0,5	115	0,075	1,43
Arulraj, Wins e Raj (2014)	H13	43	0,75	115	0,075	1,7
Arulraj, Wins e Raj (2014)	H13	43	1	115	0,075	1,65
Arulraj, Wins e Raj (2014)	H13	43	0,5	75	0,1	1,64
Arulraj, Wins e Raj (2014)	H13	43	0,75	75	0,1	1,13
Arulraj, Wins e Raj (2014)	H13	43	1	75	0,1	1,78
Arulraj, Wins e Raj (2014)	H13	43	0,5	95	0,1	1,77
Arulraj, Wins e Raj (2014)	H13	43	0,75	95	0,1	1,83
Arulraj, Wins e Raj (2014)	H13	43	1	95	0,1	1,53
Arulraj, Wins e Raj (2014)	H13	43	0,5	115	0,1	1,32
Arulraj, Wins e Raj (2014)	H13	43	0,75	115	0,1	1,6
Arulraj, Wins e Raj (2014)	H13	43	1	115	0,1	1,79
Bartarya e Choudhury (2012)	AISI 52100	60	0,1	167	0,075	2,83
Bartarya e Choudhury (2012)	AISI 52100	60	0,15	167	0,075	3,35
Bartarya e Choudhury (2012)	AISI 52100	60	0,1	167	0,113	1,47
Bartarya e Choudhury (2012)	AISI 52100	60	0,15	167	0,113	2,72
Bartarya e Choudhury (2012)	AISI 52100	60	0,2	167	0,113	2,47

Bartarya e Choudhury (2012)	AISI 52100	60	0,1	167	0,15	1,97
Bartarya e Choudhury (2012)	AISI 52100	60	0,15	167	0,15	2,3
Bartarya e Choudhury (2012)	AISI 52100	60	0,2	167	0,15	2,05
Bartarya e Choudhury (2012)	AISI 52100	60	0,1	204	0,075	1,37
Bartarya e Choudhury (2012)	AISI 52100	60	0,15	204	0,075	2,49
Bartarya e Choudhury (2012)	AISI 52100	60	0,2	204	0,075	3,83
Bartarya e Choudhury (2012)	AISI 52100	60	0,1	204	0,113	1,3
Bartarya e Choudhury (2012)	AISI 52100	60	0,15	204	0,113	2,26
Bartarya e Choudhury (2012)	AISI 52100	60	0,2	204	0,113	2,28
Bartarya e Choudhury (2012)	AISI 52100	60	0,1	204	0,15	1,89
Bartarya e Choudhury (2012)	AISI 52100	60	0,15	204	0,15	2,56
Bartarya e Choudhury (2012)	AISI 52100	60	0,2	204	0,15	1,95
Bartarya e Choudhury (2012)	AISI 52100	60	0,1	261,1	0,075	1,11
Bartarya e Choudhury (2012)	AISI 52100	60	0,15	261,1	0,075	2,47
Bartarya e Choudhury (2012)	AISI 52100	60	0,1	261,1	0,113	1,23
Bartarya e Choudhury (2012)	AISI 52100	60	0,15	261,1	0,113	1,95
Bartarya e Choudhury (2012)	AISI 52100	60	0,2	261,1	0,113	1,92
Bartarya e Choudhury (2012)	AISI 52100	60	0,1	261,1	0,15	1,38
Bartarya e Choudhury (2012)	AISI 52100	60	0,15	261,1	0,15	1,43
Bartarya e Choudhury (2012)	AISI 52100	60	0,2	261,1	0,15	1,83
Bensouilah et al (2016)	D3	63	0,1	75	0,08	0,72
Bensouilah et al (2016)	D3	63	0,2	75	0,12	0,91
Bensouilah et al (2016)	D3	63	0,3	75	0,16	1,08
Bensouilah et al (2016)	D3	63	0,4	75	0,2	1,16
Bensouilah et al (2016)	D3	63	0,2	105	0,08	0,63
