



**CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS
GERAIS UNIDADE ARAXÁ**

JAÍNA CRISTINA GOMES CINTRA

**DETERMINAÇÃO DO FATOR DE SEGURANÇA EM TALUDES DE
SOLO POR MEIO DO RANDOM FOREST**

ARAXÁ-MG

2022

JAÍNA CRISTINA GOMES CINTRA

**DETERMINAÇÃO DO FATOR DE SEGURANÇA EM TALUDES DE
SOLO POR MEIO DO RANDOM FOREST**

Trabalho de Conclusão de Curso
apresentado ao Centro Federal de
Educação Tecnológica de Minas
Gerais - Unidade Araxá, como
requisito parcial para obtenção do
grau de Bacharel em Engenharia
de Minas.

Orientador: Dr. Allan Erlikhman
Medeiros Santos

Coorientador: Me. Leonardo
Vinícius Paixão Daciolo

ARAXÁ-MG

2022


DETERMINAÇÃO DO FATOR DE SEGURANÇA EM TALUDES DE SOLO POR MEIO DO RANDOM FOREST

Trabalho de Conclusão de Curso
apresentado ao Centro Federal de
Educação Tecnológica de Minas
Gerais - Unidade Araxá, como
requisito parcial para obtenção do
grau de Bacharel em Engenharia
de Minas.


Araxá, 05 de dezembro de 2022.




Prof. Dr. Allan Erlikhman Medeiros Santos, Engenheiro de Minas
Centro Federal de Educação Tecnológica de Minas Gerais



Prof. Me. Leonardo Vinícius Paixão Daciolo
Centro Federal de Educação Tecnológica de Minas Gerais



Prof. Me. Guilherme Alzamora Mendonça, Engenheiro de Minas
Centro Federal de Educação Tecnológica de Minas Gerais



Geol. Me. Sérgio Túlio de Pinho Tavares, Geólogo
Mosaic Fertilizantes Ltda.

DEDICATÓRIA

DEDICO ESTE TRABALHO

Aos meus pais que sempre me fizeram acreditar na realização dos meus sonhos e trabalharam muito para que eu pudesse realizá-los.

AGRADECIMENTOS

Agradeço aos meus pais, que sempre me apoiaram mesmo quando eu não sabia o que eu queria para mim. Não que agora eu saiba completamente, mas com o tempo as coisas vão ficando mais claras. O aprendizado que vamos cultivando ao longo dos anos e após alguns tombos fazem a gente mudar, as vezes para pior ou melhor, mas isso depende unicamente de você, sempre levante a cabeça e continue a busca pelos seus sonhos.

Agradeço imensamente a Deus por todas as oportunidades e todas as bênçãos divinas a mim designadas, sendo sempre meu suporte nos momentos mais conturbados e me mostrando a luz no fim da tempestade.

Agradeço todo o suporte e paciência de meu orientador Prof. Me. Allan Erlikhman Medeiros Santos, que acreditou em meu potencial e me ajudou ao longo desta jornada acadêmica, te desejo todo sucesso do mundo nesta nova jornada que se inicia, as vezes mudanças são necessárias para que o crescimento seja possível.

Agradeço a todos os professores que conheci ao longo de minha vida por todo conhecimento passado, em especial ao Me. Leonardo Vinícius Paixão Daciolo, que foi meu coorientador, contribuindo de uma maneira muito positiva neste trabalho.

Agradeço a todos os meus amigos, aos que fiz ao longo destes cinco anos tanto no CEFET ou fora e aos que são de longa data, que sempre proporcionaram grandes momentos de distração e algumas centenas de horas de gargalhada, além claro dos grandes momentos reclamando que não poderia ficar de fora e alguns delírios nos momentos de exaustão.

EPÍGRAFE

“A mais bela coisa que podemos vivenciar é o mistério. Ele é fonte de qualquer arte verdadeira e qualquer ciência. Aquele que desconhece esta emoção, aquele que não para mais para pensar e não se fascina, está como morto: seus olhos estão fechados .”

ALBERT EINSTEIN

“Ao homem que teme ao senhor, ele o instruirá no caminho que deve escolher. Na prosperidade repousará a sua alma e a sua descendência herdará a Terra .”

Salmo 25; 12:13

RESUMO

A determinação do fator de segurança para taludes em maciços em rocha e/ou solos constitui uma etapa fundamental de um estudo inicial de estabilidade de taludes. Sabe-se que o fator de segurança é dependente de diversos parâmetros, relacionados às forças de resistência e as forças mobilizadoras atuantes naquela estrutura. Atualmente a tecnologia em aquisição e tratamento de dados têm permitido a aplicação de diversas técnicas não paramétricas na geomecânica, tanto para rochas como para solos. Neste contexto, a presente pesquisa tem como objetivo criar um modelo preditivo para determinação do fator de segurança em taludes para ruptura circular, utilizando técnicas de aprendizado em máquinas. O banco de dados utilizado foi organizado pela professora Maria Ferentinou, disponibilizado na Geotechnical and Geological Engineering. A priori, o banco foi utilizado para criação de modelos de predição por redes neurais artificiais. O banco é composto por 59 amostras e suas variáveis são geométricas, tais como: altura e inclinação do talude; parâmetros de resistência, tais como: ângulo de atrito e coesão; condições de fluxo: taxa de poropressão; além disso o peso específico. Os parâmetros apresentados são de fato critérios relevantes em análise de estabilidade de taludes em solo. Além disso o banco de dados apresenta como variável *target*, o fator de segurança. A técnica utilizada para a construção dos modelos será o Random Forest, que permite além de criar o modelo preditivo, avaliar a importância das variáveis para o modelamento por meio de índice Gini. Para este banco de dados alguns modelos já foram propostos, utilizando redes neurais artificiais e outro utilizando análise discriminante, com resultados promissores. Para a presente pesquisa o modelo será feito utilizando amostra de treino e amostra de teste, onde a validação será feita utilizando RMSE que é a medida que calcula a raiz quadrática média dos erros entre valores do fator de segurança real e o estimado; o MAE que calcula o erro absoluto médio dos erros entre valores de segurança real e o estimado; e o coeficiente de correlação de Pearson na regressão entre o fator de segurança real e o estimado. Como resultado, têm-se o modelo que permite indicar a sensibilidade do fator de segurança em função dos modelos de predição e classificação utilizando gráficos de dispersão e matriz de confusão. Posto isso, a pesquisa contribui com um modelo que permite indicar taludes com maior risco em função da variação de seus parâmetros, auxiliando a tomada de decisão na indicação de áreas de maior risco, como um sistema de recomendação. Apresentando resultados satisfatórios para o método devido ao ajuste do *Random Forest* para treinamento, para o modelo de classificação apenas um dado foi classificado de forma errônea mostrando que o modelo apresenta uma metodologia confiável.

Palavras-chave: Fator de segurança. *Random forest*. Estabilidade de taludes.

ABSTRACT

Determining the factor of safety for massive slopes in rock and/or soil is a fundamental step in an initial slope stability study. It is known that the safety factor is dependent on several parameters, related to resistance forces as mobilizing forces acting on the structure. Currently, the technology in application and data processing has allowed several non-parametric techniques in geomechanics, both for rocks and soils. In this, the present research aims to create a predictive model to determine the factor of safety in slopes for circular failure, using machine learning techniques. The database used was organized by Professor Maria Ferentinou, available at Geotechnical and Geological Engineering. A priori, the database was used to create prediction models by artificial neural networks. The bank is composed of 59 samples and its variables are geometric, such as: bank height and slope slope; resistance parameters such as: resistance angle and such; flow conditions: pore pressure rate; in addition the specific weight. The parameters presented are in fact relevant in soil slope stability analysis. In addition, the database has a variable target, the factor of safety. A technique used for the construction of Random Forest models, which will allow creating the predictive model, evaluating the importance of the variables for the model through the Gini index. For this database, some models have already been proposed, using artificial neural networks and another using discriminant analysis, with promising results. For the present research, the model will be made using a training sample and a test sample, where the validation will be done using RMSE, which is the measure that calculates the root mean square of the errors between values of the real safety factor and the estimating; the MAE that calculates the mean absolute error of the errors between real and estimated safety values; and Pearson's correlation coefficient in the regression between the real and the estimated factor of safety. As a result, we have the model that allows us to indicate the sensitivity of the safety factor as a function of the prediction and classification models used. That said, the research contributes with a model that allows to indicate slopes with greater risk due to the variation of their parameters, helping the decision making in the indication of areas of greater risk, as a recommendation system. Presenting satisfactory results for the method due to the adjustment of the Random Forest for training, for the classification model only one data was classified in an erroneous way, showing that the model presents a reliable methodology.

Keywords: Safety factor. Random forest. Slope Stability.

ÍNDICE DE ILUSTRAÇÕES

Figura 1 - Terminologia para taludes	18
Figura 2 - Efeito escala em maciços rochosos	20
Figura 3 - Representação efeito escala em taludes de 30,90 e 500m	20
Figura 4 - Características encontradas no maciço	23
Figura 5 - Modelo de ruptura planar	28
Figura 6 - Representação ruptura em cunha	29
Figura 7 - Representação do tombamento flexural	30
Figura 8 - Representação do tombamento de blocos	30
Figura 9 - Representação do tombamento bloco-flexural	31
Figura 10 - Representação da ruptura circular pelo método de fatias	32
Figura 11 - Forças atuantes em uma fatia	33
Figura 12 - Talude em fatias	38
Figura 13 - Convenção de sinais para a direita e à esquerda	38
Figura 14 - Geometria de talude definida por Taylor	40
Figura 15 - Localização dos círculos de pé com inclinação superior a 54°	41
Figura 16 - Representação de Bishop e Morgenstern	42
Figura 17 - Árvore de classificação do aprendizado em a máquina	46
Figura 18 - Exemplo de árvore de decisão	49
Figura 19 - Etapas de funcionamento do Random Forest	54
Figura 20 - Exemplo de regressão	56
Figura 21 - Fluxograma de desenvolvimento de Santos e Silva (2021)	64
Figura 22 - Fluxograma de desenvolvimento do trabalho	67
Figura 23 - Fluxograma para modelo de regressão	68
Figura 24 - Widgets: avaliação de treinamento	69

Figura 25 - Definição do Random Forest	71
Figura 26 - Localização widgets de predição no Orange	72
Figura 27 - Widgets: construção da variável erro	72
Figura 28 - Widgets: gráfico de dispersão	74
Figura 29 - Widgets: configuração de histograma	74
Figura 30 - Fluxograma para o modelo de classificação	75
Figura 31 - Resultados do erro no modelo de regressão	78
Figura 32 - Gráfico de dispersão para treino: fator de segurança vs predito	79
Figura 33 - Histograma de frequência do erro para treino	80
Figura 34 - Fator de segurança proposto pelo Random Forest para teste	81
Figura 35 - Interpolação do erro em valores conservadores vs risco	83
Figura 36 - Histograma erro vs frequência do erro	84
Figura 37 - Gráfico de dispersão: Random Forest vs fator de segurança	85
Figura 38 - Resultados da avaliação de treinamento para classificação	86
Figura 39 - Resultados gráficos para o modelo treino de classificação	87
Figura 40 - Matriz de confusão	88
Figura 41 - Classificação da estabilidade para modelo classificatório de teste	89
Figura 42 - Predição de estabilidade vs FS	90

ÍNDICE DE TABELAS

Tabela 1 - Descrição do espaçamento	24
Tabela 2 - Descrição da persistência	24
Tabela 3 - Grau de alteração	25
Tabela 4 - Grau de rugosidade	25
Tabela 5 – Comparação entre os métodos de análise de ruptura	43
Tabela 6 - Modelos com as principais funções	45
Tabela 7 - Matriz de confusão	76

ÍNDICE DE SIGLAS

NBR	Norma Brasileira Regulamentadora
FS	Fator de segurança
ABGE	Associação Brasileira de Geologia de Engenharia
S	Estabilidade
RNA	Rede neural artificial
PCA	<i>Principal components analysis</i>
OPS	<i>Overall probability sucess</i>
MSE	<i>Mean Squared Error</i>
RMSE	<i>Root Mean Squared Error</i>
MAE	<i>Mean Absoluto Error</i>
CA	<i>Classification accuracy</i>
AUC	<i>Area under ROC</i>
AA	Ângulo de atrito
C	Coesão
ROC	<i>Receiver Operating Characteristic</i>

SUMÁRIO

1. INTRODUÇÃO	15
2. REFERENCIAL TEÓRICO	17
2.1. CONCEITOS INICIAIS	17
2.2. EFEITO ESCALA	18
2.3. ESTRUTURA DO MACIÇO ROCHOSO	20
2.3.1. DEFINIÇÃO DE MACIÇO ROCHOSO	20
2.3.2. CARACTERIZAÇÃO DE DESCONTINUIDADES	21
2.4. ESTABILIDADE DE TALUDE	25
2.4.1. FATOR DE SEGURANÇA	25
2.4.2. TIPOS DE RUPTURA	26
2.4.3. RUPTURA CIRCULAR	30
2.5. ANÁLISE DE ESTABILIDADE PARA RUPTURA CIRCULAR	31
2.5.1. MÉTODO DE FATIAS	31
2.5.2. MÉTODO DE BISHOP	35
2.5.3. MÉTODO DE JANBU	38
2.5.4. MÉTODO DE TAYLOR	39
2.5.5. MÉTODO DE BISHOP E MORGENSTERN	41
2.6. ÁGUA SUBTERRÂNEA E TENSÕES EFETIVAS	43
2.7. APRENDIZADO EM MÁQUINA	43
2.7.1. TIPOS DE APRENDIZAGEM	43
2.7.2. ÁRVORE DE DECISÃO	47
2.7.2.1. CONCEITOS INICIAIS	47
2.7.2.2. ESTRUTURA DAS ÁRVORES	47
2.7.2.3. ÍNDICE OU PUREZA DE GINI	50

2.7.3. RANDOM FOREST	51
2.7.4. VALIDAÇÃO DOS MODELOS DE REGRESSÃO	54
2.7.5. VALIDAÇÃO DOS MODELOS DE CLASSIFICAÇÃO	56
2.8. ESTABILIDADE DE TALUDES UTILIZANDO REDES NEURAIS ARTIFICIAIS- ESTUDO DE SAKELLARIOU E FERENTINOU (2004)	57
2.8.1. HISTÓRICO	57
2.8.2. BANCO DE DADOS	58
2.8.3. METODOLOGIA APLICADA	59
2.8.4. RESULTADOS OBTIDOS	60
2.9. ESTABILIDADE DE TALUDES UTILIZANDO ANÁLISE DISCRIMINANTE - ESTUDO SANTOS E SILVA (2021)	61
2.9.1. HISTÓRICO	61
2.9.2. BANCO DE DADOS	62
2.9.3. METODOLOGIA APLICADA	62
2.9.4. RESULTADOS OBTIDOS	63
3. METODOLOGIA	64
3.1. MATERIAIS	64
3.2. PARTIÇÃO DO BANCO DE DADOS	64
3.3. MÉTODOS	65
3.4. DESENVOLVIMENTO DO RANDOM FOREST	66
3.5. MODELO DE REGRESSÃO	67
3.5.1. METODOLOGIA	67
3.5.2. VALIDAÇÃO	72
3.6. MODELO DE CLASSIFICAÇÃO	74
3.6.1. METODOLOGIA	74

3.6.2. VALIDAÇÃO	75
4. RESULTADOS E DISCUSSÕES	77
4.1. MODELO DE REGRESSÃO: TREINO	77
4.2. MODELO DE REGRESSÃO: TESTE	79
4.3. MODELO DE CLASSIFICAÇÃO: TREINO	84
4.4. MODELO DE CLASSIFICAÇÃO: TESTE	87
5 CONCLUSÃO.....	90
6 REFERÊNCIAS.....	91
APÊNDICE	96
SCRIPT MODELO DE REGRESSÃO:	97
SCRIPT MODELO DE CLASSIFICAÇÃO:	106
ANEXOS	120
BANCO DE DADOS FERENTINOU.....	120
ÁBACOS DE BISHOP E MORGENSTERN	121
ÁBACOS DE TAYLOR.....	127

1. INTRODUÇÃO

A instabilidade de taludes é um grande problema enfrentado, principalmente nos períodos chuvosos onde o maciço sofre bastante com a percolação da água em seus espaços vazios. Desta forma colocando a vida de diversas pessoas em riscos, além dos danos patrimoniais e ambientais. Segundo a Associação Brasileira de Geologia de Engenharia e Ambiental (ABGE, 1998), e citado por Marangon (2018) a execução de cortes nos maciços pode condicionar movimentos de massa ou, mais especificamente, deslizamentos de taludes, quando as tensões cisalhantes atuantes no maciço excedem a sua resistência ao cisalhamento, ao longo de superfícies de ruptura específicas, com isso é natural que os taludes provenientes da má execução de aterros possam também levar ao movimento de massas de solos.

Para se fazer uma análise de estabilidade de taludes, em uma abordagem determinística, o principal fator a ser determinado é o fator de segurança que de acordo com a norma brasileira de estabilidade de taludes NBR 11682 (ABNT, 2009), o fator de segurança (FS) é a relação entre os esforços estabilizantes e esforços instabilizantes, para determinado método de cálculo.

Um talude pode ser considerado estável quando os esforços instabilizantes forem menores que os estabilizantes, assim a avaliação de estabilidade dos taludes é indispensável independente da obra seja em uma mina a céu aberto em bancadas, estoques de minério e estéril, barragens entre diversas outras obras. A norma brasileira de estabilidade de taludes NBR 11682 (2009) recomenda valores mínimos de fator de segurança, com base em níveis de segurança para danos materiais, ambientais, patrimoniais e de riscos à saúde e à vida.

O objetivo deste trabalho é a criação de dois modelos: um preditivo e o outro classificatório para determinar o fator de segurança utilizando técnicas de aprendizagem em máquinas, mais especificamente o Random Forest.

A ruptura circular que está sendo analisada é comumente encontrada em taludes de mina, rodoviários e urbanos. Podendo acontecer em maciços rochosos extremamente fraturados de grande porte, rochas muito alteradas e em solos. Segundo Fontinhas 2012 apud Hoek & Bray 1981 uma descontinuidade

pouco espaçada, com pressões intersticiais elevadas, assim como uma alteração de suas características intrínsecas intensa no caso dos maciços rochosos, pode ocasionar este tipo de movimento.

