

### **CATEGORIA 3**

## **APLICAÇÃO DE *GRID SEARCH* PARA CLASSIFICAÇÃO DE FALHAS EM MÁQUINAS DE CHAVE ELÉTRICAS FERROVIÁRIAS**

### **INTRODUÇÃO**

As máquinas de chave são responsáveis pela movimentação dos Aparelhos de Mudança de Via (AMV) que direcionam o movimento dos trens em regiões de cruzamento como pátios e terminais. Elas têm como função deslocar, travar e fiscalizar a posição das agulhas de um AMV. Apenas com o travamento e a fiscalização do correto posicionamento das agulhas, o sistema de sinalização permite que trens sejam licenciados sobre o AMV. Do ponto de vista operacional, as máquinas de chave são os ativos de maior relevância de um sistema de sinalização ferroviária, pois, no caso de falha, são impostas de restrições de velocidade e, quase sempre, parada dos trens que por elas percorrem.

As máquinas de chave elétricas são sujeitas a diferentes modos de falha que impactam a operação ferroviária. Quando em falha, estes ativos necessitam de intervenção das

**26ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA**  
**7º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS**



equipes de pronto atendimento para o restauro de suas condições operacionais. O período de manutenção das falhas de uma máquina de chave depende do tempo de reparo e do tempo de deslocamento das equipes, pois os ativos estão situados ao longo de toda a malha. Por esse motivo, as máquinas de chave elétricas são monitoradas constantemente para que ações sejam tomadas de forma a aumentar a disponibilidade desses ativos para a operação.

Na literatura, encontram-se trabalhos que buscam realizar diagnóstico e, até mesmo, prognóstico de máquinas de chaves elétricas. Estas tarefas podem ser executadas baseadas na premissa de que a maior parte das anomalias não acontece instantaneamente, mas apresentam algum processo de degradação (FU *et al*, 2004 *apud* SHIN; JUN, 2015). Estes trabalhos, em sua maioria, utilizam aprendizado de máquina para realizar o diagnóstico e prognóstico de falhas. Como modelo de aprendizado de máquina, McHutchon, Taszewski e Schmid (2005) utilizaram modelos de agrupamento, baseado em distância, para classificação de diversos modos de falha de máquina de chave. Eker, Camci e Kumar (2010) e Asada, Roberts e Koseki (2013) utilizaram *Máquina de Vetores de Suporte (SVM)* para classificação de um e dois modos de falha, respectivamente, relacionados ao desalinhamento ou à regulagem do tirante de operação. Já Guo *et al* (2017), com o mesmo modelo, classifica as leituras apenas entre operação normal e anormal. Matei *et al.* (2015) utilizou o método de *Florestas Randômicas* para classificar quatro modos de falha: pino de acoplamento frouxo, parafusos de ajuste desalinhados, obstáculo na ponta de agulha e falta de

## 26ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 7º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS



rolete. Por sua vez, Moreira, Kallemback e Barbosa (2016) utilizaram um sistema Neuro-Fuzzy para classificação em sete grupos (dentre *normal*, *falha* e *defeito*), sendo um deles a obstrução da ponta da agulha (falha abrupta). Em Nunes e D'Amore (2020) foi proposto um classificador de referência, dividido em sete grupos, que foram associados em três classes (*normal*, *falha abrupta* e *falha incipiente*) e a separação apenas das falhas *incipientes*. Para estes agrupamentos, obteve desempenho 90,93% e 89,86%, respectivamente, para a métrica de avaliação utilizada.

Este trabalho utiliza o monitoramento da corrente elétrica de cada operação para inferir o estado da máquina de chave. Após a coleta desses dados, os mesmos são exportados e manipulados com a utilização da linguagem de programação *Python* (PYTHON SOFTWARE FOUNDATION, 2020). Então, é possível analisá-los no domínio do tempo a fim de extrair diferentes características. Estas características são utilizadas por modelos de aprendizado de máquina supervisionado para classificar cada operação, também, entre *normal*, *falha abrupta* ou *falha incipiente*. Utiliza-se a técnica de *Busca em rede*, *Grid search*, para encontrar os melhores hiperparâmetros de diferentes modelos de aprendizado de máquina supervisionado. O aprendizado é realizado com base nos dados obtidos com o monitoramento da corrente. Os dados são agrupados em sete grupos distintos, sendo um para operações *normais*, um para operações com *falhas abruptas* e os demais, com *falhas incipientes*.

Este trabalho propõe, ainda, a utilização de uma técnica de extração de características baseada nas fases de operação da máquina de chave e uma técnica de balanceamento

da base de dados de treinamento através de amostragem com o objetivo de obter melhores desempenhos.

Para a base de dados utilizada em conjunto com as técnicas propostas, obteve-se um modelo de aprendizado de máquina por *Árvore de Decisão*, e seus respectivos hiperparâmetros, com 100% de desempenho na métrica de avaliação utilizada, média macro *F1-Score*, para a classificação das operações entre *normal*, *falha abrupta* ou *falha incipiente*. Já para a classificação entre os cinco grupos de tipos de falhas *incipientes*, apenas com a aplicação da técnica de extração de características proposta, chegou-se a um modelo de *k-Vizinhos Mais Próximos*, diferente do modelo encontrado para a classificação anterior, mas também com desempenho de 100%.

## **MÉTODOS**

A seguir serão apresentados os métodos utilizados com o objetivo de desenvolver um sistema de diagnóstico e prognóstico de falhas de máquinas de chave elétricas na companhia.

### **1- A Máquina de Chave Elétrica**

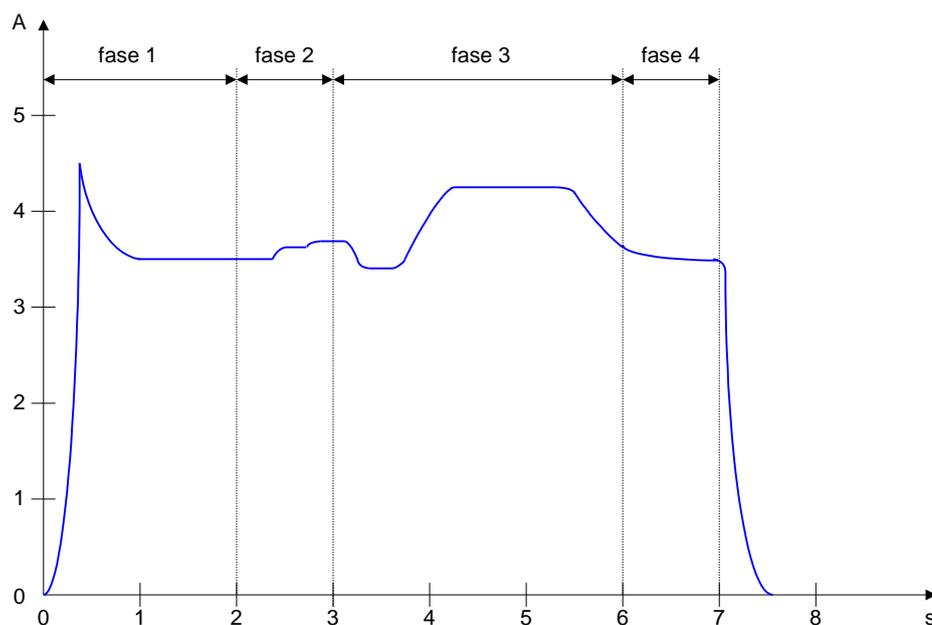
O Aparelho de Mudança de Via (AMV), ou chave, é uma seção da linha férrea que possui partes móveis. A máquina de chave é a parte responsável pelo deslocamento destas partes móveis, conhecidas como agulhas. A máquina de chave possui três funções: movimentar as agulhas, aplicando força sobre as mesmas; travar as agulhas,

mantendo-as em sua correta posição; e supervisionar as agulhas, fornecendo indicação de sua posição ao sistema de sinalização (THEEG; VLASENKO, 2009).