Bensouilah et al (2016)	D3	63	0,1	105	0,12	0,92
Bensouilah et al (2016)	D3	63	0,4	105	0,16	0,94
Bensouilah et al (2016)	D3	63	0,3	105	0,2	1,08
Bensouilah et al (2016)	D3	63	0,3	150	0,08	0,51
Bensouilah et al (2016)	D3	63	0,4	150	0,12	0,66
Bensouilah et al (2016)	D3	63	0,1	150	0,16	0,75
Bensouilah et al (2016)	D3	63	0,2	150	0,2	1,04
Bensouilah et al (2016)	D3	63	0,4	210	0,8	0,24
Bensouilah et al (2016)	D3	63	0,3	210	0,12	0,47
Bensouilah et al (2016)	D3	63	0,2	210	0,16	0,84

Bensouilah et al (2016)	D3	63	0,1	210	0,2	0,92
ÇIÇEK et al (2013)	H13	48	0,3	150	0,08	0,28
ÇIÇEK et al (2013)	H13	48	0,3	200	0,08	0,24
ÇIÇEK et al (2013)	H13	48	0,3	250	0,08	0,23
ÇIÇEK et al (2013)	H13	48	0,3	300	0,08	0,27
ÇIÇEK et al (2013)	H13	48	0,3	150	0,12	0,57
ÇIÇEK et al (2013)	H13	48	0,3	200	0,12	0,55
ÇIÇEK et al (2013)	H13	48	0,3	250	0,12	0,57
ÇIÇEK et al (2013)	H13	48	0,3	300	0,12	0,58
ÇIÇEK et al (2013)	H13	48	0,3	150	0,16	1,12
ÇIÇEK et al (2013)	H13	48	0,3	200	0,16	1,21
ÇIÇEK et al (2013)	H13	48	0,3	250	0,16	1,16
ÇIÇEK et al (2013)	H13	48	0,3	300	0,16	1,22
Davim e Figueira (2007)	D2	60	0,2	80	0,05	0,43
Davim e Figueira (2007)	D2	60	0,2	80	0,05	0,5
Davim e Figueira (2007)	D2	60	0,2	80	0,05	0,56
Davim e Figueira (2007)	D2	60	0,2	80	0,1	0,72
Davim e Figueira (2007)	D2	60	0,2	80	0,1	0,97
Davim e Figueira (2007)	D2	60	0,2	80	0,1	1,05
Davim e Figueira (2007)	D2	60	0,2	80	0,15	0,55
Davim e Figueira (2007)	D2	60	0,2	80	0,15	0,7
Davim e Figueira (2007)	D2	60	0,2	80	0,15	0,82
Davim e Figueira (2007)	D2	60	0,2	150	0,05	0,39
Davim e Figueira (2007)	D2	60	0,2	150	0,05	0,5
Davim e Figueira (2007)	D2	60	0,2	150	0,05	0,6
Davim e Figueira (2007)	D2	60	0,2	150	0,1	0,79
Davim e Figueira (2007)	D2	60	0,2	150	0,1	0,89
Davim e Figueira (2007)	D2	60	0,2	150	0,1	1,05
Davim e Figueira (2007)	D2	60	0,2	150	0,15	0,77
Davim e Figueira (2007)	D2	60	0,2	150	0,15	1,07
Davim e Figueira (2007)	D2	60	0,2	150	0,15	1,32
Davim e Figueira (2007)	D2	60	0,2	220	0,05	0,26
Davim e Figueira (2007)	D2	60	0,2	220	0,05	0,46
Davim e Figueira (2007)	D2	60	0,2	220	0,05	1,4
Davim e Figueira (2007)	D2	60	0,2	220	0,1	0,59

Davim e Figueira (2007)	D2	60	0,2	220	0,1	0,98
Davim e Figueira (2007)	D2	60	0,2	220	0,1	1,38
Davim e Figueira (2007)	D2	60	0,2	220	0,15	0,88
Davim e Figueira (2007)	D2	60	0,2	220	0,15	1,31
Davim e Figueira (2007)	D2	60	0,2	220	0,15	1,48