Os bancos de dados utilizados neste trabalho foram organizados pela professora Maria Ferentinou em seu doutorado na Universidade de Atenas na Grécia, onde ela aplicou redes neurais artificiais tanto para regressão como classificação. O conjunto de dados é constituído por 46 amostras de estudos de caso de estabilidade, sendo que destes 29 são instáveis e 17 estão estáveis, este banco utilizado no estudo de ruptura circular. A presente pesquisa aplicou uma técnica de aprendizado de máquinas, o *Random Forest*, técnica que cria uma floresta de árvores de decisão, com uma estrutura que se assemelha com um fluxograma onde cada uma das condições impostas é verificada. Os dados de treino buscam as melhores condições e resultados para o banco de dados em estudo, utilizando o algoritmo de entropia ou o índice de Gini que é utilizado para medições de desigualdade.

Desta forma o objetivo deste trabalho é gerar dois modelos um modelo preditivo e outro classificatório que irá indicar a sensibilidade do fator de segurança em função dos parâmetros encontrados nos bancos de dados, contribuindo com um modelo que seja capaz de indicar taludes com maior risco em função da variação de seus parâmetros, de forma que auxilie nas decisões para indicar uma área de maior risco, como um sistema de recomendação.

Além da realização de uma análise da diferença encontrada entre os modelos propostos e os valores encontrados através de cálculos matemáticos que são mostrados no banco de dados em estudo para o fator de segurança.

Averiguando dessa forma a viabilidade do método proposto que é um método rápido e preditivo de antecipação da ruptura, porém ele não substitui os cálculos do fator de segurança, funcionando como um sistema de recomendação.

2. REFERENCIAL TEÓRICO

2.1. Conceitos iniciais

Talude é uma superfície inclinada com o intuito de garantir a estabilidade, seja em um maciço rochoso, solo ou ambos. Ele pode ser natural, como exemplo encontrado na natureza as encostas e vertentes, já para o talude artificial que ocorre por ações humanas temos como exemplo cortes e aterros. Na Figura 1 pode ser observado os elementos básicos de geometria de um talude. Onde:

- Pé: Cota mais baixa de um talude.
- Plano de topo: é perpendicular ao plano vertical de projeção (face do talude).
- Face do talude: face de exposição do maciço a agentes modificadores externos como intemperismo.
- Crista: Cota mais alta de um talude.
- Altura: diferença entre a cota mais baixa do talude (pés) e a cota mais alta (crista).
- Ângulo de inclinação: é o ângulo entre a horizontal (terreno de fundação) e a reta média entre o pé e a crista.

Figura 1- Terminologia para taludes



Fonte: Caputo et al. (2015)

Para Hoek-Brown(1980) os principais parâmetros de resistência são peso específico da rocha, altura do talude e a resistência da rocha intacta a compressão simples ou resistência do maciço rochoso a compressão uniaxial.

Considerando os critérios de resistência de Mohr Coulomb que é um dos mais antigos e usados, os aspectos mais importantes para a resistência são o ângulo de atrito, coesão, taxa de poropressão e peso específico. Onde:

- Ângulo de atrito: é o ângulo máximo entre a força propagada no solo em relação a força normal da superfície sem que aconteça cisalhamento do solo;
- Coesão: é a força de atração ou grau de agregação das partículas;
- Taxa de poropressão: é a pressão do fluido no interior dos poros de solos ou rochas;
- Peso específico: relação peso por volume ocupado.


2.2. Efeito Escala

O efeito escala é a influência das discontinuidades e do tamanho da escala em relação ao mecanismo de ruptura. Assim a distribuição das discontinuidades depende das dimensões do talude além dos parâmetros de resistência que são adotados para que seja possível determinar o mecanismo de ruptura.

Desta maneira pode ser definido a escala em meio contínuo, meio fraturado, meio muito fratura, meio extremamente fraturado e o meio contínuo equivalente como representado na Figura 2.

Na representação de rocha intacta pode ser observado que ela não apresenta nenhuma família de discontinuidade, pois a escala em que ela está não interceptou nenhuma família. Porém se for ampliando a escala do problema aos poucos é possível notar que o maciço rochoso na verdade é um meio bastante fraturado, diferente da percepção inicial que foi observada.


Figura 2 - Efeito escala em maciços rochosos



Fonte: Modificado de Wylie e Mah(2005)

Em um estudo realizado por Sjöberg (1999) é mostrado a ação do efeito escala das descontinuidades em comparação com a altura das bancadas do talude (Figura 3). Sendo estudado bancos de 30, 90 e 500 metros de altura com juntas com persistência entre 8 e 10 metros e espaçamentos entre 3 e 7 metros.

Figura 3- Representação efeito escala em taludes de 30, 90 e 500m



Fonte: Modificado de SJOBERG(1999)

Como resultado ele observou que as juntas tiveram a mesma distribuição, porém com taludes de 30m de altura o maciço apresentou um fraturamento muito

pequeno, já no talude de 500m, o maciço se mostrou altamente fraturado. De acordo com SJOBERG(1999) em taludes de grande escala, as descontinuidades de interesse são: (1) descontinuidades com a mesma escala do talude aproximadamente, que possui falhas e grandes zonas de cisalhamento e (2) descontinuidades com escalas pequenas que compõem a estrutura do maciço rochoso.

2.3. Estrutura do maciço rochoso

2.3.1. Definição de maciço rochoso

De acordo com AYACHE (2021) o maciço rochoso é um conjunto de blocos do material rocha (denominado, indevidamente, de “rocha intacta”), definidos pela interseção de conjuntos denominados famílias de superfícies sub-paralelas, mais ou menos planares, de origem geológica qualquer e que contém feições estruturais. E são coletivamente designadas por descontinuidades, sendo sem dúvida um dos aspectos mais importantes para que o talude seja estável. Entre as feições estruturais temos:

- Falhas: é um tipo de descontinuidade onde ocorre deslocamento em relação ao maciço rochoso, podendo acontecer devido ao sistema fraturamento paralelo a subparalelo do plano de cisalhamento;
- Foliação: orientação preferencial de minerais ou bandas em rochas metamórficas;
- Dobras: são estruturas que possuem camadas com atitudes alteradas pela flexão resultante, ocasionadas pela força tectônicas pós deposicionais;
- Zona de cisalhamento: região de material espesso no qual existe zonas de alívio de tensão ou então material intemperizado, que afeta na diminuição da resistência ao cisalhamento no local;
- Juntas: Fratura que ocorre no maciço rochoso, porém não acontece movimento relativo de suas paredes
- Planos de estratificação: são superfícies subparalelas que podem ocorrer em processos de deposição de sedimentos;


- Fratura: estruturas geológicas com aparência tabulares ou planares que proporciona redução na capacidade mecânica, pois possui propriedades e rigidez inferiores em comparação com a rocha encaixante;
- Clivagem: descontinuidades paralelas, que acontecem em planos incompetentes de camadas;
- Xistosidade: foliação que ocorre em xistos ou rochas cristalinas com granulometria grosseira, devido ao arranjo dos grãos durante o processo de metamorfismo.

De acordo com Brady e Brown(1985) o conceito do maciço rochoso realça os fatores estruturais determinantes de heterogeneidade e anisotropia, devido aos diferentes tipos de litologia, à presença de descontinuidade e ao grau de alteração de rocha.

2.3.2. Caracterização de descontinuidades

De acordo com Santos(2016) descontinuidade é um termo usado na engenharia para identificar dobras, falhas, juntas, fraturas, fissuras, estratificações, xistosidades e foliações que se encontram na zona de cisalhamento dúcteis e ou rúpteis, sendo estruturas geológicas que interceptam a continuidade física da matriz rochosa, ou seja, é um indicador que o maciço não é um meio contínuo, formando dessa maneira o plano de fraqueza das rochas que são características específicas que podem ser caracterizadas com uma avaliação em campo ou mais profundamente com ensaios específicos, onde podem ser observadas características quantitativas e qualificativas. Na Figura 4 pode ser observado a disposição dos principais parâmetros de avaliação em relação às descontinuidades.

Figura 4 - Características encontradas no maciço



Fonte: Adaptado por Santos(2021) apud ISRM (1981).

Caso a família não apresente um padrão nas distâncias das descontinuidades, o recomendado é a realização de uma setorização. Seja individualmente ou agrupadas em famílias. Como parâmetro de caracterização das descontinuidades temos:

- Percolação: Presença de fluxo de água no maciço.
- Preenchimento: Material que preenche o interior das descontinuidades, podendo ser o próprio material alterado das paredes das descontinuidades ou material transportado por fluídos no interior.
- Grau de fraturamento: O grau de fraturamento do maciço rochoso está diretamente vinculado com o tipo de ruptura do maciço rochoso, além de fatores como orientação e arranjo das descontinuidades em conformidade com o talude, definindo dessa maneira a situação dos planos de ruptura em maciços resistentes, já nos maciços friáveis a matriz define a geração dos planos e mecanismos de ruptura.
- Espaçamento: distância entre uma descontinuidade e outra que pertencem à mesma família de descontinuidade, na Tabela 1 pode ser observado sua classificação de acordo com seus espaçamentos.

Tabela 1- Descrição do espaçamento

Descrição	Espaçamento (mm)
Extremamente próximas	<20
Muito próximas	20 - 60
Próximas	60 - 200
Moderadamente espaçadas	200 - 600
Muito Eespaçadas	600 - 6000
Extremamente espaçadas	> 6000

Fonte: Adaptado por Wolpp(2018) apud ISRM (1978).

- Persistência: é o comprimento médio das descontinuidades dentro do maciço, na Tabela 2 pode ser observado sua descrição de acordo com a persistência.

Tabela 2- Descrição da Persistência

Descrição	Persistência(m)
Muito Baixa	<1
Baixa	1-3
Média	3-10
Alta	10-20
Muito Alta	>20

Fonte: Adaptado por Wolpp(2018) apud ISRM (1978).

- Grau de alteração da rocha: é a ação do intemperismo químico, físico ou biológico na rocha, na Tabela 3 pode ser observado observar o grau de alteração e sua descrição.

Tabela 3- Grau de alteração

Grau de Alteração	Descrição
Rocha sã	Sem Alteração.
Ligeiramente intemperizada	Apresenta manchas de coloração e material fino alterado.
Moderadamente Intemperizada	Leve descoloração com grande quantidade de descontinuidades(20% de todo material).
Altamente itemperizada	Apenas a textura se mantém preservada, grande parte friável.
Completamente intemperizada	Rocha totalmente decomposta com estrutura friável(solo).

Fonte: Adaptado por Wolpp(2018) apud ISRM (1978)

- Rugosidade: as descontinuidades apresentam irregularidades na superfície que interferem no comportamento cisalhante do bloco, assim quanto maior o grau de rugosidade maior é resistência ao cisalhamento e consequentemente aumenta a estabilidade do bloco.

Tabela 4- Grau de rugosidade

Classe	Escala		Perfil Típico de Rugosidade da Descontinuidade
	Intermédia	Menor	
I	Escalonada	Rugosa	
II		Lisa	
III		Polida	
IV	Ondulosa	Rugosa	
V		Lisa	
VI		Polida	
VII	Plana	Rugosa	
VIII		Lisa	
IX		Polida	

Fonte: Adaptado por Brown(1981) de ISRM (1978).

2.4. Estabilidade de talude

2.4.1. Fator de segurança

Como método comumente utilizado existe o equilíbrio limite que nos permite o cálculo do fator de segurança com a finalidade de avaliar a estabilidade da estrutura em estudo. O estado de carregamento em taludes, tem alguns fatores que devem ser avaliados, como a força peso, poropressão, abalos sísmicos e possíveis forças externas. O fator de segurança pode ser previsto pela Equação 1 como pode ser visto a seguir:

$$FS = \frac{S}{\tau} \quad (1)$$

Onde:

- S é a resistência ao cisalhamento do solo;
- τ é a tensão cisalhante.

Onde a resistência ao cisalhamento, pode ser dado em termos de um critério de resistência, em função das tensões efetivas para o critério de resistência de Mohr - Coulomb:

$$S = c' + \sigma' \tan \phi' \quad (2)$$

- c' é a coesão efetiva;
- ϕ' é o ângulo de atrito;
- σ' é a tensão normal efetiva no plano de ruptura.

A resistência ao cisalhamento também pode ser expresso em função das tensões totais na Equação 3:

$$S = c + \sigma \tan \phi \quad (3)$$

- c Coesão em relação a tensão total;
- ϕ Ângulo de atrito em relação a tensão total;

- σ Tensão total normal no plano de ruptura.

Substituindo a Equação 2 em 1, obtém a Equação 4:

$$FS = \frac{c' + \sigma' \tan \phi'}{\tau} \quad (4)$$

Teoricamente, as considerações de tensões efetivas ou totais para o cálculo de estabilidade de taludes é similar. Porém, em campo na prática, é mais conveniente a escolha das tensões efetivas pois é considerado conhecido os valores de poropressão em toda a superfície potencial de ruptura. Agora para as tensões totais é considerado valores existentes, de acordo com os ensaios triaxiais.

É comum adotar uma superfície potencial de ruptura para métodos de equilíbrio limite em cálculos de fator de segurança, o qual é possível ser obtido a partir das equações de equilíbrio estático a seguir nas Equações 5, 6, 7:

$$\Sigma \text{ Forças Horizontais} = 0 \quad (5)$$

$$\Sigma \text{ Forças Verticais} = 0 \quad (6)$$

$$\Sigma \text{ Forças Momentos} = 0 \quad (7)$$

Essas equações podem ser aplicadas a massa de solo potencialmente instáveis, assim o cálculo é repetido até que seja encontrada a superfície potencial de ruptura, ou seja, com o menor valor de fator de segurança (superfície crítica).

2.4.2. Tipos de ruptura


As rupturas podem ser divididas em quatro grupos principais, que são: rupturas planares, em cunhas, tombamento e circulares que é o foco principal deste trabalho.

Entende-se por rupturas planares a movimentação de maciços ao longo de uma ou mais superfícies pré-determinadas, como descrito na Figura 5, assim segundo Fiori e Camignani (2009), ocorrendo na extensão das feições estruturais definidas, como falhas, juntas tectônicas, fraturas ou planos de acamamento de acordo com Pio Fiore (2015).

Assim como condição para que aconteça esse tipo de ruptura as descontinuidades têm que estar mergulhando a favor do talude e devem possuir a mesma direção, onde o ângulo de mergulho seja maior que o ângulo da descontinuidade $\psi > \omega$, e onde o ângulo da descontinuidade seja maior que o ângulo de atrito interno $\omega > \phi$, adotando um intervalo de ± 20 graus para essa direção.

Existem diferentes tipos de rupturas planares que dependem da distribuição e características das descontinuidades, o primeiro tipo de ruptura é por um plano paralelo à face do talude, que pode acontecer por erosão ou por perda de resistência na região mais baixa do talude chamada de pé. E tem-se o tipo de ruptura por um plano que aflora a face ou então localizada no pé do talude com ou sem fenda de tração, esse tipo de deslizamento pode acontecer em várias intensidades e para que isso aconteça existem vários fatores que devem ser levados em consideração, sendo um deles a água subterrânea que reduz a resistência ao cisalhamento.

Figura 5 - Modelo de ruptura planar




Fonte: Hoek e Bray, 1981

As rupturas em cunha ocorrem em uma superfície pré-existente quando há uma intersecção de dois planos de descontinuidades, na direção da linha de intersecção formando um bloco de geometria aproximadamente tetraédrica, que pode ser uma junta de placas tectônicas, uma falha ou até ser uma estratificação, onde a matriz possui um papel de grande importância na geração destes planos e no mecanismo de ruptura.

Para que aconteça a geração deste tipo de ruptura, os dois planos devem aflorar na superfície do talude e deve cumprir a seguinte condição para que aconteça esse tipo de ruptura, as descontinuidades precisam estar mergulhando a favor do talude e também devem possuir a mesma direção, e o ângulo de mergulho precisa ser maior do que o ângulo da descontinuidade $\psi > \omega$, onde o ângulo da descontinuidade seja maior que o ângulo de atrito interno $\omega > \phi$, porém ω é o mergulho da linha de intersecção, como observado na Figura 6.

Figura 6 - Representação ruptura em cunha




Fonte: Ferentinou, 2004

A ruptura por tombamento acontece quando os planos estruturais definidos se encontram de forma subparalelos em relação a face do talude, entretanto o mergulho se apresenta de forma contrária ao ângulo da face do talude. Dessa maneira os blocos entre as descontinuidades rotacionam em sentido a face livre do talude. Existem três tipos principais de tombamentos que são: o flexural, em blocos e bloco flexural.

O tombamento flexural acontece em taludes preferencialmente de rochas sedimentares estratificadas ou metamórficas foliadas, porém pode ocorrer em outros tipos de litotipos. As direções da foliação são perpendiculares à face do talude e com o mergulho no sentido contrário, como é representado na Figura 7.


Figura 7 - Representação do tombamento flexural



Fonte: Hoek & Bray, 1977

O tombamento de blocos é gerado por colunas de rochas que são divididas em juntas perpendiculares, que possuem um amplo espaçamento como pode ser visto na Figura 8, segregando assim o bloco, dessa forma, as colunas inferiores formadas próximo ao pé do talude são empurradas pelas colunas superiores, acontecendo assim o deslizamento dos blocos.


Figura 8 - Representação do tombamento de blocos



Fonte: Hoek & Bray, 1977

O tombamento bloco-flexural é o tipo mais complexo de tombamento, pois ele é a combinação dos dois outros tipos (flexural e blocos), porém nesse caso o tombamento acontece devido ao acúmulo das juntas transversais. Resultando em um meio termo em um campo contínuo de deslocamento no tombamento flexural e um campo descontínuo associado ao tombamento de blocos de acordo com Hoek & Bray, 1977, como pode ser visto na Figura 9.

Figura 9 - Representação do tombamento bloco-flexural



Fonte: Hoek & Bray, 1977

2.4.3. Ruptura circular

As rupturas circulares ou também conhecidas como rotacionais, ocorrem com maior frequência em solos ou podem acontecer em rochas friáveis ou em rochas muito alteradas e/ou muito fraturadas as dimensões deste tipo de ruptura podem variar bastante podendo muitas vezes ser visíveis, movimentando centenas de metros.

Esse tipo de ruptura apresenta um comportamento isotrópico, pois os planos de descontinuidades não têm controle sobre o comportamento mecânico do maciço, ou então, a rocha já está tão alterada que as descontinuidades são menos relevantes, devido à baixa resistência.


Assim a ruptura acontece na superfície de menor resistência, dessa maneira as forças atuantes e seus parâmetros são avaliados e como resultado entre as forças de resistência e estabilizadoras mostra se o talude é instável ou estável. Existem diversos métodos matemáticos utilizados para efetuar a análise de estabilidade, nos próximos tópicos, serão descritos a metodologia dos principais deles.