As máquinas de chave podem ser classificadas entre manuais e elétricas. As máquinas de chave elétricas são operadas através da conversão da energia elétrica em cinética e podem ser operadas remotamente. Estas ainda podem ser classificadas de acordo com a conversão de energia realizada: pneumática, magnética, mecânica ou hidráulica (THEEG; VLASENKO, 2009).

Na empresa em que os dados foram levantados, a regulagem das máquinas de chave elétricas e os testes de segurança são realizados com uma periodicidade mensal. Estes testes fazem parte do plano de manutenção preventivo para verificação da segurança do equipamento que seguem a recomendação da *Federal Railroad Administration (FRA)*, órgão do governo norte-americano responsável pela administração das ferrovias. (UNITED STATES, 2019) O teste, conhecido como teste de obstrução, consiste em colocar um gabarito que possui dois lados de dimensões pré-determinadas entre a agulha e o trilho de encosto do AMV e operar a máquina de chave. Ao utilizar o lado de menor espessura do gabarito, a máquina de chave deve indicar o correto posicionamento do AMV, informando ao sistema de sinalização que os trens podem circular sobre o referido AMV com segurança. Ao utilizar o lado de maior espessura, em contrapartida, a máquina de chave não deve indicar o correto posicionamento do AMV, pois a abertura entre a ponta de agulha e o trilho de encosto pode causar o descarrilamento de veículos ferroviários.

A figura 1 ilustra as quatro fases de operação de uma máquina de chave elétrica através da medição da corrente do motor da máquina (SHIMONAE *et al*, 1991). A primeira fase está relacionada à partida do motor elétrico. A segunda fase, à liberação do mecanismo de travamento da máquina de chave e deslocamento inicial do tirante de operação sem, contudo, haver deslocamento das agulhas. A terceira fase, por sua vez, está relacionada à efetiva movimentação das agulhas do AMV. Por fim, a quarta fase, ao travamento do mecanismo de travação da máquina de chave.



**Figura 1** Quatro fases da operação da máquina de chave elétrica: corrente em função do tempo. (adaptado de SHIMONAE *et al*, 1991)

Diversos componentes podem causar a falha, ou perda de função, das máquinas de chave elétricas. As falhas dos componentes elétricos ou eletromecânicos podem ser consideradas *incipientes*, pois o desenvolvimento de seus principais modos de falha pode apresentar variação em seus parâmetros ao longo do tempo a depender das

grandezas físicas monitoradas. As falhas dos componentes mecânicos do AMV ou da máquina de chave, por sua vez, são consideradas *incipientes* por natureza. Por fim, falhas causadas por intervenção externa de terceiros são consideradas *abruptas*.

## **2- Aprendizado de Máquina**

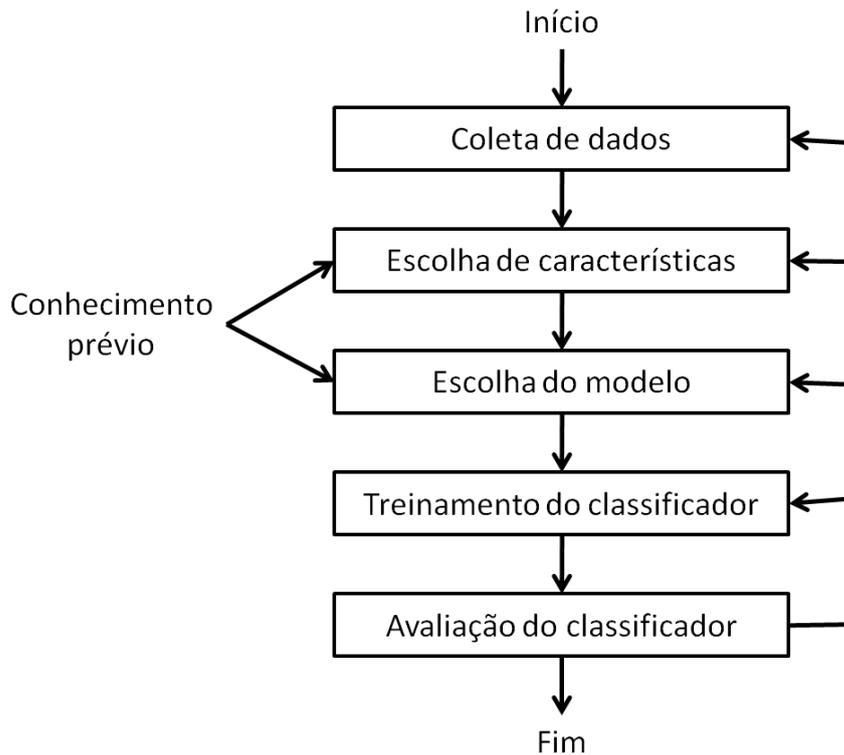
O Aprendizado de Máquina é uma área da Inteligência Artificial que lida com a construção de programas de computador que se aprimoram automaticamente com a experiência (MITCHELL, 1997). Também pode ser definido como a programação de computadores para otimizar um critério de desempenho usando dados de exemplo ou experiência anterior (ALPAYDIN, 2010).

O Aprendizado de Máquina utiliza a teoria da estatística em construção de modelos matemáticos, pois sua tarefa principal é realizar inferência a partir de uma amostra. Os modelos podem ser preditivos, utilizados para realizar previsões no futuro; descritivos, utilizados para se adquirir conhecimento dos dados; ou ambos. (ALPAYDIN, 2010)

Na aprendizagem supervisionada, o objetivo é aprender o mapeamento entre as características de entrada e suas respectivas saídas cujos valores corretos são providos pelo supervisor (ALPAYDIN, 2010). O processo de aprendizagem de máquina supervisionada é composto por cinco etapas distintas que, a depender dos resultados da última etapa, podem ser revistas: coleta de dados, extração de características,

definição do modelo, treinamento e avaliação do modelo (DUDA; HART; STORK, 2000).

A figura 2 ilustra a sequência deste processo.



**Figura 2 Processo de Aprendizado de Máquina Supervisionado (adaptado de DUDA; HART; STORK, 2000)**

No aprendizado de máquina, diversos métodos ou modelos matemáticos podem ser utilizados. Na etapa de treinamento, utilizam-se os dados disponíveis de forma a encontrar os melhores parâmetros de determinado modelo que representem estes dados. Por fim, critérios de avaliação do modelo são utilizados para determinar a qualidade de sua representação dos dados utilizados.

O modelo deve ser escolhido de acordo com o problema a ser resolvido e os dados utilizados. Não existe o melhor modelo, existe o modelo que melhor retrata o problema estudado (ALPAYDIN, 2010; JAMES *et al*, 2013).