Gaitonde et al. (2009)	D2	59	0,2	80	0,1	0,39
Gaitonde et al. (2009)	D2	59	0,2	80	0,1	0,52
Gaitonde et al. (2009)	D2	59	0,2	80	0,1	0,57
Gaitonde et al. (2009)	D2	59	0,4	80	0,1	0,63
Gaitonde et al. (2009)	D2	59	0,4	80	0,1	0,95
Gaitonde et al. (2009)	D2	59	0,4	80	0,1	1,34
Gaitonde et al. (2009)	D2	59	0,6	80	0,1	0,86
Gaitonde et al. (2009)	D2	59	0,6	80	0,1	1,33
Gaitonde et al. (2009)	D2	59	0,6	80	0,1	1,94
Lima et al. (2005)	4340	42	1	120	0,1	0,5
Lima et al. (2005)	4340	42	1	120	0,2	1,33
Lima et al. (2005)	4340	42	1	120	0,3	3,8
Lima et al. (2005)	4340	42	1	120	0,4	6,7
Lima et al. (2005)	4340	50	1	120	0,1	0,38
Lima et al. (2005)	4340	50	1	120	0,2	0,5
Lima et al. (2005)	4340	50	1	120	0,3	1,4
Lima et al. (2005)	4340	50	1	120	0,4	2,39
Lima et al. (2005)	4340	42	0,5	120	0,2	1,31
Lima et al. (2005)	4340	42	1	120	0,2	1,34
Lima et al. (2005)	4340	42	1,5	120	0,2	1,33
Lima et al. (2005)	4340	42	2	120	0,2	1,61
Lima et al. (2005)	4340	50	0,5	120	0,2	1,13
Lima et al. (2005)	4340	50	1	120	0,2	0,53
Lima et al. (2005)	4340	50	1,5	120	0,2	1,1
Lima et al. (2005)	4340	50	2	120	0,2	1,04
Lima et al. (2005)	4340	42	1	60	0,2	1,87
Lima et al. (2005)	4340	42	1	120	0,2	1,34
Lima et al. (2005)	4340	42	1	180	0,2	1,72
Lima et al. (2005)	4340	50	1	60	0,2	0,63
Lima et al. (2005)	4340	50	1	120	0,2	0,54

Lima et al. (2005)	4340	50	1	180	0,2	0,46
Lima et al. (2005)	4340	58	1	80	0,05	0,47
Lima et al. (2005)	4340	58	1	80	0,05	0,42
Lima et al. (2005)	4340	58	1	80	0,05	0,4
Lima et al. (2005)	4340	58	1	80	0,1	0,66
Lima et al. (2005)	4340	58	1	80	0,1	0,82
Lima et al. (2005)	4340	58	1	80	0,1	0,76
Lima et al. (2005)	4340	58	1	80	0,15	1,04
Lima et al. (2005)	4340	58	1	80	0,15	0,93
Lima et al. (2005)	4340	58	1	80	0,15	1,09
Lima et al. (2005)	4340	58	1	150	0,05	0,34
Lima et al. (2005)	4340	58	1	150	0,05	0,36
Lima et al. (2005)	4340	58	1	150	0,05	0,37
Lima et al. (2005)	4340	58	1	150	0,1	0,5
Lima et al. (2005)	4340	58	1	150	0,1	0,55
Lima et al. (2005)	4340	58	1	150	0,1	0,58
Lima et al. (2005)	4340	58	1	150	0,15	1
Lima et al. (2005)	4340	58	1	150	0,15	0,93
Lima et al. (2005)	4340	58	1	150	0,15	0,81
Lima et al. (2005)	4340	58	1	220	0,05	0,31
Lima et al. (2005)	4340	58	1	220	0,05	0,33
Lima et al. (2005)	4340	58	1	220	0,05	0,34
Lima et al. (2005)	4340	58	1	220	0,1	0,52
Lima et al. (2005)	4340	58	1	220	0,1	0,5
Lima et al. (2005)	4340	58	1	220	0,1	0,54