2.5. Análise de estabilidade para ruptura circular

2.5.1. Método de fatias

O método comum de fatias (FELLENIOUS, 1936) é também conhecido como “método de Fellenius” ou “método Swedish Circle”, era o método mais utilizado para a realização da análise de estabilidade devido a sua facilidade de execução antes dos métodos computacionais. Para a realização deste método é necessário supor que a superfície de ruptura é circular e dividi-la em fatias ou lamelas verticais, podendo ser de diferentes espessuras, como na Figura 10.


Figura 10 - Representação da ruptura circular pelo método de fatias



Fonte: Sjöberg, 1999.

A força existente entre as fatias é desprezada e o equilíbrio é obtido através da somatória das forças verticais e horizontais sendo igual a zero, desta forma não existe nenhuma força contrária a poropressão, assim o método contempla apenas os equilíbrios de momentos. Na Figura 11 é possível ver todas as forças atuantes em uma fatia.

Figura 11 - Forças atuantes em uma fatia



Fonte: LAMBE & WHITMAN, 1969.

As variáveis apresentadas na figura 11 são:

- W_i = Peso da fatia ;
- X_i = Resultante das tensões cisalhantes na face esquerda da fatia;
- $\bar{E}_i$ = Resultante das tensões normais efetivas na face esquerda da fatia;
- $X_i + 1$ = Resultante das tensões cisalhantes na face direita da fatia;
- $\bar{E}_i + 1$ = Resultante das tensões normais efetivas na face direita da fatia;

- T_i = Resultante da resistência ao cisalhamento mobilizada ao longo da base da fatia;
- $\bar{N}_i$ = Resultante das tensões normais efetivas atuantes na base da fatia;
- U_1 = Resultante das poro-pressões atuantes na face esquerda da fatia;
- U_r = Resultante das poro-pressões atuantes na face direita da fatia;
- u_i = poro-pressão atuante na base da fatia;
- U_i = Resultante das poro-pressões atuantes na base da fatia;
- θ_i = Inclinação da base;
- Δl_i = Comprimento da base;
- Δx_i = Largura da fatia;
- a_i = Distância da face esquerda da fatia até o ponto de aplicação de $\bar{N}_i$;
- b_i = Distância da base da fatia até o ponto de aplicação de $\bar{E}_i$.

Para a realização do cálculo é importante considerar a base da fatia como uma reta em vez de curva para a simplificação do cálculo do peso próprio, outro fator importante é que quanto menor a largura da fatia, menor será o erro no resultado. Assim a resultante de resistência ao cisalhamento ao longo da base da fatia, se dá na Equação 8:

$$T_i = \tau \times \Delta l_i \quad (8)$$

Substituindo a equação 4 em 5, obtém-se a Equação 9 e 10:

$$FS = \frac{c' + \sigma' \tan \phi'}{\frac{T_i}{\Delta l_i}} \quad (9)$$

$$T_i = \frac{c' \Delta l_i + \sigma' \Delta l_i \tan \phi'}{FS} \quad (10)$$

Como a resultante das tensões normais efetivas atuantes na base da fatia é igual a Equação 11:

$$\bar{N}_i = \sigma' \Delta l_i \quad (11)$$

Logo obtém-se a Equação 12:

$$T_i = \frac{c'\Delta l_i + \bar{N}_i \times \tan \phi'}{FS} \quad (12)$$

Como o somatório de momentos em relação a 0, tem-se a Equação 13:

$$\Sigma M^o = 0$$

$$\Sigma W_i \times R \sin \theta_i - \Sigma T_i \times R = 0 \quad (13)$$

Substituindo a equação 12 em 13, obtém-se a Equação 14:

$$\Sigma W_i \times R \sin \theta_i = \Sigma \left(\frac{c'\Delta l_i + \bar{N}_i \times \tan \phi'}{FS} \right) \times R \quad (14)$$

Reorganizando a equação 14 em função do fator de segurança, temos a Equação 15:

$$FS = \frac{\Sigma (c'\Delta l_i + \bar{N}_i \times \tan \phi')}{\Sigma W_i \times \sin \theta_i} \quad (15)$$

Combinando as equações 5, 6 e 7 e todas as variáveis desconhecidas da Figura 11, é encontrado um sistema indeterminado, pois existem mais variáveis do que equações, impossibilitando assim a resolução. Assim, para resolver esses sistemas foram criadas metodologias simplificadoras, algumas sendo classificadas como minuciosas, pois atendem às equações de equilíbrio estático e outras bastantes simplificadas. Dessa maneira a equação 15 é a equação de base para os outros métodos de cálculo de fator de segurança, a combinação desta equação 15 com as outras equações de equilíbrio, seguindo as novas metodologias é possível alcançar o valor do fator de segurança. As novas metodologias mais utilizadas são FELLENIUS (1936), JANBU (1954), BISHOP (1955), MORGENSTERN & PRICE (1965) e SPENCER (1967).

2.5.2. Método de Bishop

O modelo de Bishop foi o primeiro método menos minucioso baseado no método de fatias, onde é possível realizar análises superficiais potenciais de ruptura circular, onde é feito a análise do equilíbrio completo das forças da fatia. Assim, esse método considera a nula as forças horizontais de interação, desprezando as forças tangenciais entre as fatias, dessa forma, o equilíbrio das forças é vertical, satisfaz as condições de equilíbrio de momentos em relação ao centro de gravidade da fatia, observadas na Figura 11, mostrada anteriormente. Desta forma, tem-se a Equação 16:

$$(X_i - X_{i+1}) = 0 \quad (16)$$

Aplicando o equilíbrio das forças verticais, tem-se a Equação 17 e 18:

$$\Sigma F_v = 0$$

$$W_i - \bar{N}_i \times \cos\theta_i - U u_i \times \Delta l_i \times \cos\theta_i - T_i \times \sin\theta_i = 0 \quad (17)$$

$$\bar{N}_i \times \cos\theta_i + u_i \times \Delta l_i \times \cos\theta_i = W_i - T_i \times \sin\theta_i \quad (18)$$

Aplicando a equação 12 e reorganizando a equação, chegasse na Equação 19, 20, 21 e 22:

$$\bar{N}_i \times \cos\theta_i + u_i \times \Delta l_i \times \cos\theta_i = W_i - \left(\frac{c' \Delta l_i + \bar{N}_i \times \tan \phi'}{FS} \right) \times \sin\theta_i \quad (19)$$

$$\bar{N}_i \times \cos\theta_i = W_i - u_i \times \Delta l_i \times \cos\theta_i - \frac{c' \Delta l_i + \bar{N}_i \times \tan \phi'}{FS} \times \sin\theta_i \quad (20)$$

$$\bar{N}_i \times \left(\cos\theta_i \frac{\tan \phi' \times \sin\theta_i}{FS} \right) = W_i - u_i \times \Delta l_i \times \cos\theta_i - \frac{c' \Delta l_i \times \sin\theta_i}{FS} \quad (21)$$

$$\bar{N}_i = \frac{W_i - U_i \times \Delta l_i \times \cos\theta_i - \frac{c' \Delta l_i \times \sin\theta_i}{FS}}{\left(\cos\theta_i \frac{\tan \phi' \times \sin\theta_i}{FS} \right)} \quad (22)$$

Substituindo a valor de $\bar{N}_i$ na equação 15 e ordenando os termos, encontra-se a equação para o cálculo do fator de segurança pelo método de BISHOP na Equação 23:

$$FS = \frac{\sum \left[c' \Delta l_i + \left(\frac{W_i - u \times \Delta l_i \times \cos \theta_i - \frac{c' \Delta l_i \times \sin \theta_i}{FS}}{\left(\cos \theta_i \frac{\tan \phi' \times \sin \theta_i}{FS} \right)} \right) \times \tan \phi' \right]}{W_i \times \sin \theta_i}$$

Portanto FS é apresentado na Equação 23:

$$FS = \frac{\sum \{ c' \Delta l_i + [(W_i - u_i \times \Delta l_i \times \cos \theta_i)_i] \times \tan \phi' \} \times \frac{1}{\left(\cos \theta_i \frac{\tan \phi' \times \sin \theta_i}{FS} \right)}}{W_i \times \sin \theta_i} \quad (23)$$

Considerando-se que se tem a Equação 24:

$$m_\theta = \cos \theta_i + \frac{\tan \phi' \times \sin \theta_i}{FS} \quad (24)$$


Encontrasse assim a Equação 25:

$$FS = \frac{\sum \{ c' \Delta l_i + [(W_i - u_i \times \Delta l_i \times \cos \theta_i)] \times \tan \phi' \} \times \frac{1}{m_\theta}}{\sum W_i \times \sin \theta_i} \quad (25)$$

Pode ser observado que a incógnita FS está se repetindo em dois membros da equação 25, assim o cálculo deve ser iterativo. Assim para a realização do método deve ser seguido o seguinte passo a passo:

1. Estimar uma superfície potencial de ruptura e o raio R;
2. Dividir o talude em fatias verticais como demonstrado na Figura 12, de maneira que a base das fatias esteja no mesmo tipo de solo, desconsiderar as descontinuidades no topo das fatias e deve-se atravessar todos os pontos de mudança da geometria do talude.


Figura 12 - Talude em fatias



Fonte: USACE, 2003

3. Medir a largura e os ângulos de cada fatia. O ângulo será positivo se possuir o mesmo sentido do ângulo de inclinação do talude de acordo com a Figura 13.

Figura 13- Convenção de sinais para θ à direita e à esquerda.



Fonte: USACE, 2003

4. Realizar o cálculo do peso (W) em cada fatia. Com a seguinte Equação 26:

$$W = \gamma \times \text{área da fatia} \quad (26)$$

5. Realizar o cálculo da poropressão média (u_i) na base de cada fatia.
6. Estipular o FS_0 que será utilizado na equação 24.
7. Calcular o FS de acordo com a equação 25.
8. Refazer os cálculos até os resultados de FS e FS_0 ficarem próximos.

9. Estimar outras superfícies com potencial de ruptura, e que tenham diferentes centros de gravidade e raios, refazendo o passo a passo anterior.
10. Adotar como o FS o menor resultado encontrado.

Este método por mais que seja um método simplificado, pois não considera as forças horizontais, fornece resultados próximos aos das metodologias mais minuciosas.

2.5.3. Método de Janbu

O método de Janbu simplificado é baseado no equilíbrio de forças de momento, desconsiderando as forças normais e as de corte entre as fatias, satisfazendo apenas o equilíbrio das forças. Para atender de forma parcial o equilíbrio de momentos, Janbu acrescentou um fator de correção empírico (f_0), para resolver o problema, porém este fator é variável de acordo com o tipo de solo e do modo de ruptura do talude. A Equação 27 estabelecida por Janbu para o fator de segurança é:

$$FS = f_0 \frac{\sum (bc + P - \mu b) \operatorname{tg} \phi \frac{1}{N_\alpha}}{\sum P \operatorname{tg} \alpha} \quad (27)$$

De forma que o N_α é igual a na Equação 28:

$$N_\alpha = \cos^2 \alpha \left(1 + \operatorname{tg} \alpha \frac{\operatorname{tg} \phi}{FS} \right) \quad (28)$$

Em comparação com o coeficiente N_α e M_α , obtemos a Equação 29:

$$N_\alpha = M_\alpha \cos \alpha \quad (29)$$

Em substituição do coeficiente N_α na equação de Janbu, obtemos a Equação 30:


$$FS = f_0 \frac{\sum (bc + P - \mu b) \operatorname{tg} \phi \frac{1}{M_\alpha}}{\sum P \operatorname{sen} \alpha} \quad (30)$$

$$FS = \frac{s_u}{c_{mob}} \quad (33)$$

A partir da equação 31, Taylor desenvolveu o ábaco para a determinação do fator de estabilidade que é basicamente $\left(\frac{1}{FS}\right)$. Em relação a profundidade da superfície de ruptura para diversas inclinações de talude (β) que são inferiores a 54° é possível localizar superfícies críticas em função de N , para esta situação não existe camada rígida, as linhas tracejadas e transversais as curvas de traço contínuo da Figura C2 e Figura C3 em anexo, permite determinar a distância da superfície de ruptura e o pé do talude.

Para inclinações superiores a 54° a superfície crítica passa fundamentalmente pelo pé do talude $D = 1$, a localização do pé do talude pode ser encontrada através da Figura 15.

Figura 15- Localização dos círculos de pé com inclinação superior a 54°



Fonte: Taylor(1948)

O método de Taylor não previa situações de $\phi \neq 0$, então Terzaghi e Peck (1967) adaptaram o ábaco (Figura C1 em anexo) para esta situação, de forma que o gráfico de DH representa a camada inferior ao pé do talude. Para a utilização do ábaco deve-se seguir as seguintes etapas:

1. Consideram $FS = FS_1$;
2. Calcular o ϕ_{mob} , pela Equação 34:


$$\phi_{mob} \rightarrow \tan\phi_{mob} = \frac{\tan\phi}{FS_1} \quad (34)$$

3. Determinar c_{mob} a partir de ϕ_{mob}, β, y e H .
4. Determinar $FS_2 = \frac{c}{c_{mob}}$, se $FS_1 \neq FS_2$ refazer os passos anteriores.

2.5.5. Método de Bishop e Morgenstern

Através do método simplificado de Bishop, foi desenvolvido por Morgenstern em parceria com Bishop, um novo método que pode ser representado pela Figura 16, onde desenvolveram ábacos para realização do cálculo do fator de segurança.

Figura 16- Representação do método de Bishop e Morgenstern



Fonte: Bishop e Morgenstern (1955).

A partir da Equação 25 é dado $W_n = \gamma b_n h$, na Equação 35:

$$r_u = \frac{U_n}{\gamma h_n} \quad (35)$$

Dispondo assim, encontrasse a Equação 36 e 37:

$$FS = \sum \left\{ \left[\frac{c}{\gamma h} x \frac{b_n}{H} + \frac{b_n}{H} (1 - r_u) \tan\phi \right] \frac{1}{m_a} \right\} \quad (36)$$

$$FS = m - n r_u \quad (37)$$

A variação de n, m com as variáveis $c/yH, D, \phi$ e β são mostradas nos ábacos (Anexo: Figuras B2 até B7) realizados por Bishop e Morgenstern. O procedimento para a realização do método é:

1. Determinação das variáveis $c/yH, \phi$ e β ;
2. Estimativa de r_u ;
3. Utilização dos ábacos para valores de c/yH e assim calcular m e n ;
4. Determinação do FS e os valores de m e n para diversas profundidades;
5. utilização do menor valor de FS encontrado.

É importante a observação do grau de consistência matemática para a realização do cálculo do fator de segurança, pois é necessário avaliar o problema para determinar a melhor metodologia entre todas apresentadas. Comparando os métodos citados neste trabalho a Tabela 5 é apresentada.

Tabela 5 – Comparação entre os métodos de análise de ruptura

Características	Método				
	Fatias	Bishop	Janbu	Taylor	Bishop e Morgenstern
Superfície de ruptura	Circular	Circular	Não circular	Circular	Circular
Solo	Homogêneo e heterogêneo	Homogêneo	Homogêneo	Homogêneo	Homogêneo
Método	Fatias	Fatias	Auxílio de ábacos	Ábaco	Ábaco
Considerações	A resultante das forças tem direção paralela a base da fátia, ignorando as forças entre as fatias	Considera o equilíbrio das forças e momentos entre as fatias, resultante das forças verticais entre as fatias é nula	Considera o equilíbrio de forças e momentos em cada fatia e despreza as forças verticais	Método de círculo de atrito com análise das tensões totais	Aplica o método simplificado de Bishop
Vantagens	Método Simples	Método Simples	Superfície de ruptura realística	Método Simples	Método Simples
Cálculos	Manual	Manual ou computacional	Computacional	Manual	Manual
Resultados	Conservativos	Conservativos	Não conservativos	Não conservativos	Conservativos
Limitações	Em círculos muito profundos e com elevados valores de poropressão, fornece valores imprecisos	método iterativo e impreciso para solos estratificados	Pode subestimar o fator de segurança	Aplicado apenas em algumas condições geométricas indicadas nos ábacos	método iterativo e impreciso para solos estratificados
Aplicação	Bastante utilizado em prática	Método muito utilizado, mas é recomendado para projetos simples	Método muito utilizado, mas deve ser considerado as limitações das rotinas de cálculo	Pouco usado na prática, utilizado em estudos preliminares	Estudo preliminar ou projetos simples de taludes homogêneos

2.6. Água subterrânea e tensões efetivas

A localização do nível do lençol freático é relevante para o planejamento, manutenção e segurança do talude. E para a escavação do talude é importante que se conheça a região através de características como a pluviometria anual, topografia, localização de rios, bacias e aquíferos, o tipo de material onde vai ser executado o talude entre outras.

De acordo com Huallanca (2004) o maciço que se encontra principalmente submerso ou seja abaixo do nível do lençol freático fica submetido a uma maior pressão da água, esse tipo de situação também pode ocorrer em taludes acima do nível do lençol freático ou seja taludes insaturados, porém com um pouco menos de intensidade. A pressão da água atua ao longo das descontinuidades reduzindo a tensão efetiva, e consequentemente diminuindo a resistência ao cisalhamento na superfície de ruptura, outra consequência do material em contato com a água é que ao longo do tempo o material irá diminuir a resistência, o que pode ser ainda mais crítico em regiões que possuem falhas. Dessa maneira, em regiões de alívio de tensões a tendência é que o fluxo de água seja maior permitindo alterações pelo lençol freático nas tensões efetivas.

2.7. Aprendizado de máquina

2.7.1. Tipos de aprendizagem

O aprendizado de máquina é um braço da área da inteligência artificial que utiliza diversas técnicas de criação. A partir dos modelos matemáticos desenvolvidos com base em banco de dados, podem ser criados modelos para regressão e/ou classificação.

Na metodologia clássica a amostra inicial é dividida em duas partes, podendo ser os dados de treino que são utilizados para treinar o modelo e os dados de teste que são utilizados para testar o modelo treinado. Para a realização deste método é necessário determinar as variáveis preditoras que são os valores utilizados no banco de dados de entrada e a variável *target* dos dados

em análise, que pode ser uma categoria ou valor de saída do modelo, ou seja, a classificação final.