Cada modelo de Aprendizado de Máquina possui diferentes hiperparâmetros que precisam ser determinados. Cada hiperparâmetro representa uma variável que influenciará na determinação dos parâmetros ótimos de cada modelo e, conseqüentemente, na qualidade do resultado durante a etapa de treinamento. (ALPAYDIN, 2010)

Os modelos baseados em instância, de maneira simplificada, utilizam medidas de distância entre as amostras para classificá-las. Diferentes medidas de distâncias podem ser utilizadas como, euclidiana, mahalanobis, manhattan, dentre outras. O método *Centróide Mais Próximo (Nearest Centroid)* calcula o centróide de todos os elementos de cada classe e prediz a classe de acordo com o centróide mais próximo. O método *k-Vizinhos Mais Próximos (k-NN, k-Nearest Neighbors)* determina a classe de uma amostra de acordo com a classe de maior representatividade entre os k vizinhos mais próximos. O método *Raio Vizinhos Mais Próximos (RNN, Radius Nearest Neighbors)* é similar ao *k-NN*, contabilizando, porém, os vizinhos mais próximos que estiverem a um determinado raio de distância da amostra.

O modelo *Máquina de Vetores de Suporte (Support Vector Machine, SVM)*, também conhecido como modelo de núcleo, utiliza diversas funções para delimitar a região de cada classe dentro do espaço de características. Os limites de cada região são

determinados pelos vetores de suporte, que são definidos pelos vetores de distância entre as amostras e os limites dentro de uma margem. O *SVM* é um problema de otimização que busca maximizar a distância da região limite com as amostras que formam os vetores de suporte.

Os modelos de *Árvore de Decisão* realizam a segmentação do espaço de características através do particionamento de seus valores. Sucessivas partições, troncos, são realizadas com a utilização de apenas uma característica por vez até se chegar aos nós finais, chamados de folhas. A ordem em que as características são segmentadas muda de acordo com sua variância entre as classes que, em problemas de classificação, podem ser determinadas pelo índice Gini ou pela entropia. A *Floresta Randômica* é um modelo similar ao anterior em que uma quantidade maior de árvores distintas é gerada a partir de um subconjunto das características selecionado aleatoriamente. Então para cada amostra, é realizada uma votação entre todas as árvores geradas para definir sua classe.

A maior parte dos modelos de aprendizado assume ou espera que a distribuição de amostras entre as classes seja balanceada ou que apresentem custos de erro de classificação iguais (HE; GARCIA, 2009). Para problemas em que há desbalanceamento de classes, um conjunto de técnicas utilizado para minimizar seu impacto é a amostragem.

As técnicas de amostragem devem ser aplicadas apenas à base de treinamento. Elas são divididas em técnicas de sobreamostragem, que aumentam o número de amostras

das classes menos representadas; sub-amostragem, que as diminuem das classes mais representadas; ou uma combinação das duas anteriores. (BATISTA; PRATI; MONARD, 2004) demonstra que as técnicas de sobreamostragem apresentam melhores resultados que as demais e que, mesmo sua técnica mais simples, o Sobreamostrador Aleatório (*Random Oversampler, ROS*), apresenta resultados próximos aos de técnicas mais complexas.

Em relação às métricas de avaliação, se uma amostra é verdadeira e classificada como verdadeira, ela é contabilizada como Verdadeira Positiva (VP), porém se ela for classificada como falsa, é Falsa Negativa (FN). Por sua vez, a amostra falsa, se classificada como verdadeira, é contabilizada como Falsa Positiva (FP), mas se classificada como falsa, é Verdadeira Negativa (VN). (FAWCETT, 2006)

A *Precisão* representa o percentual de acertos dentre todos os casos preditos para uma classe. A *Revocação*, por sua vez, representa o percentual de acertos dentro todos os casos reais de uma classe. A *F1-Score* é uma métrica que busca relacionar a *Precisão* e a *Revocação*, através da média harmônica entre ambas. Suas fórmulas são representadas por:

$$Precisão = \frac{VP}{VP + FP}$$

$$Revocação = \frac{VP}{VP + FN}$$

$$F1 - Score = \frac{2 \times Revocação \times Precisão}{Revocação + Precisão}$$

### 3- Método de *Busca em Rede*

Conforme mencionado na seção anterior, cada modelo de aprendizado de máquina possui seus hiperparâmetros ou variáveis que influenciam nos resultados do treinamento. Para cada problema ou base de dados, pode-se encontrar um conjunto de hiperparâmetros de determinado modelo ou método que otimiza seu resultado. Para uma determinada função de perda ou métrica de avaliação, existem quatro métodos de busca que se destacam para otimização deste problema.

A Figura 3 ilustra os quatro métodos para um problema hipotético com dois hiperparâmetros. O método de *Melhor suposição*, a partir de um conjunto inicial de hiperparâmetros, realiza alterações em um ou mais hiperparâmetros e avalia a alteração na métrica de avaliação. Este método, porém, é muito dependente de conhecimento prévio sobre o modelo e o problema aplicado. O método *Um fator por vez*, realiza alterações em um único hiperparâmetro por vez, porém este método não leva em consideração a interação entre os hiperparâmetros. Por sua vez, o método de *Desenho fatorial*, ou *Busca em rede (grid search)*, realiza todas as combinações de valores pré-determinados de todos os hiperparâmetros escolhidos. Apesar de seu maior custo computacional, este método permite avaliar uma quantidade de combinações de hiperparâmetros muito maior quando comparado aos demais métodos. (ALPAYDIN, 2010) Por fim, a *Busca aleatória* varia os hiperparâmetros de maneira aleatória por um número finito e pré-determinado de vezes, dentro de uma

faixa delimitada. Sua grande vantagem é o baixo custo computacional com desempenho similar à *Busca em rede*. (BERGSTRA; BENGIO, 2012)

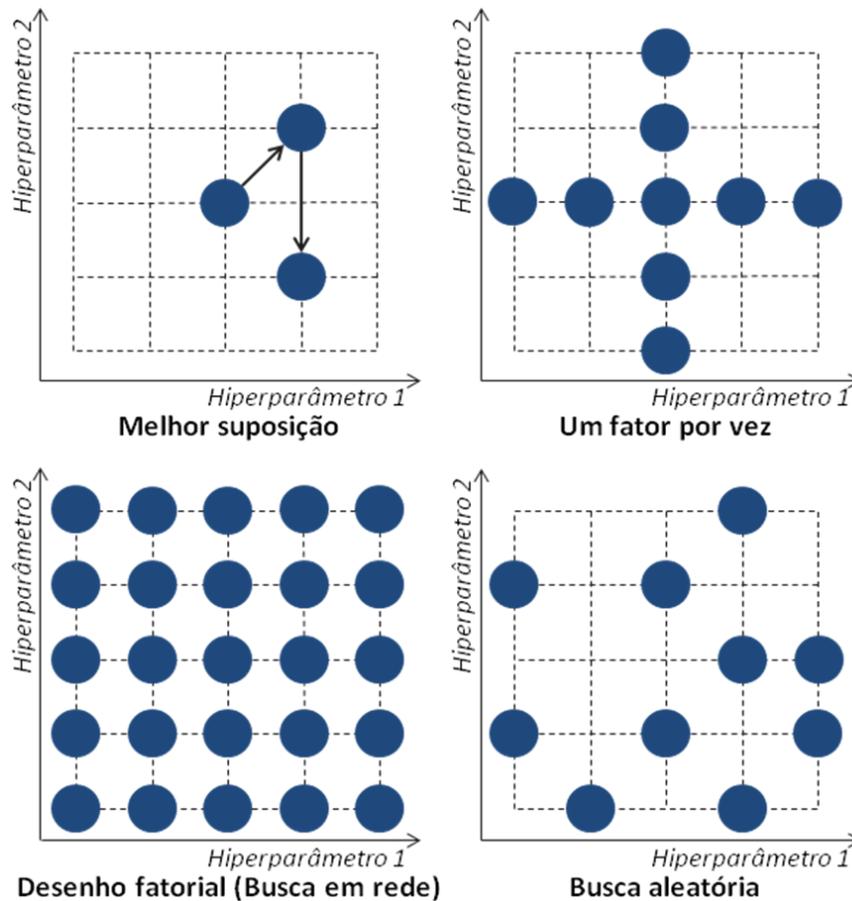


Figura 3 Diferentes métodos de busca de hiperparâmetros (adaptado de ALPAYDIN, 2010 e BERGSTRA; BENGIO, 2012)

## DIAGNÓSTICO

Para realizar a leitura da corrente de operação, utiliza-se um transdutor janelado toroidal de efeito Hall, que gera uma tensão elétrica proporcional à corrente do motor.