Lima et al. (2005)	4340	58	1	220	0,15	0,41
Lima et al. (2005)	4340	58	1	220	0,15	0,37
Lima et al. (2005)	4340	58	1	220	0,15	0,7
Rath, Panda e Pal (2018)	D3	61	0,1	80	0,04	2,08
Rath, Panda e Pal (2018)	D3	61	0,3	80	0,05	1,48
Rath, Panda e Pal (2018)	D3	61	0,5	80	0,06	1,02
Rath, Panda e Pal (2018)	D3	61	0,7	80	0,07	2,12
Rath, Panda e Pal (2018)	D3	61	0,9	80	0,08	3,48
Rath, Panda e Pal (2018)	D3	61	0,3	140	0,04	1,44
Rath, Panda e Pal (2018)	D3	61	0,5	140	0,05	1,04

Rath, Panda e Pal (2018)	D3	61	0,7	140	0,06	1,5
Rath, Panda e Pal (2018)	D3	61	0,9	140	0,07	4,53
Rath, Panda e Pal (2018)	D3	61	0,1	140	0,08	2,5
Rath, Panda e Pal (2018)	D3	61	0,5	190	0,04	1,02
Rath, Panda e Pal (2018)	D3	61	0,7	190	0,05	0,5
Rath, Panda e Pal (2018)	D3	61	0,9	190	0,06	3,04
Rath, Panda e Pal (2018)	D3	61	0,1	190	0,07	1,47
Rath, Panda e Pal (2018)	D3	61	0,3	190	0,08	2,01
Rath, Panda e Pal (2018)	D3	61	0,7	245	0,04	1
Rath, Panda e Pal (2018)	D3	61	0,9	245	0,05	4,48
Rath, Panda e Pal (2018)	D3	61	0,1	245	0,06	0,49
Rath, Panda e Pal (2018)	D3	61	0,3	245	0,07	3,08
Rath, Panda e Pal (2018)	D3	61	0,5	245	0,08	1,04
Rath, Panda e Pal (2018)	D3	61	0,9	320	0,04	3,06
Rath, Panda e Pal (2018)	D3	61	0,1	320	0,05	0,48
Rath, Panda e Pal (2018)	D3	61	0,3	320	0,06	0,5
Rath, Panda e Pal (2018)	D3	61	0,5	320	0,07	1,03
Rath, Panda e Pal (2018)	D3	61	0,7	320	0,08	0,52
Srithar, Palanikumar e Durgaprasad (2019)	D2	64	0,2	80	0,05	0,14
Srithar, Palanikumar e Durgaprasad (2019)	D2	64	0,2	130	0,05	0,11
Srithar, Palanikumar e Durgaprasad (2019)	D2	64	0,2	180	0,05	0,06
Srithar, Palanikumar e Durgaprasad (2019)	D2	64	0,2	230	0,05	0,07
Srithar, Palanikumar e Durgaprasad (2019)	D2	64	0,2	280	0,05	0,09
Srithar, Palanikumar e Durgaprasad (2019)	D2	64	0,2	80	0,05	0,22
Srithar, Palanikumar e Durgaprasad (2019)	D2	64	0,2	80	0,1	0,41
Srithar, Palanikumar e Durgaprasad (2019)	D2	64	0,2	80	0,15	0,69
Srithar, Palanikumar e Durgaprasad (2019)	D2	64	0,2	80	0,2	0,85
Srithar, Palanikumar e Durgaprasad (2019)	D2	64	0,2	80	0,25	0,95
Srithar, Palanikumar e Durgaprasad (2019)	D2	64	0,2	80	0,05	0,9
Srithar, Palanikumar e Durgaprasad (2019)	D2	64	0,4	80	0,05	0,14

Srithar, Palanikumar e Durgaprasad (2019)	D2	64	0,6	80	0,05	0,17
Srithar, Palanikumar e Durgaprasad (2019)	D2	64	0,8	80	0,05	0,19
Srithar, Palanikumar e Durgaprasad (2019)	D2	64	1	80	0,05	0,2