De acordo com Ayache(2021) os dados de treinamento para modelos preditivos são compostos pela união do conjunto de variáveis, mais o conjunto de respostas das variáveis. Desta forma é factível a criação de um modelo para prever o comportamento do conjunto de resposta em comparação às respostas das variáveis. Para validar o modelo foi utilizado um modelo de treinamento e após o modelo entender as necessidades e quais são os parâmetros de interesse é aplicado um modelo de teste para validar os resultados.

Os modelos do tipo preditivo, podem ser classificados em modelo de regressão que possuem uma variável *target*, que é formada por dados do tipo numérico e que aceita valores fora dos dados usados em treino. Os modelos do tipo classificação também possuem a variável *target*, porém ela é restrita aos valores determinados pelo conjunto de dados, assim os dados de saída são respostas objetivas sem meio termo. Na Tabela 6 pode ser observado os principais modelos de acordo com suas funções.

Tabela 6- Modelos com as principais funções

Modelo	Função
Algoritmo de aprendizado supervisionado	
Vizinho mais próximo	Classificação
Naive Bayes	Classificação
Árvore de Decisão	Classificação
Classificador por regras de aprendizagem	Classificação
Regressão Linear	Regressão numérica
Árvore de Regressão	Regressão numérica
Modelo de Árvores	Regressão numérica
Rede Neural	Ambos os usos
Máquina de Vetores de Suporte	Ambos os usos
Algoritmo de aprendizado não supervisionado	
Regra de associação	Detecção de padrões
K-means por análise de agrupamento	Análise de agrupamento

Fonte: Adaptado de Lantz, (2013)

De acordo com Zhang (2020), os tipos de aprendizado de máquina podem ser classificados de forma regular/euclidiana ou não euclidiana. Há estruturação das metodologias está representada na Figura 17, com as respectivas categorias com uma hierarquia de distribuição de máquina.

Figura 17 - Árvore de classificação do aprendizado em máquina



Fonte: adaptado de Zhang, 2020

- Aprendizagem supervisionada que é feita a partir de um conjunto de dados de um banco de treinamento, apresentando variáveis de entrada, onde o algoritmo interpreta o conjunto de treino mapeando as informações rotuladas que é a variável *target*. Assim, o modelo interpreta as informações do banco de dados de teste.
- Aprendizagem não supervisionada usa o conjunto de treino sendo um banco de dados, porém sem a variável *target*, desta forma somente as variáveis de entrada são utilizadas ao longo do modelo.
- Aprendizagem semi-supervisionada ocorre quando um modelo recebe um banco de dados e este banco possui informações rotuladas ou não. Desta forma ficando no meio termo entre os outros dois tipos de aprendizagem, ela pode ser do tipo auto treinamento que utiliza as próprias previsões para se auto ensinar. Podendo ser do tipo com treinamento usado em previsões de ampliação de conhecimento do próprio modelo ou pode ser do tipo ativa onde o método faz com que o modelo realize de forma ativa a determinação dos pontos que devem ser rotulados para fazer parte do treinamento.
- Aprendizagem por reforço que funciona no formato de recompensa e punição onde são dados como resposta a previsão por um sistema de inteligência artificial que sempre se atualiza com cada *feedback*.

- Aprendizagem por transferência onde as informações são datadas ou perdem atualização ao longo do tempo, tornando-se obsoletas sendo necessário à sua substituição ou atualização de forma que seleciona os dados relevantes após as novas informações integradas no sistema.
- Aprendizagem não euclidiana que consiste em um aprendizado com dados irregulares e estruturados que não segue as definições euclidianas igual às outras metodologias, funcionando com uma estruturação de gráficos com informações do banco de dados de treino podendo ser supervisionadas ou não.

A aplicação do aprendizado em máquina pode ser feita utilizando muitas metodologias, mas cada método é utilizado com o intuito de alcançar diferentes resultados para problemas específicos como dito por Zhang (2020). Os principais métodos de aprendizagem em máquina são:

- Redes neurais artificiais (RNA's) simula uma comunicação neural, em que cada um dos neurônios recebe informações de entrada e a partir dele calcula um valor de saída que é repassado para outro neurônio onde a mesma informação é reavaliada de outra forma, até atingir o último neurônio da camada de saída dos dados que será a resposta final.
- Redes Bayesianas é um modelo de probabilidade bastante complexo, que representa as variáveis e a ligação entre elas. Neste caso, a rede mantém as variáveis em estado aleatório e forma uma condição de probabilidade que gera uma função.
- Redes de associação buscam interligações entre as variáveis do banco de dados, utilizando medidas para o conhecimento de frequência de relações e frequência de itens no banco de dados, gerando uma confiança entre todas as vezes que o padrão se repete.
- Aprendizagem indutiva acontece quando o modelo busca exemplos e tenta prever os rótulos de um banco de dados com informações ainda não conhecidas. A partir disso, é possível formar padrões e regularidades para a criação de hipóteses.
- Computação evolutiva consiste por uma família de algoritmos de otimização global que utiliza a evolução biológica, de forma que otimiza o

excesso de informação a partir do comportamento natural da vida aplicado a algoritmos.

O aprendizado em máquina vem crescendo bastante ao longo dos últimos anos em diversas áreas de estudo, a mineração área de interesse deste estudo, está relacionada a diversas variáveis operacionais além de necessitar de uma otimização de processos.

2.7.2. Árvore de decisão

2.7.2.1. Conceitos iniciais

As árvores de decisão são um modelo não paramétrico que possui a capacidade de tratar atributos do tipo categórico, numérico ou então os dois juntos. Desta maneira a árvore de decisão complementa a seleção de dados proporcionando um maior desenvolvimento aos algoritmos na solução dos problemas impostos em casos que possuem variáveis menos relevantes a regras de regressão. Existem diferentes algoritmos que servem de complemento para uma árvore de decisão, que tem como objetivo a modelagem das relações complexas entre os dados de entrada e saída em um problema de predição ou classificação.

2.7.2.2. Estrutura das árvores

As árvores de Decisão são feitas com base no modelo de hierarquia *top-down*, que é do nó localizado na raiz em direção às folhas, utilizando a técnica chamada de dividir para conquistar, que é baseada nas diversas divisões do problema em estudo em subproblemas de menor dimensão, desta maneira é encontrado uma solução mais simples para cada problema imposto.

Com o uso da árvore de decisão é possível minimizar as chances de erro e com isso maximizar a chance de alcançar um resultado satisfatório. Dessa maneira os benefícios esperados são idênticos ao valor total de todos os valores

arranjadas de acordo com a quantidade de informação. Após os nós, têm-se os ramos de ligação que fornece os testes dos valores das propriedades correspondentes e posteriormente aparecem as folhas que é responsável pela classificação final, representando a classe de dados correspondente dos nós. Desta forma, a classificação começa no nó e vai até as folhas. Pode-se afirmar que cada nó interno é um teste de atributo, o ramo final de um nó interno é o resultado do teste do atributo, a folha é um rótulo de classes e que uma nova observação segue o caminho da raiz até a folha para ser classificada.

As regras de classificação acontecem de forma geral em conjunto com a árvore e de acordo com o trajeto dos dados em cada nó até chegar as folhas com a sua classe já determinada, porém em alguns casos as regras substituem a árvore, desta maneira as derivadas da regra são as seguintes, de acordo com os resultados da Figura 18:

If $A < 10$ e $B < 50\%$ Then Sim.

If $A < 10$, $B \geq 50\%$ e $D < 10$ Then Sim.

É imprescindível a aplicação de testes em todos os nós determinados e nos conjuntos, o melhor caminho na árvore é escolhido durante a classificação. Os resultados podem variar de acordo com a natureza dos atributos (numéricos, categóricos ou simbólicos), é imprescindível que cada nó faça apenas um teste para que a árvore aconteça de forma mais simplificada.

O processo de formação da árvore de decisão é chamado de indução, que tem como base o particionamento por várias vezes o conjunto até que o critério de parada para classificação seja encontrado, como por exemplo uma mesma classe. O processo de indução pode ser feito de duas formas diferentes que são:

- Por profundidade: que começa por um nó inicial até outro nó ou folha, de forma que acrescente uma ligação a outro nó e assim por diante. Assim quando a ligação chega em uma folha a informação é retornada ao nó que gerou a folha e é adicionado um novo ramo e outro nó, caso não aconteça a criação de outro nó a informação é devolvida até que seja possível essa criação. Assim o processo é finalizado somente quando todos os caminhos acabarem em uma folha e que não seja possível criar mais nós.

- Por largura: todos os novos nós são feitos a partir de um único nó que é responsável por todas as ligações, e em cada nó adicionado o critério é testado e desenvolve novos nós ou uma folha, até que não tenha mais possibilidades, porém esta metodologia não retorna ao nó de origem (raiz).

Para melhorar as características de predição do modelo é realizado uma “poda” em ramificações de acordo com as variáveis analisadas e sua importância, desta forma reduz o tamanho do modelo, para reconhecer se a árvore precisa ser podada e quais são as variáveis de maior interesse foi desenvolvido por Breiman et al. (2017) o índice de Gini e a Entropia do nó.

2.7.2.3. Índice ou pureza de Gini

Em hipótese com um objeto u , sendo um objeto finito não vazio de acordo com o valor e com categoria imposta e sendo dividido por outras N diferentes categorias, o índice de Gini pode ser expresso pela seguinte Equação 38:

$$Gini(u) = 1 \sum_{i=1}^n [p(c_i \setminus u)]^2 \quad (38)$$

A probabilidade do conjunto de objetos em u pertencer a categoria c_i , pode ser expressa por $[p(c_i \setminus u)]$, quando o valor do índice de Gini for igual a 0, desta forma todos os objetos dentro do nó pertencem à mesma categoria, obtendo o maior número de informações necessárias. Para que o valor do índice de Gini seja máximo todos os objetos dentro do nó têm que possuir uma distribuição uniforme no campo de categoria, pois as médias podem ter informações úteis mínimas. O conjunto em relação com o subconjunto de atributos é dividido pelo número de conjunto $k(u, j, k=1, 2 \dots k)$, após a divisão do nó em Gini de acordo com a Equação 39:

$$Gini_{split}(u) = \sum_{i=1}^k \frac{n_j}{n} Gini(u_j) \quad (39)$$

Onde, n é igual ao número de objetos de u , e n_j é igual ao número de objetos situados no sub-nó. Assim o objetivo do índice de Gini é que todos os atributos individualmente percorrem todas as possíveis divisões até obter um valor mínimo de Gini, desta forma pode se dizer que o nó obteve o valor máximo de informação útil finalizando assim árvore de decisão ou então buscar um novo subproduto de acordo com Breiman et al. (2017).

Mas para que o índice de Gini determine se há a necessidade de um novo subproduto ou crescimento da árvore ele precisa de um complemento, que é Entropia do nó que é a medida da desordem de um conjunto de acordo com a variável target utilizando o $\log_2$ para definir seu valor ao invés da utilização de probabilidade simples, como pode ser visto na Equação 40:

$$Entropia = - \sum_j p_j \log_2(p_j) \quad (40)$$

Onde p_j , é a probabilidade de análise do fator j da variável *target*. Assim, quanto mais o valor tende a 0 mais puro é o nó e mais próximo de 0 é o índice de Gini. Assim os parâmetros mostram o desenvolvimento da árvore de decisão em relação ao menor número de impurezas dos nós.

2.7.3. Random Forest

O *Random Forest* é um tipo de aprendizagem de máquina constituído por um algoritmo utilizado para a classificação multivariada não paramétrica constituída pela metodologia *ensemble* que foi desenvolvido por Breiman (2001). Esta metodologia foi baseada na técnica de árvores de decisão, que é desenvolvida no treinamento de diversos modelos e utilizando o resultado dos modelos para definir apenas um resultado, ou seja, um valor final singular.

Resumidamente, o *Random Forest* é basicamente uma técnica de construção de múltiplas árvores de decisão de acordo com a seleção aleatória de amostra e parâmetros a partir dos dados de treino (Breiman, 2001).

Desta forma o *Random Forest* é um classificador que é composto por uma categoria n de árvores $\{h_k(x, t_k)\}$, sendo que $k = 1, 2, 3, \dots, n$, e t_k é um conjunto de

amostras independentes e aleatórias e distribuídas de forma homogênea e cada árvore escolhe a classe mais elegível para a entrada x .

A criação das árvores de decisão acontece de forma aleatória, a partir da observação dos dados de entrada do subconjunto, selecionando as variáveis e as amostras de forma aleatória. Criando assim diversos modelos a partir de um conjunto de dados aleatórios, de forma que o algoritmo garanta a participação de todas as variáveis e avaliando o grau de importância de cada uma.


As principais vantagens do *Random Forest* é a facilidade de aplicação da técnica em um modelo multifuncional que funciona em diversos tipos de problemas, uma menor aptidão ao *overfitting*, funciona em banco de dados incompletos ou com ruídos. As variáveis podem ser divididas em categorias ou podem permanecer de forma contínua, podendo assim ser aplicadas em banco de dados extensos e com seleção das variáveis de maior relevância.

Em contrapartida os pontos negativos são mais complexos, pois não permitem a visualização, apresentando uma difícil interpretação e podendo necessitar de algumas reparações em relação ao modelo, de acordo com os dados do banco de dados.

As etapas de classificação e regressão do algoritmo a partir do *Random Forest* são descritas por LIAW & WIENER (2002) e podem ser observadas na Figura 19, que é dividido em:

- Seleção da amostra de treino de forma aleatória.
- Seleção das variáveis em cada nó.
- Construção das próximas árvores seguindo os passos anteriores.
- Avaliação dos resultados em cada classe de modo que o modelo de classificação seja determinado pela maioria dos votos e o modelo de regressão pela média dos valores encontrados em cada árvore.

Figura 19- Etapas do funcionamento do Random Forest



Fonte: OSHIRO, 2013

A taxa de erro ou *estimate of error rate* (OOB) é um parâmetro importante no treinamento do *Random Forest*, que é basicamente o erro obtido utilizando amostras OOB em cada interação no treino, de forma que funciona como uma validação interna pois as amostras OOB são excluídas pelas amostras *bootstrap*, desta forma acontece a estimativa do erro OOB.

De acordo com Santos(2021) existem dois parâmetros de ajuste para o modelo que são de grande importância para o funcionamento do mesmo que são m_{try} , onde o número de variáveis a disposição de cada nó e são amostradas de forma aleatória e n_{tree} que é a quantidade de árvores construídas. Assim são definidas duas equações a 41 e 42 que são mostradas a seguir, onde a Equação 41 é para problemas de classificação e a Equação 42 para problemas de predição. A variável p é definida como sendo a número total de variáveis existente no banco de dados.

$$m_{try} = \sqrt{p} \quad (41)$$

$$m_{try} = \frac{p}{3} \quad (42)$$

2.7.4. Validação dos modelos de regressão

Métodos de regressão surgiram há mais de dois séculos com Legendre(1805) e Gauss(1809), que exploraram o método com o objetivo de fazer previsões de órbitas ao redor do sol de acordo IZBICKI E SANTOS, 2020.

Os modelos de regressão são bastante utilizados para prever variáveis numéricas e contínuas de acordo com HARRINGTON, 2012, além de ser utilizadas para prever respostas contínuas que podem ser interpretadas, entre a relação das variáveis preditoras definidas e os resultados obtidos graficamente ou numericamente. A regressão linear é uma maneira simples de modelagem para conjunto de dados, pois é embasada em funções lineares polinomiais, cujo objetivo é prever a probabilidade de cada evento e a que classe específica ele vai pertencer representando uma abordagem bastante simples do problema.

Assim o modelo é composto pela combinação linear das variáveis de entrada e seus pesos, e pode ser apresentada pela Equação 43 de acordo com Bishop, 2006.

$$y(X, W) = w_0 + w_1x_1 + \dots + w_Dx_D \quad (43)$$

Onde:

X : é um vetor de variáveis $(x_1, x_2, \dots, x_D)^T$;

W : é o vetor com pesos ou coeficientes de cada variável de entrada.


A partir da base linear um modelo simples de regressão linear é constituído pela relação linear entre um regressor x e uma resposta y que é uma linha reta (MONTGOMERY; PECK; VINING, 2012). Na equação 44 a seguir β_0 e β_1 são conhecidos por ser coeficientes de regressão sendo constantes não conhecidas e ε é um componente que assume uma média zero e variância desconhecida por ser um erro aleatório.

$$y = \beta_0 + \beta_1 x + \varepsilon \quad (44)$$

Diante da Equação 44, o regressor x é um fator que controla e serve para medir um erro não conhecido e y é uma variável indeterminada. β_1 é a inclinação da variância da média de distribuição y , que resulta em uma mudança unitária de x de acordo com MONTGOMERY; PECK; VINING (2012).

O método de estimativa ordinária de mínimos quadrados tem a função de estimar estes parâmetros, selecionando os parâmetros com o objetivo de diminuir a soma residual dos quadrados em relação os valores observados que estão no conjunto de dados e os valores esperados por aproximação linear de acordo com Weisberg (2005). Na Figura 20 é mostrado um exemplo de um conjunto de dados e a linha de tendência dos dados que melhor se ajusta a eles.

Figura 20- Exemplo de regressão



Fonte: HARRINGTON, 2012.

O algoritmo do modelo de regressão pode ser dividido em duas etapas que é a partição do conjunto de dados possível em regiões distintas e disjuntas. Onde são ajustadas a um modelo simples que usualmente é uma constante, para que assim consiga a predição da resposta de interesse de cada região. Assim para que ocorra a validação do modelo de regressão os seguintes erros são calculados para ver o quão ajustado está o modelo.

- MSE: é o valor do erro médio quadrático entre o valor predito e o

verdadeiro elevado ao quadrado, quanto mais próximo de zero melhor é o ajuste de dados, ou seja, maior será a acurácia do resultado.

- RMSE: é a raiz quadrada do erro médio quadrático, obtido através da raiz quadrada do MSE, neste caso erros grandes não condenam o resultado da mesma forma que acontece no MSE, apenas apresenta uma leve penalização devido a diferença entre o valor real e o predito.
- MAE: o erro absoluto médio é uma medida maior do que zero e sua função é avaliar a diferença entre o valor predito e os reais.
- R^2 : o coeficiente de determinação é um ajuste do modelo estatístico que gera uma medida de acordo com os valores de interesse podendo variar de 0 a 1, seu objetivo é mostrar o quanto o modelo consegue explicar os valores encontrados, assim quanto maior o resultado do coeficiente mais completo é o modelo.

2.7.5. Validação dos modelos de classificação

De acordo com SANTOS(2018) as árvores de regressão e classificação são muito semelhantes, exceto pelo fato de que a resposta da predição para uma nova categoria está relacionada a classe mais frequente entre as observações de treinamento na região a qual a nova classe pertence. De acordo com IZBICKI E SANTOS(2020) a diferença entre um problema de classificação e regressão é que as respostas preditas não serão uma variável quantitativa, mas sim qualitativa. Assim, uma aplicação do risco quadrático não é adequada para este tipo de problema.