A tensão do transdutor é lida, convertida e armazenada em um aquisitor de dados que

é, então, enviada para um sistema supervisorizado que faz a análise de cada operação. Dois modelos de aquisição de dados são utilizados, um com taxa de amostragem de 100Hz (YOKOGAWA, 2012) e outro com taxa de amostragem de até 960Hz (LUPA TECNOLOGIA, 2014). A Figura 4 mostra um esquema da solução de aquisição de dados.

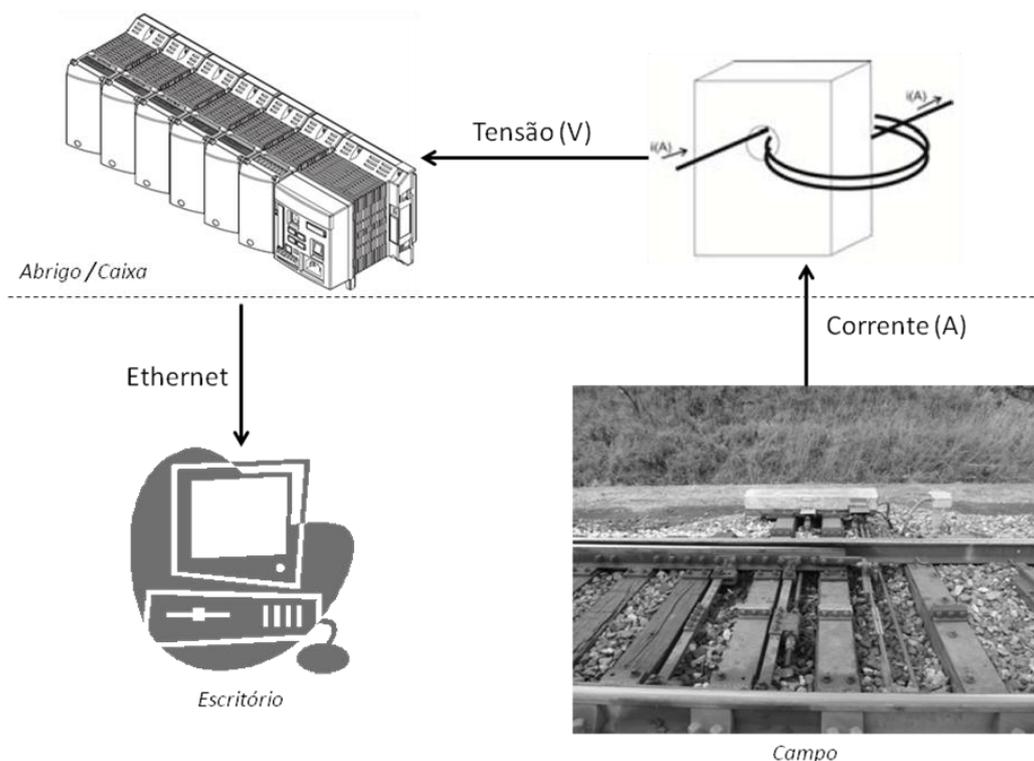


Figura 4 Solução de aquisição de dados de máquina de chave

As máquinas de chave elétricas são monitoradas por um sistema supervisorizado que analisa as leituras de cada operação e gera alarmes de tendência de falha, antes que elas efetivamente ocorram, através da variação da corrente de operação ou do tempo de operação. A grande vantagem deste sistema é a capacidade de parametrização da corrente e tempo de operação padrão para cada chave elétrica em específico. Porém,

sua grande desvantagem é não diferenciar entre alarmes gerados por tendência de falhas, *falhas incipientes*, ou por *falhas abruptas*.

A falta de separação dos alarmes por *falhas incipientes* ou *falhas abruptas* tem dois inconvenientes. O primeiro se deve aos testes de obstrução realizados mensalmente como parte da manutenção preventiva em todas as máquinas de chave elétricas. Nesses testes, toda vez que uma máquina de chave é operada com obstrução da sua ponta de agulha, um alarme é gerado. O segundo decorre do fato de que as *falhas abruptas* ocorrem sem nenhuma indicação prévia, ou seja, no momento de geração do alarme a falha já ocorreu e, possivelmente, as equipes de manutenção já foram acionadas. Estes dois casos respondem por uma parte considerável dos alarmes gerando custos para análise e separação.

Após o exposto, é conveniente a separação das operações em três grupos: *normal*, *falha abrupta* e *falha incipiente*. As operações *normais* não devem ser tratadas. As operações com *falha abrupta* não devem gerar alarmes de tendência de falha (elas servem apenas para o diagnóstico das falhas já ocorridas). Já as operações com *falha incipiente* devem gerar alarmes de tendência de falha, de preferência, antes de sua efetiva ocorrência. Caso o alarme ocorra antes da falha, as equipes de manutenção podem ser acionadas para verificação da máquina de chave, atuando de forma preventiva. Caso ocorra após a falha, o alarme pode auxiliar no diagnóstico da falha pelas equipes de manutenção.

## 26ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 7º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS



A base de leituras utilizadas neste trabalho consiste nos dados originais utilizados por DE AGUIAR *et al.* (2016) para um modelo específico de máquina de chave, sendo todas oriundas do primeiro modelo de aquisitor com taxa de amostragem de 100Hz. Todas as leituras foram obtidas de operações reais com máquinas de chave elétricas em seus locais típicos de instalação e agrupadas de acordo com seus modos de falha.

Habitualmente, a maior parte das operações das máquinas de chave é *normal*, ou seja, não é resultante de falha ou perda de função. Esse fato se reflete na base de dados, que é extremamente desbalanceada, em qualquer dos agrupamentos utilizados. Por isso, recomenda-se a utilização de técnicas de tratamento de bases desbalanceadas. A tabela 1 apresenta a quantidade de amostras de cada grupo. Quando agrupadas em operações *normais*, *falhas incipientes* e *falhas abruptas*, as respectivas quantidades são apresentadas na tabela 2. Por fim, quando se considera o detalhamento das falhas *incipientes*, suas respectivas quantidades são apresentadas na tabela 3.

Tabela 1 Quantidade de amostras de cada grupo de operação

Classificação	Número de amostras	% das amostras
Componente AMV	74	4,67
Falhas Elétricas	21	1,33
Lubrificação	27	1,71
<i>Normal</i>	1433	90,52
Obstrução PA	3	0,19
Regulagem	16	1,01
Rolete	9	0,57

Tabela 2 Quantidade de amostras agrupadas em 3 classes

Classificação	Número de amostras	% das amostras
Falhas <i>incipientes</i>	147	9,29
<i>Normal</i>	1433	90,52
Falhas <i>abruptas</i>	3	0,19

Tabela 3 Quantidade de amostras de *falhas incipientes*

Classificação	Número de amostras	% das amostras
Componente AMV	74	50,34
Falhas Elétricas	21	14,29
Lubrificação	27	18,37
Regulagem	16	10,88
Rolete	9	6,12

### 1- Extração de Características

Este trabalho utiliza como características doze parâmetros estatísticos calculados a partir das leituras das operações das máquinas de chave, os mesmos utilizados por Agboola *apud* McHutchon, Staszewski e Schmid (2005): *duração, máximo, mínimo, média, pico a pico, desvio padrão, Root Mean Square (RMS), Shape Factor, Crest Factor, Impulse Factor, Kurtosis e integral definida ou numérica.*

Inicialmente foram calculados os parâmetros estatísticos com base na série temporal completa. Entretanto, verificou-se que dividindo a curva de corrente em quatro fases, conforme o estágio de operação da máquina de chave elétrica, é possível aumentar o número de características (SHIMONAE *et al*, 1991). Dessa forma, foram calculados os mesmos parâmetros estatísticos para cada uma das quatro fases, com exceção da duração da operação. O gráfico superior da figura 5 mostra a curva da corrente ao longo do tempo numa operação normal na empresa em que os dados foram

levantados. No gráfico inferior da figura 5, um filtro de média móvel simples foi utilizado para melhor visualização.

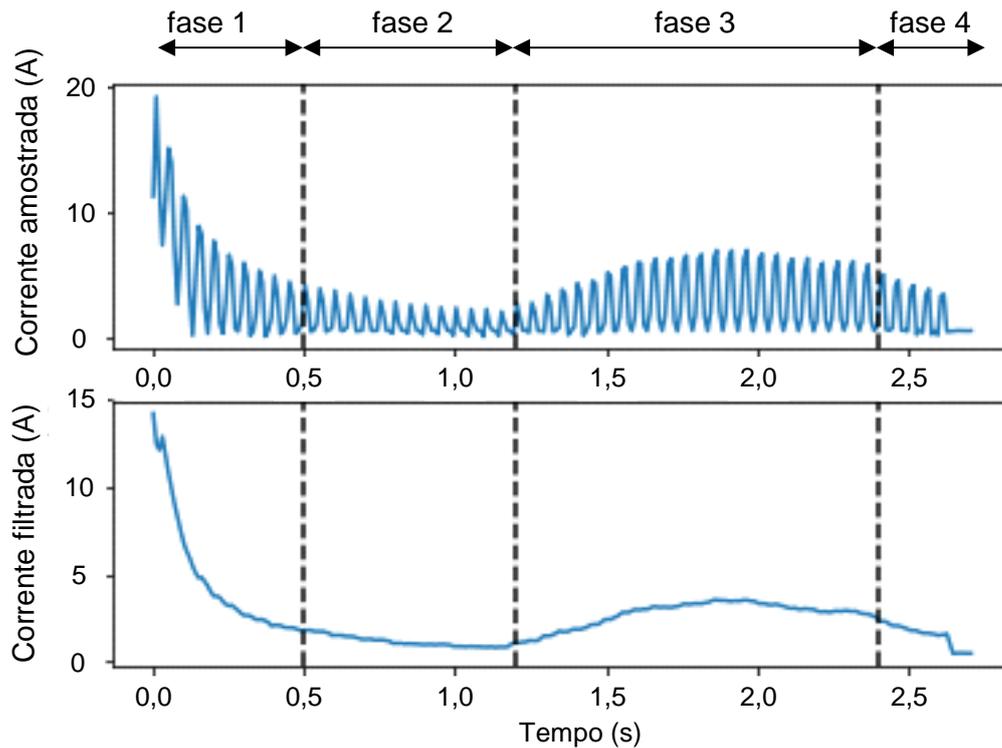


Figura 5 Exemplo de curva obtida de uma operação normal dividida em quatro fases.

## 2- Escolha do Modelo

A fim de avaliar o modelo mais adequado para os dados utilizados, foram avaliados os modelos: *Centróide Mais Próximo*, *k-NN*, *RNN*, *SVM*, *Árvores de Decisão* e *Florestas Randômicas*.

Na avaliação, separou-se a base de dados em duas partes: a base de treinamento e a base de teste, com 80% e 20% das amostras respectivamente. Em vez de realizar a

## 26ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 7º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS



separação puramente aleatória, a separação aleatória estratificada foi utilizada. Assim, manteve-se a representatividade de cada classe em cada uma das bases. A separação em duas bases reforça a independência entre as amostras utilizadas nas etapas de treinamento e teste e permite a utilização de técnicas para redução do impacto do desbalanceamento na etapa de treinamento.

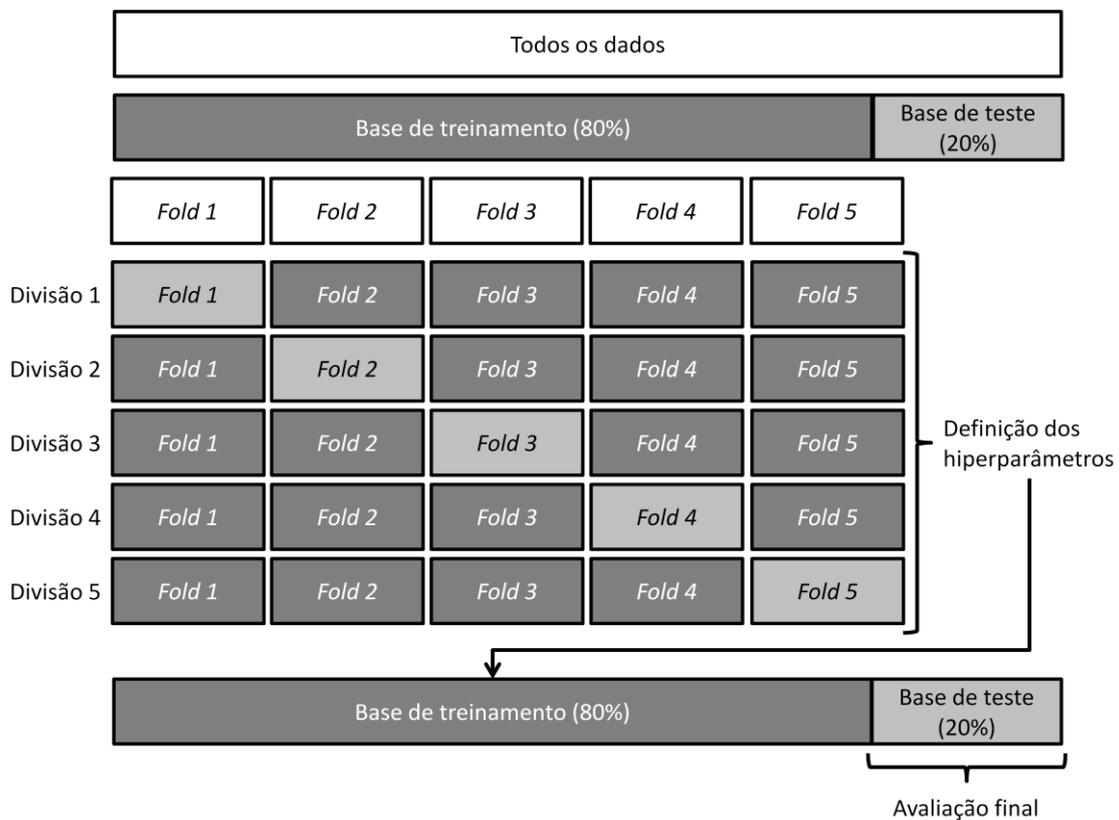
A técnica de balanceamento *Sobreamostrador Aleatório* (ROS) foi utilizada na base de treinamento a fim de melhorar o desempenho de modelos que são impactados pelo número de amostras de cada classe.