O *Random Forest* é um algoritmo de aprendizado de máquina para classificação multivariada não paramétrica, o modelo de classificação tem como objetivo a associação de uma classe ou condição a uma categoria, onde o modelo pergunta a qual grupo pertence a variável analisada a partir de suas características. Os modelos de classificação são desenvolvidos a partir do método do aprendizado para modelos de predição. De acordo com PEREIRA(2015) a classificação tem dois extremos possíveis, onde pode

acontecer a classificação de todos os dados em uma mesma classe ou então cada dado em uma classe distinta.

No modelo de classificação, existem variáveis classificadas como independentes que são os dados de entrada e podem ser de forma contínua e/ou categórica, e as variáveis do tipo dependente que são os dados de saída e podem ser classificadas como dicotômica ou seja o resultado pode ser apresentado apenas de duas formas sim ou não, pertence ou não pertence entre outras formas. Caso a saída não apresente resultados dicotômicos eles são convertidos para se adaptar a esta especificação.

LIAW E WIENER(2002) destaca as seguintes etapas do algoritmo para classificação que são a seleção aleatória da amostra de treino, seleção das variáveis de cada nó, construção das árvores que aparecem na sequência e previsão final. Para a validação do modelo de classificação é utilizado a precisão dos resultados que é a proporção correta de uma categoria em relação a todas as previsões feitas para a categoria, além de medidas como acurácia, precisão, sensibilidade entre outras que podem ser obtidas a partir dos resultados de uma matriz de confusão que serão mais bem apresentadas na metodologia deste trabalho.

2.8. Estabilidade de taludes utilizando Redes Neurais Artificiais- Estudo de Sakellariou e Ferentinou (2004)

2.8.1. Histórico

O crescente interesse entre os pesquisadores em relação à inteligência artificial é decorrente do fato de o aprendizado em máquinas ter um excelente desempenho nas questões de reconhecimento de padrões e a modelagem de relações não lineares em sistemas dinâmicos multivariáveis. O artigo em estudo investigou a validação da rede neural artificial no problema físico de previsão de estabilidade de taludes.

Todos os métodos de modelagem numérica tentam alcançar o mapeamento de mecanismo “um para um” no modelo, que na realidade é um modelamento direto da relação tensão-tensão, que se refere à modelagem direta

de geometria e mecanismos físicos, especificamente ou por meio de propriedades equivalentes. A abordagem de rede neural é um método de “mapeamento não um-para-um”. Nesse modelo, o mapeamento do mecanismo não é totalmente direto, pois fornece recursos de previsão, é por este motivo que tem sido utilizado para identificação de parâmetros de rochas e solos e suas predições.

A estimativa precisa da estabilidade de um talude de rocha ou solo é um problema difícil, pois devido à complexidade do próprio sistema físico e da dificuldade envolvida para determinação dos dados de entrada são necessários parâmetros geotécnicos associados. Sendo este, um sistema dinâmico não linear que também é distribuído espacialmente, e por essas razões, é difícil determinar os valores dos dados de entrada essenciais.

2.8.2. Banco de dados

Uma ampla gama de informações para o conjunto de treinamento é mais importante do que seu tamanho, no que diz respeito a seu desempenho em dados futuros. Ter conjuntos de dados representativos é igualmente importante.

Existem várias maneiras de estimar qual é a taxa de erro para entradas, que não estão no conjunto de treinamento. Este erro é chamado nas estatísticas de 'taxa de erro fora da amostra definida', a técnica mais simples para estimar esse erro é dividir os vetores de entrada disponíveis para treinamento em dois conjuntos distintos e usar apenas um deles, que será chamado de conjunto de treinamento. Uma vez que o treinamento é concluído, o outro conjunto (o conjunto de validação ou teste) é usado para estimar a taxa de erro fora da amostra. Se o número de vetores em ambos os conjuntos é grande, a taxa de erro no conjunto de validação é uma estimativa razoável de precisão.

Os dados da camada de entrada consistem em seis parâmetros para a ruptura circular que foram peso unitário (γ), coesão (c), ângulo de atrito interno (φ), ângulo de inclinação (β), altura (H) e pressão da água dos poros (r_u). A camada de saída é composta por um único parâmetro de saída, seja o fator de segurança FS, ou o status de estabilidade (S). Os parâmetros que foram

selecionados estão relacionados às propriedades geotécnicas e a geometria de cada inclinação.

O primeiro conjunto de dados era composto por 46 componentes. Destas, 23 casos eram secas/insaturadas (13 instáveis, 10 estáveis) e 23 casos estavam molhadas/saturadas (16 instáveis, 7 estáveis). Os dados originais do banco de dados com os 46 componentes dos estudos de caso são apresentados na tabela 7 em anexo.

O treinamento ocorreu para a faixa específica de valores que abrangem o conjunto de dados de treinamento. Tentando alcançar o melhor desempenho da rede, assim várias redes com diferentes arquiteturas foram desenvolvidas usando todas as variações possíveis do algoritmo. Para o modo de falha circular 14 vetores foram usados como dados de teste cobrindo históricos de casos (Lin et al., 1988; Madzic, 1988; Spencer, 1967).

2.8.3. Metodologia aplicada

O artigo em estudo é uma continuação da pesquisa realizada por Sakellariou e Ilias (1997) e Roussos (2000). O objetivo foi investigar o problema da estabilidade de taludes sob a perspectiva de um sistema dinâmico, para quantificar o estado de estabilidade e investigar a relação da importância dos parâmetros envolvidos na avaliação da estabilidade do talude e na estimativa do FS.

No estudo em análise, uma série de redes neurais artificiais (RNA's) foram criadas para prever o fator de segurança e estimar a estabilidade em relação ao mecanismo de ruptura circular. Cada grupo de dados foi introduzido na rede individualmente e o desempenho das redes foi estimado.

Os resultados obtidos com a aplicação do algoritmo de retro propagação em conjuntos de dados do mundo real para o problema de estimativa de estabilidade de talude, permitem desenhar algumas conclusões interessantes.

Duas redes neurais artificiais foram construídas, para realizar a estimativa de fator de segurança (FS) e estabilidade (S). Ambas as redes possuíam arquitetura semelhante. A variação da retropropagação aplicado foi '*traincgp*'. O

termo retro propagação refere-se à maneira pela qual o gradiente do quadrado função de erro é calculado para redes multicamadas não lineares.

Essa variação específica pode treinar qualquer rede, desde que seu peso, entrada e funções de transferência, possua funções derivadas. O algoritmo de retropropagação é usado para calcular as derivadas de desempenho em relação às variáveis de peso. O (MSE), entre os valores alvo (dados reais) e os valores previstos da rede é $MSE = 0,0025$ para FS e $MSE = 0,01$ para S. O estado de estabilidade é considerado como uma aproximação de função problema tomando valores na faixa de $[0,1]$, em vez de valores discretos 0 ou 1. Para validar o desempenho da rede, seguiu a estratégia de procedimentos de treinamento de rede e treinou as redes com os dados de teste.

2.8.4. Resultados obtidos

Para o problema de segurança, para predição de fatores sob mecanismo de ruptura circular, os resultados mostram que os parâmetros importantes são o ângulo(β), e a altura H do talude, que são os parâmetros que controlam a geometria do talude.

Particionamentos de pesos também foram realizados para as redes treinadas com os 31 dados filtrados. Ficou evidente que as entradas w_2 , e w_3 , que correspondem ao ângulo de atrito e ângulo de inclinação (β), são os parâmetros mais dominantes na estimativa do fator de segurança, mas o resto dos parâmetros são quase igualmente importantes.

O fator de segurança calculado proveniente do método analítico para os dados de referência (conjunto de 46 vetores), foi comparado com o fator de segurança previsto nas análises de rede neural, bem como o fator de segurança proveniente de um mínimo quadrado, metodologia de aproximação (Sah et al., 1994), e foi encontrado para dar uma melhor convergência. Em particular, houve uma melhor convergência entre o FS estimado de redes neurais e o valor calculado a partir de métodos analíticos, do que em relação a convergência entre os resultados do método de aproximação de mínimos quadrados em comparação com os resultados dos métodos analíticos.

Outro resultado muito importante decorrente do estudo em análise foi a capacidade da rede neural para classificar o grupo de dados que não se encaixava no conjunto de dados inicial, para a qual coesão $c = 0$. Pode ser concluído que a RNA pode reconhecer tendências e dobras em conjuntos de dados referentes ao próprio problema físico, o que comprova que as redes não são apenas “caixas pretas”. O desempenho das redes foi altamente aprimorado no caso de falha circular filtrando os dados.

Um talude pode sofrer ruptura devido a uma variedade de razões ou uma combinação delas. Alguns dos parâmetros envolvidos neste sistema dinâmico não linear são quantitativos e alguns são descritivos. De acordo com os resultados obtidos da análise, o desempenho da rede foi satisfatório para o conjunto de treinamento, mas não previu os valores de forma confiável do fator de segurança (F). A previsão justa da rede pode ser inicialmente atribuída à quantidade relativamente pequena de dados que o conjunto de treinamento consistia.

2.9. Estabilidade de taludes utilizando Análise discriminante - Estudo Santos e Silva (2021)

2.9.1. Histórico

Rupturas em taludes são fenômenos naturais complexos que constituem um sério risco natural em diversos países (Wang et al., 2005). Novas metodologias para abordagem para o problema são frequentemente propostas, como por exemplo Wang et al. (2005), Nagahashi et al. (2013), Santos et al. (2018), Feng et al. (2018). Estudos relacionados a ruptura em taludes são tradicionalmente realizados por análises de estabilidade como Ordinário (Fellenius, 1936), Janbu (1954), Bishop simplificado (1955), Morgenstern e Price (1965) e Spencer (1967).

Os avanços tecnológicos na aquisição e processamento de dados priorizam a aplicação de abordagens probabilísticas, além de apresentar resultados mais precisos. Assim desta maneira, os avanços tecnológicos contribuem para aplicações de metodologias não paramétricas para prever as condições de

estabilidade de taludes, que se diferenciam da determinação dos fatores de segurança.

2.9.2. Banco de dados

A base de dados utilizada na pesquisa foi compilada e organizada por Feng et al. (2018), de 59 taludes sujeitos a ruptura circular, que são resultados da compilação de bases de dados de Feng (2000), Sah et al. (1994), Wang et al. (2005), Xu et al. (1999), Zhou e Chen (2009). Uma segunda base de dados foi utilizada, que também foi compilada por Feng et al. (2018) utilizada para validação do modelo, ela foi obtida a partir de 12 casos da literatura que não foram incluídos no conjunto de dados de treino, e são resultantes da compilação de bancos de dados de Hoek e Bray (1981), Lin et al. (1988), Madzic (1988), Yan e Li (2011).

A base de dados de Feng et al. (2018) é resultado da compilação de artigos e livros publicados, que abrangem muitos históricos de casos de estabilidade de taludes, como, talude natural e de mina a céu aberto, portanto estas informações são amplas e representativas, pois tem origem de diversas situações e com origem bem distintas, reforçando assim, a premissa de generalização do modelo proposto.


Os parâmetros do banco de dados são geometria da altura do talude(H) e ângulo do talude (α); resistência ao cisalhamento, coesão (kPa) e ângulo de atrito (φ), peso específico (γ), e pressão da água dos poros (r_u).

2.9.3. Metodologia aplicada

A primeira técnica utilizada foi a análise de componentes (PCA) e, em seguida, a análise discriminante nos escores da PCA. A Figura 21 mostra a metodologia aplicada. O desenvolvedor do trabalho em estudo, utilizou as técnicas estatísticas do *software R Development Core Team* (2006). O PCA foi utilizado para reduzir o tamanho do banco de dados de forma que visualizasse

o modelo com duas dimensões. A seleção do número de componentes para retenção foi realizada com base na variância explicada por cada componente. A partir da análise discriminante, uma equação foi gerada, onde limitava as duas populações de taludes, estável e instável. Para avaliar a qualidade da função discriminante gerada, foram aplicados dois tipos de validação: validação cruzada e externa.

Figura 21 - Fluxograma de desenvolvimento de Santos e Silva (2021)



Fonte: Santos e Silva (2021)

A diferença entre os dois tipos de validação é que a validação cruzada é influenciada pela construção do modelo, o que não é verificado pela validação externa, pois são utilizadas novas inclinações.

A metodologia utilizada no trabalho para determinar a qualidade da função discriminante está de acordo com Santos et al. (2018). A probabilidade geral de sucesso (OPS) é determinada com base no número total de taludes classificados corretamente.

2.9.4. Resultados Obtidos

Os resultados do trabalho de Santos e Silva (2021) são relevantes para realçar que a metodologia apresentada tem aplicabilidade não apenas em encostas rochosas, mas também em encostas de solo. A probabilidade geral de sucesso foi de 89,83%, com taxas de erro que proporcionam uma maior

segurança ao talude, pois os erros estão relacionados à classificação de taludes estáveis em taludes instáveis. Apesar da metodologia aplicada por Santos e Silva (2021) apresentar menor probabilidade geral de sucesso quando comparada às metodologias de Feng et al. (2018) e Sah et al. (1994), é importante destacar o embasamento das técnicas aplicadas, em estudos mais precisos nas relações e estrutura das variáveis com base em testes estatísticos, análise de variabilidade e adequação de variáveis. Assim o modelo proposto pode ser utilizado para conhecer a condição de estabilidade de taludes, além da capacidade de prever as situações mais perigosas não apenas em um conjunto de taludes rochosos, mas também em vários outros tipos de taludes.

3. METODOLOGIA

3.1. Materiais

Para a realização deste trabalho, além da utilização do banco de dados estudado por Ferentinou (2004), foi utilizado o software Orange Data Mining que é uma ferramenta *open source*, ou seja, uma ferramenta com código livre (gratuito). O software apresenta uma interface de fácil compreensão, além de possuir vários recursos de visualização, onde diversas análises estatísticas podem ser realizadas de forma eficaz e com precisão nos resultados. Além da realização de análises preditivas, descritivas e a classificação das variáveis do projeto, além da determinação da variável alvo do processo.

3.2. Partição do banco de dados

O primeiro banco de dados estudado foi utilizado para treino que é constituído por 46 amostras onde 23 dessas amostras estavam secas/insaturadas (sendo que destas 13 apresentavam condições iniciais instáveis e 10 estáveis). O restante estava úmido (solo saturado) sendo que destas 16 apresentavam condições iniciais instáveis e 7 estáveis.

O banco de dados é classificado por 6 parâmetros que foram

determinados por Ferentinou(2004) sendo estes pesos específicos, coesão, ângulo de atrito interno, ângulo do talude, altura do talude e determinação da poropressão. Dentro do artigo em estudo (Ferentinou, 2004) os modelos introduzidos por Hoek e Bray (1981) são utilizados para produzir dados de teste, para a realização da validação e a qualidade do processo de aprendizagem do Random Forest, sendo constituído por 21 amostras que se referem a rochas secas, úmidas e ou encostas de solos sem qualquer descontinuidade, onde essas foram utilizadas para teste.


3.3. Métodos

O mecanismo potencial na ruptura circular pode acontecer em solos ou rochas altamente fraturadas, mas neste trabalho o alvo principal são os solos. Ao avaliar a estabilidade de um talude por métodos de equilíbrio limite, é necessário determinar a localização da superfície crítica de deslizamento e o correspondente valor mínimo de fator de segurança, testando um número considerável de superfícies com potencial de deslizamento.

O método proposto é um método rápido de avaliação preditiva que tem como intuito a correção imediata de taludes de alto risco de ruptura, porém ele não substitui os cálculos do fator de segurança, funcionando como um sistema de recomendação.

Os fluxos de trabalho do Orange Data Mining, são constituídos por componentes que leem, processam e visualizam os dados. Os *widgets* se comunicam entre si enviando informações, desta maneira criando um fluxograma de informações. Para o melhor desenvolvimento do trabalho foi realizado um planejamento de execução, na Figura 22 pode ser observado que de modo geral o processo do lado de fora do Orange em forma de fluxograma.

Figura 22 - Fluxograma de execução



3.4. Desenvolvimento do Random Forest

O primeiro passo para o desenvolvimento do Random Forest é a entrada do banco de dados, que é o recebimento de dados externos. A segunda etapa, é a criação das árvores e funções para que ocorra o processamento dos dados, onde todas as etapas estão interconectadas entre si. A última parte do Random Forest é a saída de dados onde todos os *widgets* se conectam para o desenvolvimento do resultado. Porém os *widgets* de saída não são interconectados a outros *widgets* dentro do processo.

Assim, o escopo principal deste trabalho é implementar a metodologia acima no problema de estimativa de estabilidade de taludes, para prever o fator de segurança (FS) ou o status de estabilidade (S) no caso de encostas de solo e taludes. Os dados da camada de entrada consistem em parâmetros que são divididos em análises de possíveis rupturas circulares. A camada de saída é composta por um único parâmetro de saída, seja o fator de segurança para o modelo de predição ou o status de estabilidade para o modelo de classificação. Para que o resultado seja preciso é necessário um amplo conjunto de treinamento, além de possuir conjuntos de dados representativos que é


igualmente muito importante.

3.5. Modelo de regressão

3.5.1. Metodologia

Inicialmente foi realizado a adição do banco de dados como pode ser visualizado na Figura 23, as demais ramificações foram desenvolvidas em cada *widgets* com uma avaliação do banco de dados informado, estas conexões são chamadas de *widgets*, assim cada *widgets* representa uma parte do desenvolvimento.

Figura 23 - Fluxograma para modelo de regressão



Para cada cor do *widgets* existe uma definição de funções:


- Laranja: visualização e seleção de dados;
- Rosa: desenvolvimento da mineração de dados;
- Azul: realiza os testes;
- Salmão: visualização dos resultados de teste.