Como métrica de avaliação, utilizou-se a média macro *F1-Score* entre as classes em vez da acurácia total por se tratar de uma base de dados com representatividade de cada classe desbalanceada. Garante-se, assim, que cada classe terá a mesma relevância independentemente do número de amostras que possua. Portanto, os modelos que possuem maior valor macro *F1-Score* nas bases de teste serão considerados os melhores modelos em cada situação.

Apesar de não utilizar a acurácia para definir qual modelo apresenta melhor desempenho, verifica-se no cotidiano que a maior parte das operações é classificada como operação *normal*. Assim sendo, as operações *normais* também estão super-representadas nas bases de teste. Portanto, a métrica acurácia possui relevância e seus resultados serão apresentados junto à métrica *F1-Score*.

Com a finalidade de determinar os melhores hiperparâmetros de cada modelo, utilizou-se a *Busca em rede* (*grid search*). Para cada hiperparâmetro, os valores

possíveis foram definidos e todas as combinações desses valores foram avaliadas. Durante o processo de *Busca em rede*, utilizou-se o método de *validação cruzada K-Fold* estratificado com *K* igual a 5. Os melhores hiperparâmetros para cada modelo foram definidos pela maior média da métrica macro *F1-Score* de cada grupo da validação cruzada. A figura 6 mostra o processo de determinação dos melhores hiperparâmetros e a avaliação de desempenho do modelo.



**Figura 6 Processo de determinação dos melhores hiperparâmetros e avaliação do modelo**

## ANÁLISE DOS RESULTADOS

Nesta seção, os resultados das buscas em rede serão apresentados e analisados. Primeiramente, serão apresentados os resultados obtidos por Nunes e D'Amore (2020). Em seguida, os resultados da aplicação de técnica de sobreamostragem e da segmentação da curva da corrente elétrica do motor pelos estágios de operação da máquina de chave serão, também, apresentados e comparados com resultados anteriores. Nesta seção, a métrica média macro *F1-Score* será referenciada apenas como *F1-Score*.

Nunes e D'Amore (2020) geraram um sistema de classificação base, em que todas as classes são representadas separadamente, através da utilização da *Busca em rede* com o mesmo método de validação cruzada utilizado neste trabalho. Para este classificador, o modelo *SVM* obteve o melhor resultado com *F1-Score* de 68,33%. Todas as demais análises utilizarão este resultado como referência.

A partir do sistema base, Nunes e D'Amore (2020) melhoram seu desempenho através do agrupamento das classes em *normal*, *falha abrupta* e *falha incipiente*, que obteve *F1-Score* de 90,93% para o modelo *Árvore de Decisão*, resultado 33,1% melhor que a referência. Gerou-se, então, um sistema de classificação apenas das classes que compõem o grupo de falhas *incipientes*, que, com o modelo de *Floresta Randômica*, obteve *F1-Score* de 89,86%, 31,5% melhor que a referência. A tabela 4 apresenta os resultados da *Busca em rede* apresentados por Nunes e D'Amore (2020) com destaque para os melhores resultados para cada agrupamento.

**26ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA**  
**7º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS**



**Tabela 4 Resultados da *Busca em rede* apresentados por Nunes e D'Amore (2020)**

Modelo Aprendizado de Máquina	Todas as classes		Normal, <i>Abrupta</i> e <i>Incipiente</i>		Falhas <i>Incipientes</i>	
	<i>F1-Score</i>	Acurácia	<i>F1-Score</i>	Acurácia	<i>F1-Score</i>	Acurácia
<b>SVM</b>	<b><u>68,33%</u></b>	<b><u>83,60%</u></b>	86,78%	92,11%	83,70%	86,67%
<b>Centróide Mais Próximo</b>	32,75%	60,88%	59,54%	87,70%	39,97%	53,33%
<b>k-NN</b>	56,99%	94,64%	51,24%	93,38%	61,92%	76,67%
<b>RNN</b>	34,02%	91,48%	38,09%	91,48%	49,44%	70,00%
<b>Árvore de Decisão</b>	59,68%	91,48%	<b><u>90,93%</u></b>	<b><u>95,27%</u></b>	39,10%	53,33%
<b>Floresta Randômica</b>	67,60%	94,64%	56,06%	95,27%	<b><u>89,86%</u></b>	<b><u>90,00%</u></b>

A partir dos resultados apresentados, buscou-se aumento de desempenho através da aplicação da técnica *Sobreamostrador Aleatório* (ROS). Para ambas as classificações, o melhor desempenho foi obtido com o modelo *k-NN*. Para a classificação em três classes (*normal*, *falha abrupta* e *falha incipiente*), obteve-se *F1-Score* de 90,98%, similar ao resultado obtido sem a aplicação da técnica, mas 33,1% melhor que a referência. Porém, para a classificação das *falhas incipientes*, obteve-se *F1-Score* de 100%, resultado 46,3% melhor que a referência, e uma melhora de 11,3% sem a aplicação da

**26ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA**  
**7º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS**



técnica ROS. A tabela 5 compara os resultados obtidos para a extração de características a partir da curva completa com e sem a aplicação da técnica ROS.

**Tabela 5 Resultados obtidos com e sem aplicação de sobreamostragem**

Modelo Aprendizado de Máquina	Normal, Abrupta e Incipiente				Falhas Incipientes			
	Curva Completa		Curva Completa + ROS		Curva Completa		Curva Completa + ROS	
	F1	Acur.	F1	Acur.	F1	Acur.	F1	Acur.
<b>SVM</b>	86,78%	92,11%	83,24%	88,33%	83,70%	86,67%	86,27%	86,67%
<b>Centróide Mais Próximo</b>	59,54%	87,70%	47,45%	88,64%	39,97%	53,33%	30,42%	53,33%
<b>k-NN</b>	51,24%	93,38%	<b><u>90,98%</u></b>	<b><u>94,95%</u></b>	61,92%	76,67%	<b><u>100,00%</u></b>	<b><u>100,00%</u></b>
<b>RNN</b>	38,09%	91,48%	35,89%	85,80%	49,44%	70,00%	78,83%	83,33%
<b>Árvore de Decisão</b>	<b><u>90,93%</u></b>	<b><u>95,27%</u></b>	56,60%	94,95%	39,10%	53,33%	85,75%	86,67%
<b>Floresta Randômica</b>	56,06%	95,27%	89,55%	94,95%	<b><u>89,86%</u></b>	<b><u>90,00%</u></b>	88,38%	90,00%

É importante notar o resultado de 100% obtido para o classificador que considera apenas as falhas *incipientes*. Nota-se, também, o incremento do desempenho da técnica baseada em instâncias *k-NN* após a utilização de técnicas que buscam balancear a quantidade de amostras na base de treinamento.

## 26ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 7º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS



Outra análise foi realizada através da segmentação da curva de operação em quatro fases, conforme apresentado na seção Extração de Características. Para a classificação em três classes, obteve-se *F1-Score* de 95,67% com o modelo *k-NN*, resultado 40,0% melhor que a referência e 5,2% melhor que o resultado baseado na curva completa. Por sua vez, para a classificação das *falhas incipientes*, o *F1-Score* obtido foi de 95,33% com o modelo *Árvore de Decisão*, resultado 39,5% melhor que a referência e 6,1% melhor que o resultado baseado na curva completa. A tabela 6 compara os resultados obtidos para a extração de características a partir da curva completa contra características extraídas da curva segmentada.

**Tabela 6 Resultados obtidos com características da curva completa e da curva segmentada**

Modelo Aprendizado de Máquina	Normal, <i>Abrupta e Incipiente</i>				Falhas <i>Incipientes</i>			
	Curva Completa		Curva Segmentada		Curva Completa		Curva Segmentada	
	<i>F1</i>	Acur.	<i>F1</i>	Acur.	<i>F1</i>	Acur.	<i>F1</i>	Acur.
<b>SVM</b>	86,78%	92,11%	80,09%	95,58%	83,70%	86,67%	87,60%	90,00%
<b>Centróide Mais Próximo</b>	59,54%	87,70%	62,92%	90,22%	39,97%	53,33%	84,14%	80,00%
<b>k-NN</b>	51,24%	93,38%	<b><u>95,67%</u></b>	<b><u>98,42%</u></b>	61,92%	76,67%	90,68%	90,00%
<b>RNN</b>	38,09%	91,48%	39,04%	94,32%	49,44%	70,00%	69,92%	76,67%
<b>Árvore de Decisão</b>	<b><u>90,93%</u></b>	<b><u>95,27%</u></b>	59,42%	96,53%	39,10%	53,33%	<b><u>95,33%</u></b>	<b><u>93,33%</u></b>
<b>Floresta Randômica</b>	56,06%	95,27%	66,10%	99,68%	<b><u>89,86%</u></b>	<b><u>90,00%</u></b>	89,86%	90,00%

Por fim, aplicaram-se ambas as técnicas apresentadas anteriormente. Para a classificação em três classes, obteve-se *F1-Score* de 100% com o modelo *Árvore de Decisão*, resultado 46,3% superior à referência e 10,0% melhor que o resultado baseado na curva completa. Por sua vez, para a classificação das *falhas incipientes*, o *F1-Score* obtido foi de 97,77% com o modelo *Árvore de Decisão*, resultado 43,1% superior à referência e 8,8% melhor que o resultado baseado na curva completa. A

**26ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA**  
**7º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS**



tabela 7 compara os resultados obtidos para a extração de características a partir da curva completa com os obtidos pelas características extraídas da curva segmentada junto à técnica de sobreamostragem.

**Tabela 7 Resultados obtidos com características da curva completa e da curva segmentada com sobreamostragem**

Modelo Aprendizado de Máquina	Normal, <i>Abrupta e Incipiente</i>				Falhas <i>Incipientes</i>			
	Curva Completa		Curva Segmentada + ROS		Curva Completa		Curva Segmentada + ROS	
	<i>F1</i>	Acur.	<i>F1</i>	Acur.	<i>F1</i>	Acur.	<i>F1</i>	Acur.
<b>SVM</b>	86,78%	92,11%	85,03%	98,11%	83,70%	86,67%	87,60%	90,00%
<b>Centróide Mais Próximo</b>	59,54%	87,70%	63,69%	90,54%	39,97%	53,33%	88,00%	83,33%
<b>k-NN</b>	51,24%	93,38%	97,54%	98,74%	61,92%	76,67%	94,18%	93,33%
<b>RNN</b>	38,09%	91,48%	43,03%	94,95%	49,44%	70,00%	80,66%	83,33%
<b>Árvore de Decisão</b>	<b><u>90,93%</u></b>	<b><u>95,27%</u></b>	<b><u>100,00%</u></b>	<b><u>100,00%</u></b>	39,10%	53,33%	67,15%	70,00%
<b>Floresta Randômica</b>	56,06%	95,27%	98,01%	99,05%	<b><u>89,86%</u></b>	<b><u>90,00%</u></b>	<b><u>97,77%</u></b>	<b><u>96,67%</u></b>

Curiosamente, em ambos os agrupamentos, os melhores modelos resultantes da aplicação das duas técnicas são os mesmos obtidos sem a aplicação de nenhuma das técnicas, com a ressalva de que o desempenho daqueles é melhor. Importante notar o

**26ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA**  
**7º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS**



excelente resultado de 100% obtido para a classificação das operações em *normal*, *falha abrupta* e *falha incipiente*.

A tabela 8 apresenta um resumo comparativo dos melhores modelos obtidos para cada combinação de técnica e agrupamento utilizados.

**Tabela 8 Comparativo dos melhores modelos obtidos para cada combinação de técnicas e agrupamento**

<b>Agrupamento</b>	<b>Métodos utilizados</b>	<b>Melhor Modelo</b>	<b>F1-Score</b>	<b>Acurácia</b>
<b>Normal, <i>abrupta</i> e <i>incipiente</i></b>	Curva Completa	Árvore de Decisão	90,93%	95,27%
<b>Normal, <i>abrupta</i> e <i>incipiente</i></b>	Curva Completa + ROS	<i>k-NN</i>	90,98%	94,95%
<b>Normal, <i>abrupta</i> e <i>incipiente</i></b>	Curva Segmentada	<i>k-NN</i>	95,67%	98,42%
<b>Normal, <i>abrupta</i> e <i>incipiente</i></b>	Curva Segmentada + ROS	Árvore de Decisão	<u>100,00%</u>	<u>100,00%</u>
<b>Falhas <i>incipientes</i></b>	Curva Completa	Floresta Randômica	89,86%	90,00%
<b>Falhas <i>incipientes</i></b>	Curva Completa + ROS	<i>k-NN</i>	<u>100,00%</u>	<u>100,00%</u>
<b>Falhas <i>incipientes</i></b>	Curva Segmentada	Árvore de Decisão	95,33%	93,33%
<b>Falhas <i>incipientes</i></b>	Curva Segmentada + ROS	Floresta Randômica	97,77%	96,67%

Analisando-se os melhores resultados obtidos dentre as combinações de agrupamento e métodos aplicados, percebe-se que, dentre os sete modelos de aprendizado de máquina utilizados para a *Busca em rede*, três deles aparecem com melhor desempenho em pelo menos uma das combinações. Este fato reforça a constatação de que não existe melhor modelo para todos os casos, pois, mesmo com a utilização da mesma base de dados, ao se utilizar diferentes técnicas de extração de características e de balanceamento, resultados diferentes são obtidos.

É possível verificar, também, que, para cada agrupamento, encontrou-se um modelo, com seus respectivos hiperparâmetros, com desempenho ótimo, ou seja, com resultado de média macro *F1-Score* de 100%.

Por fim, como o objetivo inicial é a separação das operações entre normal, falha *abrupta* e falha *incipiente*, pois cada uma tem uma finalidade diferente, o melhor modelo encontrado é a *Árvore de Decisão*. Além disso, percebe-se que as técnicas propostas de extração de características diferenciada e balanceamento da base de treinamento por sobreamostragem conduziram ao melhor resultado possível, dentre as combinações avaliadas.

## **CONCLUSÕES**

A técnica *Grid Search*, aplicada ao Aprendizado de Máquina, é um método robusto para a classificação de falhas em Máquinas de Chave elétricas ferroviárias para fins de

diagnóstico e prognóstico de falhas. Por meio da contextualização da geração de alarmes indevidos pelo sistema utilizado atualmente na empresa, foi possível corrigir este problema. Para tal, aplicaram-se técnicas de *Busca em rede* para encontrar os modelos, e seus respectivos hiperparâmetros, que obtivessem o melhor resultado para a métrica de avaliação utilizada dentre os modelos utilizados em outros trabalhos relacionados.