O treinamento do banco de dados é realizado por um algoritmo no *widgets*

de avaliação do treinamento, neste *widgets* é possível entrar com os dados de três formas (entrada de dados, entrada de teste/validação e aprendizagem), onde é possível entrar com mais de uma forma simultaneamente, além de comparar a eficiência entre as informações. A amostragem no *widgets* de avaliação de treinamento pode ser realizado de 6 formas, conforme observado na Figura 24, que são:

- *cross validation*: é a principal delas, nela os dados são separados em grupos de amostras e cada amostra é testada individualmente.
- *Cross validation by feature*: o princípio de funcionamento é igual ao anterior, porém neste caso é necessário selecionar as características de interesse das amostras.
- *Random sampling*: os dados são divididos em dois grupos (um para treino e o outro para teste) de maneira randômica, assim as interações são especificadas e apresenta uma proporção predefinida de cada conjunto.
- *Leave one out*: separa individualmente as amostras a fim de comparar com todos os dados do conjunto, proporcionando resultados precisos.
- *Test on train data*: todos os dados são utilizados tanto para treino quanto para teste, sendo a forma utilizada neste trabalho.
- *Test on test data*: neste método é preciso da adição de outro conjunto com dados diferentes para a realização dos testes.

Figura 24 – Widgets: avaliação de treinamento



A função da tabela *Evaluation Results* ainda na Figura 24, é capaz de mostrar a porcentagem de informações da mineração de dados para o modelo utilizado. Onde:

- *Model*: é o modelo utilizado na avaliação do treinamento, para este trabalho o modelo será o *Random Forest*.
- *MSE*: é o valor do erro médio quadrático entre o valor predito e o verdadeiro elevado ao quadrado, quanto mais próximo de zero melhor é o ajuste de dados, ou seja, maior será a acurácia do resultado.
- *RMSE*: é a raiz quadrada do erro médio quadrático, obtido através da raiz quadrada do *MSE*, neste caso erros grandes não condenam o resultado da mesma forma que acontece no *MSE*, apenas apresenta uma leve penalização devido a diferença entre o valor real e o predito.
- *MAE*: o erro absoluto médio é uma medida maior do que zero e sua função é avaliar a diferença entre o valor predito e os reais.
- R^2 : o coeficiente de determinação é um ajuste do modelo estatístico que gera uma medida de acordo com os valores de interesse podendo variar de 0 a 1, seu objetivo é mostrar o quanto o modelo consegue explicar os valores encontrados, assim quanto maior o resultado do coeficiente mais completo é o modelo.

O *widgets* chamado de Random Forest que está representado na Figura 25, é um conjunto de árvores de decisão que se desenvolvem a partir de um atributo e cria um modelo final com base no resultado da maioria das árvores desenvolvidas de forma individual. Inicialmente é preciso determinar um nome para o modelo, posteriormente vem o *basic properties*, onde é determinado as características básicas do modelo, que são:

- *Number of trees*: determina o número de árvores de decisão, neste trabalho optou-se por trabalhar com 200 árvores dentro do Random Forest.
- *Number of attributes considered at each split*: desta etapa o objetivo é especificar quantos atributos serão considerados por nó, se por acaso não for especificado o valor considerado será igual a raiz quadrada do número de atributos encontrados no banco de dados. No caso deste trabalho o


valor escolhido foi 5.

- *Replicable training*: é utilizado para poder replicar os resultados.
- *Balance class distribution*: são classes com pesos proporcionais às frequências.

Após a determinação básica do modelo vem o controle de crescimento, chamado de growth control, que pode ser determinado de duas formas:

- *Limit depth of individual trees*: que é a limitação da profundidade das árvores, sendo considerado uma pré poda.
- *Do not split subsets smaller than*: neste caso definisse o menor subconjunto em que a árvore pode alcançar.

Figura 25 – Definição do Random Forest




Após a definição do Random Forest acontece um pré-processamento, quando não existe nenhum outro tipo de pré-processador, que o executa da seguinte forma, inicialmente acontece a remoção instantânea de valores de destino desconhecidos e colunas vazias e posteriormente preenche lacunas vazias com valores médios.

O *widgets* de predição, que pode ser visualizado na Figura 26, tem a função de classificar os dados que estão fora das amostras de treino, de acordo com suas características semelhantes, através do modelo gerado pela mineração de dados, apresentando os resultados de classificação final do


modelo e a probabilidade de cada classe escolhida.

Figura 26 – Localização widgets de predição no Orange



Após a realização da predição vem o widgets chamado de construção da variável erro, que está representado na Figura 27, nesta etapa acontece a adição de novos recursos aos conjuntos de dados. Esta adição acontece em forma de novas colunas, e para os resultados destas colunas é adicionado cálculos através da combinação das variáveis.

Figura 27 – Widgets: construção da variável erro



Na opção new é onde adiciona-se novas fórmulas e logo a sua frente é definido o nome da coluna, mas à frente é onde se escreve a expressão que deve ser realizada na forma de *Python*. Abaixo pode ser selecionado as variáveis

disponíveis no conjunto em *select feature* e posteriormente em *select function* acontece a seleção da função.

Nesta parte do trabalho foi realizado o desenvolvimento de duas funções semelhantes, onde uma é utilizada para a realização do modelo de treino e a outra para o modelo de teste que estão inclusas dentro do modelo de regressão. As fórmulas são constituídas pelo valor definido do fator de segurança real chamado de F , menos o fator de segurança gerado no Random Forest, assim é definido o erro em cada talude presente no banco de dados, e com esses resultados é possível avaliar a variabilidade do modelo.


3.5.2. Validação

Como métodos de validação dos dados para o modelo de regressão, apresenta inicialmente o gráfico de dispersão com análises exploratórias, que fica localizada no *widget* de diagrama de dispersão, Figura 28. Fornecendo uma visualização bidimensional dos dados, onde são exibidos como um conjunto de pontos e cada ponto possui atributos que determinam a sua posição no eixo x e no eixo y do gráfico. Para configurar o *widgets* de gráfico de dispersão:

- *Axes*: escolha de atributo para o eixo x e y .
- *Attributes*: define a cor dos pontos plotados e permite a rotulação dos dados.
- *Set symbol size*: define o tamanho dos pontos, a opacidade, não deixa os pontos se sobreporem.
- *Select, zoom, pan e zoom to fit*: são opções de exploração agindo como uma seleção manual de dados.


Para o modelo de regressão, dois gráficos de dispersão foram utilizados, o primeiro foi o fator de segurança *versus* o erro com o intuito de visualizar o quão conservador ou perigoso são os resultados apresentados. E o segundo gráfico, é o Random Forest *versus* o fator de segurança onde é possível notar a semelhança entre o valor real *versus* o predito.

Figura 28 – Widgets: gráfico de dispersão



O outro método de análise dos dados finais é o *widget* de histograma que exibe as distribuições dos valores em relação a um único atributo, exibindo a distribuição dos dados de forma discreta ou contínua.

Figura 29 – Widgets: configuração de histograma




Para avaliação do modelo de regressão os atributos escolhidos para representação dos dados foi o erro *versus* a frequência do erro com o objetivo de visualizar a confiabilidade da análise feita pelo Random Forest.

3.6. Modelo de classificação

3.6.1. Metodologia

O modelo de classificação foi desenvolvido de uma forma semelhante ao modelo de regressão, porém de uma maneira mais simples como pode ser visualizado na Figura 30.

Figura 30 - Fluxograma para modelo de classificação



O arquivo de entrada do banco de dados é o mesmo utilizado anteriormente no modelo de predição. As configurações utilizadas no Random Forest, na avaliação de treinamento e na predição utilizam os mesmo valores e requisitos do modelo anterior. Porém os resultados são apresentados de uma maneira distinta. A mesma configuração dos parâmetros não significa que os resultados serão iguais, pois o padrão de avaliação acontece de formas diferentes enquanto o modelo de classificação apresenta resultados categóricos a predição fornece análises de variáveis contínuas, assim o modelo de predição irá fornecer um valor predito para o fator de segurança enquanto o modelo de

classificação irá fornecer o status de estabilidade do talude.

3.6.2. Validação

A matriz de confusão é uma das técnicas de validação mais utilizadas em problemas de classificação, usada para entender a relação dos valores corretos e os erros do modelo utilizado, dessa forma a determinação da acurácia que basicamente é a porcentagem de acertos em todas as determinações do algoritmo utilizado. Assim, observando a Tabela 7 pode-se entender melhor o funcionamento da matriz de confusão.

Tabela 7 - Matriz de confusão

		Predição	
		Instável	Estável
Real	Instável	Verdadeiro Negativo	Falso Positivo
	Estável	Falso Negativo	Verdadeiro Positivo

A matriz de confusão é basicamente uma tabela comparativa que utiliza um algoritmo de predição sob os valores reais, dessa maneira resultando em quatro resultados distintos que podem ser divididos em quatro categorias:

- Verdadeiro Positivo (VP): significa que o valor dito como verdadeiro, é realmente verdadeiro.
- Verdadeiro Negativo (VN): significa que o valor dito como verdadeiro, no entanto, é falso.
- Falso Positivo (FP): significa que o valor dito como falso, é realmente falso.
- Falso Negativo (FN): significa que o valor dito como falso, no entanto, é verdadeiro.

A partir dos resultados encontrados é possível calcular:

- Acurácia que basicamente é a quantidade de dados classificados como positivos e negativos, e estão corretos.

$$Acurácia = \frac{VP+VN}{VP+FP+VN+FN} \quad (45)$$

- Precisão que é a quantidade de dados positivos classificados verdadeiramente na matriz de confusão, assim utiliza-se as seguintes fórmulas:

$$Precisão = \frac{VP}{VP+FP} \quad (46)$$

- A taxa de erro aparente que mostra a qualidade da classificação do grupo amostral em função das amostras mal classificadas, sendo um complemento para a acurácia.

$$Taxa\ de\ erro\ aparente = \frac{FP+FN}{VP+VN+FP+FN} \quad (47)$$

- A sensibilidade de acordo com (Santos, 2021), que indica a qualidade do classificador em categorizar corretamente a classe em análise.

$$Sensibilidade = \frac{VP}{VP+FP} \quad (48)$$

- A especificidade de acordo com (Santos, 2021) indica a porção dos valores verdadeiros negativos em referência ao total de negativos.

$$Especificidade = \frac{VN}{VN+FN} \quad (49)$$

- A eficiência é a média entre a sensibilidade mais a especificidade.

$$Eficiência = \frac{Sensibilidade + especificidade}{2} \quad (50)$$


A outra maneira de visualização dos resultados para o modelo de classificação é o gráfico de dispersão, porém para esse método os resultados são apresentados de forma distinta do método de predição pois apresenta os resultados em uma distribuídos ao longo de uma linha de tendência com aproximadamente 45° de inclinação. No modelo de classificação os dados se acumulam na categoria que mais se identificam, criando assim uma dispersão perfeita.

4. Resultados e discussões

4.1. Modelo de regressão: Treino

O modelo de regressão é o primeiro a ser realizado e nele foi utilizado o banco de dados com 46 amostras. Na Figura 31 é possível observar os resultados obtidos na avaliação de treinamento, no *widgets* de avaliação de treinamento. Observando os valores encontrados de MSE, RMSE e MAE que foram de 0,023 para o MSE, de 0,153 para o RMSE e de 0,116 para o MAE é possível dizer que os valores encontrados apresentam um erro de baixa intensidade, indicando que o modelo teve um bom desempenho, pois o modelo está bem ajustado. O valor de R^2 foi igual a 0,836 que se mostra eficiente, pois diferente dos outros resultados, quanto mais próximo de 1 mais eficiente se torna o modelo proposto, pois ele se ajusta em relação a amostra e aos valores encontrados neste widgets.

Figura 31 - Resultados do erro no modelo de regressão




Na Figura A1 em apêndice, pode ser visto o banco de dados utilizado para treinamento, que fica contido dentro do widgets de predição. Na coluna Random Forest obtém-se os valores do fator de segurança predito de acordo com os parâmetros adotados na metodologia. Fazendo uma comparação entre os resultados propostos pelo software e o fator de segurança real é encontrado 17 amostras com valores acima do valor real com uma média superior de 0,153 e 29 amostras com um valor predito abaixo do real com uma média de -0,079.

Comparando a variação dos resultados tanto negativa quanto positiva, os valores preditos estão bastante próximos do real, com uma taxa de erro total igual a 0,23% desta forma o desempenho da metodologia se mostra eficiente e com valores mais conservadores devido à proximidade dos resultados.

Foi analisada a correlação entre o fator de segurança real, que foi devidamente calculado e o valor predito, encontrado através da análise estatística do software como foi visto na Figura 32.

Pode ser observado que o gráfico apresenta resultados em uma correlação positiva, pois a variável independente (eixo horizontal) e a variável dependente (eixo vertical) tendem a formar uma linha de tendência inclinada com angulação próxima de 45° . Outro ponto a ser analisado é a dispersão dos dados, que mostra a existência de uma forte correlação entre os dados, devido à baixa dispersão ao longo da linha de tendência.


Figura 32 - Gráfico de dispersão para treino: fator de segurança real vs predito



O segundo resultado de validação para treino, é o histograma de frequência do erro, Figura 33, onde a frequência com que o erro ocorre entre

valores tidos como estáveis e instáveis e sua veracidade.

Figura 33 - Histograma de frequência do erro para treino



O pico do gráfico mostra um agrupamento mais alto com assimetria à esquerda entre os valores que estão entre -0,2 até 0 que contém 26 amostras nesta faixa. O segundo agrupamento maior está contido entre 0 e 0,2 composto por 10 amostras, sendo um erro esperado com variações negativas o que se mostra um erro perigoso, pois isso irá diminuir o fator de segurança previsto. Mostrando que o valor estimado está próximo do real e está coerente com a média geral do erro apresentada de 0,23%.

4.2. Modelo de regressão: Teste

O modelo de teste acontece posteriormente ao modelo de treino e utiliza modelo treinado como referência para definição dos resultados. Após o treinamento do modelo de treino, o banco de dados de teste é adicionado ao

Random Forest e o conjunto das árvores de decisão analisam os resultados seguindo os parâmetros de aprendizagem utilizado anteriormente.

Para o modelo de teste, foi utilizado um banco de dados com 21 amostras como mostrado na Figura 34, que pode ser visualizado com todas as suas variáveis de origem, exceto a coluna nomeada como Random Forest que é o fator de segurança proposto. Comparando os resultados preditos para teste versus o real, é visto que, o fator de segurança predito apresentou 7 amostras dentre as 21, com valores acima do valor real, apresentando uma média superior de 0,253 as outras 14 amostras do banco apresentaram um valor predito abaixo do real, com uma média de -0,288 e a média geral de diferença entre os valores reais versus preditos é de 0,108.

Avaliando a variação dos resultados tanto negativa quanto positiva, assim, os valores preditos apenas para teste apresentam um desvio maior em comparação com o modelo de treino. É comum o modelo de treino apresentar resultados com diferenças menores entre os resultados, pois o Random Forest utiliza o banco de dados e os parâmetros do modelo de treino justamente para que aconteça a sua aprendizagem. Desta forma, as validações seguintes utilizam o modelo de treino como parâmetro de avaliação do conjunto de dados apresentados.

Figura 34- Fator de segurança proposto pelo Random Forest para teste

	Random Forest	F	P	C	AA	AT	HT	R
1	1.411	2.31	20.00	40.00	40.00	40.00	10.00	0.20
2	1.592	2.09	18.00	45.00	25.00	25.00	14.00	0.30
3	1.455	2.00	19.00	30.00	35.00	35.00	11.00	0.20
4	1.486	1.84	20.00	40.00	30.00	30.00	15.00	0.30
5	1.370	1.84	21.00	20.00	40.00	40.00	12.00	0.00
6	1.339	1.53	21.00	45.00	25.00	49.00	12.00	0.30
7	1.237	1.49	21.00	30.00	35.00	40.00	12.00	0.40
8	1.253	1.46	18.80	30.00	20.00	30.00	50.00	0.10
9	1.165	1.43	21.00	35.00	28.00	40.00	12.00	0.50
10	1.392	1.40	18.80	30.00	10.00	25.00	50.00	0.10
11	1.266	1.34	20.00	10.00	29.00	34.00	6.00	0.30
12	1.162	1.29	18.85	10.34	21.30	34.00	37.00	0.30
13	1.101	1.21	18.80	25.00	20.00	30.00	50.00	0.20
14	1.244	1.18	18.80	25.00	10.00	25.00	50.00	0.20
15	1.309	1.12	22.00	20.00	22.00	20.00	180.00	0.00
16	1.033	1.07	18.85	24.80	21.30	29.20	37.00	0.50
17	1.094	1.00	18.80	20.00	20.00	30.00	50.00	0.30
18	1.307	0.99	22.00	20.00	22.00	20.00	180.00	0.10
19	1.247	0.97	18.80	20.00	10.00	25.00	50.00	0.30
20	0.993	0.65	19.10	10.00	20.00	30.00	50.00	0.40
21	1.140	0.65	19.10	10.00	10.00	25.00	50.00	0.40

O Random Forest pode dar previsões de dois tipos:

- Conservadoras: quando o fator de segurança predito é maior que o real;
- Perigosas: caso o fator de segurança predito seja menor do que o real.

Outra avaliação que pode ser realizada com esse banco de dados da Figura 34 é se a amostra é do tipo atritiva que são solos arenosos ou coesos que são solos mais argilosos.


Para realizar esta classificação foi levado em consideração ângulos de atrito(AA) maiores que 25 e coesão(C) igual a zero para ser considerado um solo atritivo de acordo com os parâmetros geotécnicos. Assim foi definido que de 46 amostras, 33 eram atritivas e as outras 13 amostras eram mais propenso a ser coesas, ou seja, ser solos argilosos.

A classificação do tipo de solo foi realizada de forma preditiva de acordo com os valores encontrados na coluna AA e C, para que esta classificação seja mais precisa é importante que uma avaliação visual em campo aconteça.

Observando a Figura 35 no eixo x e y consegue-se definir se esses valores são seguros ou não para se trabalhar. Analisando individualmente o eixo x e observando em vermelho a linha de fator de segurança mínima para o talude ser considerado estável, a grande maioria das amostras se encontram com fator de segurança acima de 1 adotando então como valor de estabilidade do talude.

Porém algumas amostras se encontram com o fator abaixo de 1, esses valores podem ser considerados perigosos para a estabilidade do maciço, por isso uma avaliação em campo destas amostras seria o mais indicado para se confirmar a previsão do software. No eixo y, os valores são referentes ao erro (valor predito menos o real), é possível observar que a grande maioria das amostras se encontram abaixo da linha de valor 0, desta forma, a maioria das amostras preditas se encontram menor que o real.

Figura 35 - Interpolação do erro em valores conservadores vs risco




A Figura 35 permite uma discussão em função dos resultados que se apresentam se estes são conversadores ou perigosos. Para a realização desta avaliação a fórmula do erro é de grande auxílio para a interpretação, onde ela é constituída pelo fator de segurança predito sendo subtraído do fator de segurança real. Desta forma, erros negativos nos informam que a predição realizada é perigosa, pois significa que a predição do fator de segurança esta abaixo do real, desta maneira, encontrando um fator de segurança subestimado e utilizando parâmetros de resistência subestimados para a estabilização do talude.