Os modos de falha das máquinas de chave foram agrupados em relação ao tratamento que será dado a cada grupo: *normal, falha abrupta e falha incipiente*. Aplicaram-se, também, diferentes métodos de extração de características e um método para balanceamento das classes da base de dados utilizada.

Assim, verificou-se que, para cada agrupamento e conjunto de técnicas utilizadas, encontraram-se modelos e hiperparâmetros diferentes com melhor desempenho, reforçando a máxima de que não existe o melhor modelo para todos os casos.

Constatou-se, também, que, com a utilização das técnicas apresentadas, foi possível encontrar sistemas classificadores ótimos, com média macro *F1-Score*, e, por consequência, acurácia, de 100% para ambos os agrupamentos de três classes e de falhas *incipientes*. Apesar da quantidade de amostras para testes dos modelos ser pequena e desbalanceada, a independência da base de testes em relação à base de treinamento reforça a qualidade dos resultados obtidos.

Por fim, encontrou-se que o melhor modelo para o problema proposto é a *Árvore de Decisão* em conjunto com as técnicas de extração de características, baseada na

segmentação das fases da operação da máquina de chave, e balanceamento de amostras de cada classe apresentadas.

## **REFERÊNCIAS BIBLIOGRÁFICAS**

AGBOOLA, O. O. **Intelligent ‘finger printing’ approach to structural health monitoring.**

2001. MEng Thesis. University of Sheffield, Sheffield *apud* MCHUTCHON, M. A.;

STASZEWSKI, W. J.; SCHMID, F. Signal processing for remote condition monitoring of railway points. **Strain**, v. 41, n. 2, p. 71-85, 2005.

ALPAYDIN, E. **Introduction to Machine Learning.** 2<sup>nd</sup> ed. Cambridge: The MIT Press, 2010. 584 p.

ASADA, T.; ROBERTS, C.; KOSEKI, T. An algorithm for improved performance of railway condition monitoring equipment: Alternating-current point machine case study.

**Transportation Research Part C: Emerging Technologies**, v. 30, p. 81-92, 2013.

BATISTA, G. E.; PRATI, R. C.; MONARD, M.-C. A study of the behavior of several methods for balancing machine learning training data. **ACM SIGKDD explorations newsletter**, v. 6, n. 1, p. 20-29, 2004.

BERGSTRA, J.; BENGIO, Y. Random search for hyper-parameter optimization. **Journal of machine learning research**, v. 13, n. Feb, p. 281-305, 2012.

DE AGUIAR, E. P. *et al.* EANN 2014: a fuzzy logic system trained by conjugate gradient methods for fault classification in a switch machine. **Neural Computing and Applications**, v. 27, n. 5, p. 1175-1189, 2016.

DUDA, R.; HART, P. E.; STORK, D. G. **Pattern Classification**. 2<sup>nd</sup> ed. New York: John Wiley & Sons, 2000. 380 p.

EKER, O. F.; CAMCI, F.; KUMAR, U. Failure diagnostics on railway turnout systems using support vector machines. In: **International Workshop and Congress on eMaintenance: 22/06/2010-24/06/2010**. Luleå tekniska universitet, 2010. p. 248-251.

FAWCETT, T. An introduction to ROC analysis. **Pattern recognition letters**, v. 27, n. 8, p. 861-874, 2006.

FU, C. *et al.* Predictive maintenance in intelligent-control-maintenance-management system for hydroelectric generating unit. **IEEE transactions on energy conversion**, v. 19, n. 1, p. 179-186, 2004 *apud* SHIN, J.-H.; JUN, H.-B. On condition based maintenance policy. **Journal of Computational Design and Engineering**, v. 2, n. 2, p. 119-127, 2015.

GUO, Z. *et al.* A hybrid feature extraction method for fault detection of turnouts. In: **2017 Chinese Automation Congress (CAC)**. IEEE, 2017. p. 540-545.

HE, H.; GARCIA, E. A. Learning from imbalanced data. **IEEE Transactions on knowledge and data engineering**, v. 21, n. 9, p. 1263-1284, 2009.

JAMES, G. *et al.* **Introduction to Statistical Learning**. New York: Springer, 2013. 426 p.

**26ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA**  
**7º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS**



LUPA TECNOLOGIA. **Monitor de Parâmetros Ferroviários MPF: Manual do Usuário.** Revisão 03. 2014.

MATEI, I. *et al.* The Case for a Hybrid Approach to Diagnosis: A Railway Switch. In: **DX@ Safeprocess.** 2015. p. 225-234.

MCHUTCHON, M. A.; STASZEWSKI, W. J.; SCHMID, F. Signal processing for remote condition monitoring of railway points. **Strain**, v. 41, n. 2, p. 71-85, 2005.

MITCHELL, T. M. **Machine Learning.** New York: McGraw-Hill, 1997. 432 p.

MOREIRA, G.; KALLEMBACK, G. M.; BARBOSA, W. Desenvolvimento de Sistema Automático de Identificação de Modos de Falhas em Máquinas de Chave Utilizando Inteligência Artificial. In: **22ª Semana de Tecnologia Metroferroviária**, 2016, São Paulo.

NUNES, C; D'AMORE, R. Monitoramento de Máquinas de Chave por Corrente de Operação. In: **VI Encontro de Ferrovias ANTF**, 6., 2020, Curitiba. Aceito para publicação.

POONGODAI, A.; BHUVANESWARI, S. AI Technique in Diagnostics and Prognostics. **International Journal of Computer Applications**, v. 975, p. 8887, fev. 2013.

PYTHON SOFTWARE FOUNDATION. **Python – About.** Disponível em <https://www.python.org/about/>. Acessado em 24/06/2020.

RELIASOFT. **Reliability Engineering eTextBook Library – System Analysis Reference: Reliability, Availability and Optimization.** Disponível em:

**26ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA**  
**7º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS**



[http://reliawiki.com/index.php/Introduction\\_to\\_Repairable\\_Systems](http://reliawiki.com/index.php/Introduction_to_Repairable_Systems). Acessado em 14/06/2020.

SHIMONAE, T. *et al.* Development of a monitoring system for electric point machines. In: **IRSE Aspect Int Conf**. 1991. p. 395-401.

SHIN, J.-H.; JUN, H.-B. On condition based maintenance policy. **Journal of Computational Design and Engineering**, v. 2, n. 2, p. 119-127, 2015.

THEEG, G.; VLASENKO, S. **Railway signalling & interlocking**. International Compendium. Hamburg, Eurail-press Publ, v. 448, 2009.

UNITED STATES. Department of Transportation. **Electronic Code of Federal Regulations**: Title 49, Subtitle B, Chapter II, Part 236. Washington, DC: DoT, 2020.

Disponível em: [https://www.ecfr.gov/cgi-bin/text-idx?SID=13e31b70b58a68a0d2734b0815d253a6&mc=true&tpl=/ecfrbrowse/Title49/49cfr236\\_main\\_02.tpl](https://www.ecfr.gov/cgi-bin/text-idx?SID=13e31b70b58a68a0d2734b0815d253a6&mc=true&tpl=/ecfrbrowse/Title49/49cfr236_main_02.tpl). Acessado em: 14/06/2020.

YOKOGAWA. **User's Manual**: MW100 Data Acquisition Unit. 4<sup>th</sup> ed. 2012.