Erros positivos, que são os erros acima de 0, são erros conservadores, pois o Random Forest está superestimando o resultado do fator de segurança, fornecendo desta maneira um resultado maior que o necessário para aquele

talude, desta forma utilizando técnicas de estabilização além do necessário.


Avaliando o pico do histograma da Figura 36, é possível ver um agrupamento maior com assimetria à esquerda entre os valores entre 0 até 0,2. Continuando a análise, a maioria das amostras do banco de dados apresenta um erro positivo, pois estão contidas acima de 0 no eixo x.

Figura 36 – Histograma erro vs frequência do erro



O gráfico de dispersão nos mostra com clareza a diferença entre os resultados obtidos no fator de segurança real versus o predito para o modelo de teste, Figura 37, apresentando um R^2 de 0,87.

Figura 37 - Gráfico de dispersão: Random Forest vs fator de segurança



Como o modelo já passou pelo processo de aprendizagem o Random Forest classificou os resultados adotando os parâmetros de treino como modelo, assim foi possível reconhecer no teste os dados ou parâmetros em estudo. É possível visualizar que eles se apresentam em uma dispersão maior em comparação com o modelo de treino Figura 32, pois no treino, o modelo entendeu quais são as variáveis de maior interesse e aperfeiçoou os parâmetros de decisão das árvores para obter o melhor resultado possível.


4.3. Modelo de classificação: Treino

O modelo de treino para classificação apresenta a mesma configuração do modelo de treino para predição, utilizando o mesmo banco de dados e as mesmas configurações para o Random Forest. O widget de avaliação de treinamento calcula várias estatísticas de desempenho como pode ser visto na Figura 38, onde:

- *Area under ROC* ou área sob a curva(AUC): que é a área sob a curva de operação do receptor. A precisão do teste depende de quão bem separado está o grupo testado, que neste caso apresenta um valor igual a 1 apresentando uma excelente separação do grupo em análise.


- Classification accuracy ou precisão da classificação (CA): que é a proporção de exemplos classificados corretamente, onde pode ser visto um valor de 0,978 bem próximo de um, que significa que a grande maioria dos dados foram classificados corretamente.
- F1: é o cálculo entre a precisão e a solicitação do teste, onde a precisão é o número de resultados positivos verdadeiros dividida pelo número de todos resultados positivos onde é incluso até os resultados não foram bem classificados. A solicitação é o número de todas as amostras que deveriam ser classificadas como positivas. O maior valor possível para F1 é o 1 que indica precisão e recuperações perfeitas, como resultado foi obtido um valor de 0,978 indicando uma boa precisão e uma recuperação quase perfeita.
- Precision ou valor predito positivo: é a proporção de verdadeiros positivos entre amostras classificadas como positiva. Como resultado obteve-se um valor de 0,979 que é bem próximo de 1 que é o valor máximo que pode ser obtido, significando uma boa recuperação de informações.
- Recall ou sensibilidade: é a proporção de verdadeiros positivos entre todas as instâncias positivas nos dados. Com um resultado de 0,978 no modelo mostrando uma sensibilidade bastante relevante e aderente.

Figura 38 - Resultados da avaliação de treinamento para classificação



Na Figura 38 foram vistos os resultados obtidos na avaliação de treinamento, mostrando que os parâmetros estão todos com resultados iguais a 1 ou então com valores bem próximos. Significando que a classificação dos resultados como estáveis e instáveis foram bastante precisas e eficientes, apresentando poucos erros de classificação. Na Figura 39 é observado os resultados dessa classificação graficamente, e é possível observar que entre todas as 46 amostras apenas uma foi classificada de forma errada.

Figura 39 – Resultados gráficos para o modelo treino de classificação



Outra forma de apresentar esses resultados é através da matriz de confusão como pode ser visto na Figura 40. Onde é mostrado novamente que apenas uma das amostras foi classificada de forma errônea, sendo um talude estável e sendo classificado como instável na matriz de confusão, essa classificação é chamada de falso negativo.

Figura 40 - Matriz de confusão

		Predito		Σ
		Instável	Estável	
Real	Instável	29	0	29
	Estável	1	16	17
		30	16	46

Através dos resultados da matriz de confusão encontrou-se uma acurácia de 0,978 utilizando a equação 45, com a equação 46 foi possível encontrar a precisão do Random Forest que foi igual a 0,941. Como o modelo apresentou apenas uma amostra classificada de forma errada a taxa de erro aparente (equação 47) foi igual a 0,022 sendo um valor bastante satisfatório. Além de um erro aparente baixo o modelo apresentou um bom resultado para a sensibilidade (equação 48) e para especificidade (equação 49) com o valor máximo de 1 para a sensibilidade e de 0,967 para a especificidade. E a partir dos resultados de sensibilidade e especificidade foi possível encontrar a eficiência que é a média entre os dois resultados (equação 50) que apresentou um resultado de 0,983 sendo um resultado eficaz mostrando mais uma vez a aplicabilidade e eficiência no modelo classificatório do Random Forest.

4.4. Modelo de classificação: Teste

Para a realização do teste no modelo de classificação como para o modelo de regressão foi adicionado o banco de dados com 21 amostras distintas e foi utilizado as mesmas especificações do Random Forest. Na Figura 41 é possível observar a avaliação de cada amostra como instável e estável na coluna Random Forest(1) e o restante das variáveis são variáveis já definidas pelo trabalho de Ferentinou(2004) sendo assim, definidas como variáveis *default*.

Figura 41 – Classificação da estabilidade para modelo classificatório de teste


	Random Forest (1)	F	P	C	AA	AT	HT	R
1	Stable	1.84	21.00	20.00	40.00	40.00	12.00	0.00
2	Failed	1.53	21.00	45.00	25.00	49.00	12.00	0.30
3	Failed	1.49	21.00	30.00	35.00	40.00	12.00	0.40
4	Failed	1.43	21.00	35.00	28.00	40.00	12.00	0.50
5	Stable	1.34	20.00	10.00	29.00	34.00	6.00	0.30
6	Stable	1.84	20.00	40.00	30.00	30.00	15.00	0.30
7	Stable	2.09	18.00	45.00	25.00	25.00	14.00	0.30
8	Stable	2.00	19.00	30.00	35.00	35.00	11.00	0.20
9	Stable	2.31	20.00	40.00	40.00	40.00	10.00	0.20
10	Failed	1.07	18.85	24.80	21.30	29.20	37.00	0.50
11	Failed	1.29	18.85	10.34	21.30	34.00	37.00	0.30
12	Failed	1.40	18.80	30.00	10.00	25.00	50.00	0.10
13	Failed	1.18	18.80	25.00	10.00	25.00	50.00	0.20
14	Failed	0.97	18.80	20.00	10.00	25.00	50.00	0.30
15	Failed	0.65	19.10	10.00	10.00	25.00	50.00	0.40
16	Failed	1.46	18.80	30.00	20.00	30.00	50.00	0.10
17	Failed	1.21	18.80	25.00	20.00	30.00	50.00	0.20
18	Failed	1.00	18.80	20.00	20.00	30.00	50.00	0.30
19	Failed	0.65	19.10	10.00	20.00	30.00	50.00	0.40
20	Failed	1.12	22.00	20.00	22.00	20.00	180.00	0.00
21	Failed	0.99	22.00	20.00	22.00	20.00	180.00	0.10

Outra avaliação que pode ser realizada com esse banco de dados da Figura 41 é se a amostra é do tipo atritiva ou coesiva. Utilizando o mesmo critério para o modelo de regressão para teste, Figura 34, foi definido que de 21 amostras 7 eram atritivas e o restante era mais propenso a ser coesas, ou seja, são solos argilosos. A classificação do tipo de solo foi realizada de forma classificatória de acordo com os valores encontrados na coluna AA e C, para que esta classificação seja mais precisa é importante que uma avaliação visual em campo aconteça.

Na Figura 42, é possível avaliar melhor a disposição dos resultados da Figura 41 em um gráfico de dispersão mostrando a predição de estabilidade versus o fator de segurança real de cada talude.

O primeiro quadrante da Figura 42 (parte superior direita) pode notar um acúmulo de 6 amostras, em relação ao eixo x os dados desse quadrante estão estáveis e em relação ao eixo y o fator de segurança(F) está acima de 1 mostrando que os resultados da classificação estão distribuídos de forma coerente e verdadeira.

Figura 42 - Predição de estabilidade vs FS



No segundo quadrante (parte superior esquerda) que é a parte superior esquerda e possui 11 amostras, apresenta um fator de segurança acima de 1 e foram classificadas como instáveis, portanto, esses resultados não estão coerentes sendo considerado um falso instável, pois na realidade o talude é estável, mas foi classificado como instável.

No terceiro quadrante (parte inferior esquerda), mostra um conjunto com 4 amostras com o fator de segurança abaixo de 1 e sendo consideradas instáveis, neste caso a classificação está coerente pois fatores de segurança abaixo de 1 são considerados risco iminente de ruptura.

No quarto quadrante (parte inferior direita) não existe nenhuma amostra nesse quadrante, portanto nenhuma amostra foi classificada de forma errônea.

5 CONCLUSÃO

Após toda a manipulação realizada dentro do software Orange Data Mining, foi possível dizer que todos os resultados encontrados foram satisfatórios, tornando a metodologia do sistema de recomendação bastante útil para a tomada de decisões rápidas, em lugares onde já existam bancos de dados conhecido, ou seja, as informações mínimas do local.

O modelo de predição para treino mostrou resultados para o fator de segurança bem próximos do real que foram devidamente calculados. Desta forma é possível concluir que entre as 200 árvores de decisão, a grande maioria delas optou por resultados mais conservadores e não discrepantes do real. O modelo de teste na regressão apresentou desvios um pouco maiores em comparação ao modelo de treino, o que já era esperado, pois as árvores foram treinadas para realizar a predição em cima do modelo de treino. Desta forma os resultados são coerentes, pois as árvores realizaram os testes com os parâmetros treinados anteriormente, mostrando resultados altamente conservadores com MSE, RMSE, MAE próximos de 0 mostrando um bom ajuste do modelo do *Random Forest*, e para o R^2 um resultado bem próximo de 1, que é o valor máximo que pode ser obtido, mostrando uma alta eficiência do modelo proposto.

Para o modelo classificatório os resultados obtidos apresentaram um bom desempenho, onde apenas um dado foi classificado de forma errônea dentre as 46 amostras no modelo de treino. Em relação a aplicação do modelo de teste o software apresentou uma quantidade maior de erro, o que também era esperado devido aos parâmetros que estão sendo seguido como base do modelo de treino. Apresentando resultados com área sob a curva, precisão de classificação, F1, e a predição com resultados bem próximos de 1, que é o valor máximo que pode ser obtido.

Para trabalhos futuros a utilização de softwares como Slide e o *R Development Core Team*, além de uma classificação prévia do banco de dados, podem fornecer melhores resultados, particionando o banco de dados em dados atritivos e coesos, treinando cada um de forma individual, desta forma é possível obter resultados ainda mais precisos.

6 REFERÊNCIAS

- AGUILERA, C. E. T. **Aplicação de métodos de análise de estabilidade de taludes de grande altura em mineração**. Tese (Mestrado em geotecnia)- PUC-RIO, Rio de Janeiro, 2009. Disponível em: < <https://www.maxwell.vrac.puc-rio.br/colecao.php?strSecao=resultado&nrSeq=31859@1>>. Acesso em: 01 jun, 2022.
- ALVARENGA JÚNIOR, W. J. **Métodos de otimização Hiperparamétrica: um estudo comparativo utilizando árvores de decisão e florestas aleatórias na classificação Binária**. 2018. Dissertação (Mestrado em engenharia elétrica) - Universidade Federal de Minas Gerais, Belo Horizonte, 2018. Disponível em: < <https://www.ppgee.ufmg.br/defesas/1461M.PDF>>. Acesso em: 01 ago, 2022.
- ANDRADE, T. J. R. **Estabilidade de Vertentes nas formações vulcânicas da Ilha da Madeira**. 2011. Dissertação (Mestrado em engenharia civil) - Universidade da Madeira, Funchal, 2011. Disponível em: < <https://digituma.uma.pt/bitstream/10400.13/406/1/MestradoTonyAndrade.pdf>>. Acesso em: 30 jul, 2022.
- ANTOCHEVIZ, R. B. **Metodologia para determinação do procedimento a ser utilizado em uma análise de estabilidade de taludes - Ruptura circular**. 2018. Dissertação (Mestrado em engenharia de minas, metalúrgica e de materiais) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2018. Disponível em: <<https://www.lume.ufrgs.br/bitstream/handle/10183/184854/001079467.pdf?sequence=1>>. Acesso em: 5 jun, 2022.
- ARMELIN, Luiz. **Medição de tensões in situ em maciços rochosos e estruturas de concreto**. 2010. Tese (Doutorado em geotecnia) - Universidade de Brasília, Brasília, 2010. Disponível em:<<https://repositorio.unb.br/handle/10482/7674> >. Acesso em: 27 mai, 2022.
- AYACHE, N. K. **Avaliação das condições de estabilidade de taludes de mina por meio de árvores de decisão**. 2021. CEFET, Araxá. Disponível em: < https://www.eng-minas.araxa.cefetmg.br/wp-content/uploads/sites/170/2021/12/Versao_final_NAIM-KHALIL-AYACHE.pdf >. Acesso em: 27 mai, 2022.
- BARBOSA, J. P. N. **Alternativas para estabilização preventiva de um talude em zona urbana na cidade de Palmas, Tocantins**. 2019. Centro Universitário Luterano de Palmas, Palmas, 2019. Disponível em: < <https://ulbra-to.br/bibliotecadigital/publico/home/documento/1692>>. Acesso em: 20 jun, 2022.

BISHOP, A. W. **The Use of Slip Circle in the Stability Analysis of Earth Slopes**. Géotechnique, v. 05, n. 01, p. 7 – 17, 1955.

BISHOP, A. W. and MORGENSTERN, N. (1960) – **Stability Coefficients for Earth Slopes**.

CONSTANTE, J. V. **Mineração multimídia de imagens usando a ferramenta Orange**. 2021. Universidade do Sul de Santa Catarina, Florianópolis, 2021. Disponível em: <
https://repositorio.animaeducacao.com.br/bitstream/ANIMA/13793/1/Joao_Constante_630430.pdf>. Acesso em: 05 set, 2022.

DILÁSCIO, M, V. **Estudo computacional do mecanismo de tombamento flexural em filitos**. 2004. Dissertação (Mestrado em engenharia civil) - Universidade Federal de Ouro Preto, Ouro Preto, 2004. Disponível em:
https://www.repositorio.ufop.br/bitstream/123456789/6435/1/DISSERTA%C3%87%C3%83O_EstudoComputacionalMecanismo.pdf> . Acesso em: 5 jun, 2022.

DELGADO FILHO, A. J. F. **Análise de métodos de regressão para previsão de demanda de curto prazo**. 2020. Dissertação (Mestrado em ciência da computação) - Universidade Federal de Pernambuco, Recife, 2020. Disponível em:<
https://repositorio.ufpe.br/bitstream/123456789/38123/1/DISSERTA%C3%87%C3%83O_Antonio_Jorge_Ferreira_Delgado_Filho.pdf>. Acesso em: 07 ago, 2022.

DOURADO, W. B. **Avaliação de técnicas de interpolação de imagens digitais**. 2014. Dissertação (Mestrado em matemática aplicada e computacional) - Universidade Estadual Paulista, Presidente Prudente, 2014. Disponível em:<
<https://repositorio.unesp.br/bitstream/handle/11449/115892/000806982.pdf?sequence=1&isAllowed=y>>. Acesso em: 17 set, 2022.

FERENTINOU, M; SAKELLARIOU, M . **A study of slope stability prediction using neural networks**. Disponível em:
<<https://link.springer.com/article/10.1007/s10706-004-8680-5>> . Acesso em: 02 mar, 2022.

FERREIRA, J. F. **Análise de estabilidade de taludes pelos métodos de Janbu e Spencer**. 2012. Dissertação (Mestrado em geotecnia) - Universidade do Porto, Porto, 2012. Disponível em: < <https://repositorio-aberto.up.pt/bitstream/10216/64689/1/000151854.pdf>>. Acesso em: 30 jun, 2022.

GOMES, T. **Ferramentas open source de data mining**. 2014. Dissertação (Mestrado em informática e sistemas) - Instituto Superior de Engenharia de Coimbra, Coimbra, 2014. Disponível em:<
<https://comum.rcaap.pt/bitstream/10400.26/14084/1/Tania-Gomes.pdf>>. Acesso em: 03 set, 2022.

HOEK, E. and BRAY, J. W. (1981) – Rock Slope Engineering,” The Institution of Mining and Metallurgy, London, England.

HUALLANCA, R. E. Z. **Mecanismos de ruptura em taludes altos de mineração a céu aberto**. 2004. Dissertação (Mestrado em geotecnia) - Universidade de São Paulo, São Carlos, 2004. Disponível em: <<https://www.teses.usp.br/teses/disponiveis/18/18132/tde-21092007-161107/publico/dissertacao1.pdf>>. Acesso em: 27 mai, 2022.

IZBICKI, R; SANTOS, T. M. **Aprendizado de máquina: uma abordagem estatística**. 1º ed. São Carlos: CBL, 2020. 141 p.

JANBU, N. **Application of Composite Slip Surfaces for Stability Analyses**. European Conference on Stability of Earth Slopes, v. 03, p. 43 – 49, 1954.

JANBU, N. **Slope Stability Computations**. In: HIRCHFELD, R. C.; POULOS, S. J. (Eds) Embankment Dam Engineering, New York: John Wiley & Sons, 1973. p. 47 – 86

LUGO, V. A. V. **Determinação das tensões in situ superficiais mediante uso da técnica fotogrametria digital de curta distância**. 2013. Tese (Mestrado em engenharia civil) - Universidade Estadual do Norte Fluminense, Campos dos Goytacazes, 2013. Disponível em: <<https://uenf.br/posgraduacao/engenharia-civil/wp-content/uploads/sites/3/2015/09/V%C3%8DCTOR-ALONSO-V%C3%81SQUEZ-LUGO.compressed.pdf>>. Acesso em: 30 mai, 2022.

MASCIA, N.T. **Teoria das tensões**. 2006. Apostila - UNICAMP, Campinas, 2006. Disponível em:< <http://www.fec.unicamp.br/~nilson/ApostilaTensao.pdf>>. Acesso em: 27 mai, 2022.

MORGENSTERN, N. R.; PRICE, V. W. **The Analysis of the Stability of General Slip Surfaces**. Géotechnique, v. 15, n. 1, p. 79 – 93, 1965.

PEREIRA, T. S. **Avaliação do desempenho de diferentes métodos de análise de estabilidade de taludes em barragens de terra**. 2013. Dissertação (Mestrado em engenharia agrícola) - Universidade Federal de Santa Maria, Santa Maria, 2013. Disponível em: <<https://repositorio.ufsm.br/bitstream/handle/1/7565/PEREIRA%2c%20TONISMAR%20DOS%20SANTOS.pdf?sequence=1&isAllowed=y>>. Acesso em: 02 jul, 2022.

PIO, A. F. **Fundamento de mecânica dos solos e das rochas: aplicações na estabilidade de taludes**. 1º edição. São Paulo SP: Oficina de textos, 2015.

RODRIGUES, B. G. D. **Uso de árvores de decisão para avaliação da segurança estática em tempo real de sistemas elétricos de potência**. 2014. Dissertação (Mestrado em sistemas de energia elétrica) - Universidade Federal do Pará, Belém, 2014. Disponível em:<

http://repositorio.ufpa.br/jspui/bitstream/2011/6280/6/Dissertacao_UsoArvoreDecisao.pdf>. Acesso em: 04 ago, 2022.

SANTOS, A. E. M. **Classificação de maciços rochosos por meio de técnicas da estatística multivariada e inteligência artificial**. 2021. Dissertação (doutorado em engenharia mineral) - Universidade Federal de Ouro Preto, Ouro Preto, 2021. Disponível em <https://www.repositorio.ufop.br/bitstream/123456789/13839/1/TESE_ClassificacaoMaciosRochosos.pdf>. Acesso em: 07 mai, 2022.

SANTOS, A. E. M. **Predição da condição de estabilidade de taludes de mina por meio de estatística multivariada**. 2016. Dissertação (mestrado em engenharia mineral) - Universidade Federal de Ouro Preto, Ouro Preto, 2016. Disponível em <<https://www.repositorio.ufop.br/handle/123456789/7362>>. Acesso em: 07 mai, 2022.

SANTOS, A. E. M.; DA SILVA, D. de F. S. **Stability Conditions Evaluation of Slope by Multivariate Analysis**. HOLOS, [S. l.], v. 3, p. 1–13, 2021. DOI: 10.15628/holos.2020.9036. Disponível em: <<https://www2.ifrn.edu.br/ojs/index.php/HOLOS/article/view/9036>>. Acesso em: 5 abr. 2022.

SJOBERG, J. **Analysis of Large Scale Rock Slope**. 1999. 292 p. Doctoral Thesis, Division of Rock Mechanics, Lulea University of Technology, Sweden, 1999.

SILVA, V. C. **Métodos analíticos para avaliar a contribuição de estacas para o fator de segurança de taludes**. 2013. Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2013. Disponível em: <<https://pantheon.ufrj.br/bitstream/11422/9575/1/monopoli10006556.pdf>>. Acesso em: 22 jun, 2022.

SIQUEIRA, F. M. F. **Estratégia de otimização de processos com o uso de redes neurais artificiais**. 2021. Dissertação (Mestrado em engenharia química) - Universidade Federal Fluminense, Niterói, 2021. Disponível em: <[https://app.uff.br/riuff/bitstream/handle/1/22073/Dissertacao de Mestrado - Felipe Macedo Freitas Siqueira..pdf?sequence=1&isAllowed=y](https://app.uff.br/riuff/bitstream/handle/1/22073/Dissertacao%20de%20Mestrado%20-%20Felipe%20Macedo%20Freitas%20Siqueira..pdf?sequence=1&isAllowed=y)>. Acesso em: 16 ago, 2022.

SPENCER, E. **A Method of Analysis of the Stability of Embankments Assuming Parallel Inter-slice Forces**. Géotechnique, v. 17, n. 1, p. 11 – 26, 1967.

TAPE, T. G. **Interpreting diagnostic tests**. University of Nebraska Medical Center, Omaha. Disponível em : <<https://darwin.unmc.edu/dxtests/Default.htm>>. Acesso em: 03 out, 2022.

TOLL, D.: **Artificial Intelligence Systems for geotechnical engineering with specific reference to the ground improvement**, In: Proc. Tenth European Young Geotechnical Engineers Conference, Izmir, Turkey, 1996.

VERÍSSIMO, G. Z; PAIVA, L. G. G. **Tipos de ruptura geológico e geotécnica, tipos de ruptura e estabilidade de taludes na mina de ferro do bonito em Jucurutu – RN.** 2014. Universidade Federal do Ceará, Fortaleza, 2014.

Disponível em: <<https://repositorio.ufc.br/handle/riufc/41845>>. Acesso em: 30 mai, 2022.

WOLPP, L. **Caracterização e classificação geomecânica de um talude de Santa Helena Mineração LTDA.** 2018. CEFET, Araxá, 2018. Disponível em: <<https://www.eng-minas.araxa.cefetmg.br/wp-content/uploads/sites/170/2018/05/Luis-fernando-de-lima-wolpp.pdf>>.

Acesso em: 01 jun, 2022.

YANG, Y. and ROSENBAUM, M.S.: **The artificial neural network as a tool for assessing geotechnical properties**, Geotech. Geol. Eng., 20, (2001), 149–168.

APÊNDICE

Figura A1 - Fator de segurança proposto pelo Random Forest para treino

Instances	Random Forest	F	P	C	AA	AT	HT	R
1	1.202	1.11	18.68	26.34	15	35	8.23	0
2	1.119	1	16.5	11.49	0	30	3.66	0
3	1.642	1.875	18.84	14.36	25	20	30.5	0
4	1.785	2.045	18.84	57.46	20	20	30.5	0
5	1.686	1.78	28.44	29.42	35	35	100	0
6	1.762	1.99	28.44	39.23	38	35	100	0
7	1.27	1.25	20.6	16.28	26.5	30	40	0
8	1.188	1.13	14.8	0	17	20	50	0
9	1.007	1.02	14	11.97	26	30	88	0
10	1.339	1.3	25	120	45	53	120	0
11	1.324	1.2	26	150.05	45	50	200	0
12	1.065	1.09	18.5	25	0	30	6	0
13	1.016	0.78	18.5	12	0	30	6	0
14	1.648	2	22.4	10	35	30	10	0
15	1.364	1.7	21.4	10	30.34	45	20	0
16	1.032	1.02	22	20	36	45	50	0
17	0.967	0.89	22	0	36	45	50	0
18	1.307	1.46	12	0	30	35	4	0
19	0.95	0.8	12	0	30	45	8	0
20	1.307	1.44	12	0	30	35	4	0
21	0.95	0.86	12	0	30	45	8	0
22	1.184	1.08	23.47	0	32	37	214	0
23	1.218	1.11	16	70	20	40	115	0
24	1.364	1.4	20.41	24.9	13	22	10.67	0.35
25	1.305	1.35	19.63	11.97	20	22	12.19	0.405
26	1.075	1.03	21.82	8.62	32	28	12.8	0.49
27	1.415	1.28	20.41	33.52	11	16	45.72	0.2
28	1.585	1.63	18.84	15.32	30	25	10.67	0.38
29	1.161	1.05	18.84	0	20	20	7.62	0.45
30	1.054	1.03	21.43	0	20	20	61	0.5
31	1.213	1.09	19.06	11.71	28	35	21	0.11
32	1.25	1.11	18.84	14.36	25	20	30.5	0.45
33	1.118	1.01	21.51	6.94	30	31	76.81	0.38
34	0.831	0.625	14	11.97	26	30	88	0.45
35	1.165	1.12	18	24	30.15	45	20	0.12
36	1.292	1.2	23	0	20	20	100	0.3
37	1.585	1.8	22.4	100	45	45	15	0.25
38	1.169	0.9	22.4	10	35	45	10	0.4
39	0.949	0.96	20	20	36	45	50	0.25
40	0.819	0.83	20	20	36	45	50	0.5
41	0.891	0.79	20	0	36	45	50	0.25
42	0.784	0.67	20	0	36	45	50	0.5
43	1.452	1.45	22	0	40	33	8	0.35
44	1.564	1.58	24	0	40	33	8	0.3
45	1.407	1.37	20	0	24.5	20	8	0.35
46	1.703	2.05	18	5	30	20	8	0.3

Script modelo de regressão:

```

<?xml version='1.0' encoding='utf-8'?>
<scheme version="2.0" title="" description="">
  <nodes>
    <node id="0" name="File"
qualified_name="Orange.widgets.data.owfile.OWFile" project_name="Orange3"
version="" title="File" position="(312.0, 435.0)" />
    <node id="1" name="Random Forest"
qualified_name="Orange.widgets.model.owrandomforest.OWRandomForest"
project_name="Orange3" version="" title="Random Forest" position="(545.0,
375.0)" />
    <node id="2" name="Predictions"
qualified_name="Orange.widgets.evaluate.owpredictions.OWPredictions"
project_name="Orange3" version="" title="Predictions" position="(750.0, 442.0)"
/>
    <node id="3" name="File"
qualified_name="Orange.widgets.data.owfile.OWFile" project_name="Orange3"
version="" title="File (1)" position="(317.0, 566.0)" />
    <node id="4" name="Scatter Plot"
qualified_name="Orange.widgets.visualize.owscatterplot.OWScatterPlot"
project_name="Orange3" version="" title="Scatter Plot" position="(950.0,
575.0)" />
    <node id="5" name="Test and Score"
qualified_name="Orange.widgets.evaluate.owtestandscore.OWTestAndScore"
project_name="Orange3" version="" title="Test and Score" position="(664.0,
221.0)" />
    <node id="6" name="Feature Constructor"
qualified_name="Orange.widgets.data.owfeatureconstructor.OWFeatureConst
ructor" project_name="Orange3" version="" title="Feature Constructor"
position="(940.0, 348.0)" />
    <node id="7" name="Distributions"
qualified_name="Orange.widgets.visualize.owdistributions.OWDistributions"
project_name="Orange3" version="" title="Distributions" position="(1107.0,
355.0)" />
    <node id="8" name="Scatter Plot"
qualified_name="Orange.widgets.visualize.owscatterplot.OWScatterPlot"
project_name="Orange3" version="" title="Scatter Plot (1)" position="(1105.0,
259.0)" />
  </nodes>
  <links>
    <link id="0" source_node_id="1" sink_node_id="2"
source_channel="Model" sink_channel="Predictors" enabled="true" />
    <link id="1" source_node_id="2" sink_node_id="4"
source_channel="Predictions" sink_channel="Data" enabled="true" />
    <link id="2" source_node_id="0" sink_node_id="1"
source_channel="Data" sink_channel="Data" enabled="true" />
    <link id="3" source_node_id="1" sink_node_id="5"
source_channel="Learner" sink_channel="Learner" enabled="true" />
  </links>
</scheme>

```

```

    <link id="4" source_node_id="0" sink_node_id="5"
source_channel="Data" sink_channel="Data" enabled="true" />
    <link id="5" source_node_id="2" sink_node_id="6"
source_channel="Predictions" sink_channel="Data" enabled="true" />
    <link id="6" source_node_id="6" sink_node_id="7"
source_channel="Data" sink_channel="Data" enabled="true" />
    <link id="7" source_node_id="6" sink_node_id="8"
source_channel="Data" sink_channel="Data" enabled="true" />
    <link id="8" source_node_id="0" sink_node_id="2"
source_channel="Data" sink_channel="Data" enabled="true" />
  </links>
  <annotations />
  <thumbnail />
  <node_properties>
    <properties node_id="0"
format="pickle">gASVgAsAAAAAAB9lCiMEmNvbnRyb2xBcmVhVmlzaWJsZZ
SljAxyZWNIbnRfcGF0aHOuXZQojB5v
cmFuZ2V3aWRnZXQudXRpbHMuZmlsZWV3aWRpYWxvZ3OUjApSZWNlbnRQYXR
olJOUKYGUfZQojAdhYnNw
YXRollxNQzovVXNlcnMvYWxsYW4vT25lRHJpdMUvw4FyZWEgZGUgVHJhY
mFsaG8vdHJhYmFsaG9f
amFpbmEvdHJlaW5vX2NpcmN1bGFyLnhszc3iUjAZwcmVmaXiUjAdiYXNIZGlyll
wHcmVscGF0aJSM
FHRyZWlub19jaXJjdWxhci54bHN4IlwFdGI0bGWUjACUjAVzaGVldJR0ElwLZm
lsZV9mb3JtYXSU
TnViaAYpgZR9lChoCYw7QzovVXNlcnMvYWxsYW4vT25lRHJpdMUvw4FyZW
EgZGUgVHJhYmFsaG8v
YmFuY29fbGF1cmEyLnhszc3iUaAtOaA1OaA9oEGgRaBBoEk51YmgGKYGUfZ
QoaAmMOKM6L1VzZXJz
L2FsbGFuL09uZURyaXZIL8OBcmVhIGRIIFRyYWJhbGhvL2JhbmNvX2xhdXJh
Lnhszc3iUaAtOaA1O
aA9oEGgRaBBoEk51YmgGKYGUfZQoaAmMZ0M6L1VzZXJzL2FsbGFuL21pb
mljb25kYTMvcGtnY9v
cmFuZ2UzLTmuMzEuMS1weTM4aDVkOTI4ZTJfMC9MaWlvc2l0ZS1wYWNRy
Wdlcy9PcmFuZ2UvZGF0
YXNldHMvaXJpcy50YWKUaAtOaA1OaA9oEGgRaBBoEk51YmgGKYGUfZQoa
AmMNUM6L1VzZXJzL2Fs
bGFuL09uZURyaXZIL8OBcmVhIGRIIFRyYWJhbGhvL1Bhc3RhMy54bHN4IGg
L
TmgNTmgPaBBoEWgQ
aBJOdWJoBimBIH2UKGgJjGpDOi9Vc2Vycy9hbGxhbi9taW5pY29uZGEzL3BrZ
3Mvb3JhbmdlMy0z
LjMxLjEtcHkzOGg1ZDkyOGUyXzAvTGliL3NpdGUtcGFja2FnZXMuV3Jhbm
dIL2
RhdGFzZXZlL3Rp
dGFuaWMudGFilGgLTmgNTmgPaBBoEWgQaBJOdWJoBimBIH2UKGgJjEND
Oi9Vc2Vycy9hbGxhbi9P
bmVEcmI2ZS/DgXJIYSBkZSBucmFiYWxoby90cmFiYWxob19jYWlvL1Bhc3Rh
MS54bHN4IGgLTmgN
TmgPaBBoEWgQaBJOdWJoBimBIH2UKGgJjD1DOi9Vc2Vycy9hbGxhbi9Pbm
VEcmI2ZS/DgXJIYSBk

```

ZSBUcmFiYWxoby9QYXN0YTEgLSBDb3BpYS54bHN4IGgLTmgNTmgPaBBo
 EWgQaBJOdWJoBimBIH2U
 KGgJjDVDOi9Vc2Vycy9hbGxhbi9PbmVEcmI2ZS/DgXJIYSBkZSBUcmFiYWxob
 y9QYXN0YTEueGxz
 eJR0C05oDU5oD2gQaBFoEGgSTnViaAYpgZR9lChoCYxbQzovVXNlcnMvYW
 xsYW4vT25lRHJpdmUv
 w4FyZWEgZGUgVHJhYmFsaG8vZXh1bXBsb18yNTAzMjAyMi9ncmlkX2p1cmFf
 YWxsYW5fZXhjZWxf
 dG90YWwueGxzeJR0C05oDU5oD2gQaBFoEGgSTnViaAYpgZR9lChoCYxVQ
 zovVXNlcnMvYWxsYW4v
 T25lRHJpdmUvw4FyZWEgZGUgVHJhYmFsaG8vZXh1bXBsb18yNTAzMjAyMi9
 ncmlkX2p1cmFfYWxs
 YW5fZXhjZWwueGxzeJR0C05oDU5oD2gQaBFoEGgSTnViaAYpgZR9lChoCY
 w9QzovVXNlcnMvYWxs
 YW4vT25lRHJpdmUvw4FyZWEgZGUgVHJhYmFsaG8vYmxvY29zX2p1cmFfb
 m4ueGxzeJR0C05oDU5o
 D2gQaBFoEGgSTnViaAYpgZR9lChoCYxXQzovVXNlcnMvYWxsYW4vQXBwR
 GF0YS9Mb2NhbC9Qcm9n
 cmFtcy9PcmFuZ2UvTGliL3NpdGUtcGFja2FnZXMvT3JhbmdlL2RhdGFzZXRzL
 2lyaXMudGFilGgL
 jA9zYW1wbGUtZGF0YXNldHOUaA2MCGIyaXMudGFilGgPaBBoEWgQaBJOd
 WJoBimBIH2UKGgJjFpD
 Oi9Vc2Vycy9hbGxhbi9BcHBEYXRhL0xvY2FsL1Byb2dyYW1zL09yYW5nZS9M
 aWlvc2l0ZS1wYWNR
 YWdlcy9PcmFuZ2UvZGF0YXNldHMvdGl0YW5pYy50YWKUaAtoN2gNjAt0aXR
 hbmljLnRhYpRoD2gQ
 aBFoEGgSTnViaAYpgZR9lChoCYxaQzovVXNlcnMvYWxsYW4vQXBwRGF0Y
 S9Mb2NhbC9Qcm9ncmFt
 cy9PcmFuZ2UvTGliL3NpdGUtcGFja2FnZXMvT3JhbmdlL2RhdGFzZXRzL2hvd
 XNpbmcudGFilGgL
 aDdoDYwLaG91c2luZy50YWKUaA9oEGgRaBBoEk51YmgGKYGUfZQoaAmM
 YEM6L1VzZXJzL2FsbGFu
 L0FwcERhdGEvTG9jYWwvUHJvZ3JhbXMvT3JhbmdlL0xpYi9zaXRILXBhY2thZ
 2VzL09yYW5nZS9k
 YXRhc2V0cy9oZWYydF9kaXNIYXNlLnRhYpRoC2g3aA2MEWhIYXJ0X2Rpc2V
 hc2UudGFilGgPaBBo
 EWgQaBJOdWJoBimBIH2UKGgJjGFDOi9Vc2Vycy9hbGxhbi9BcHBEYXRhL0x
 vY2FsL1Byb2dyYW1z
 L09yYW5nZS9MaWlvc2l0ZS1wYWNRYWdlcy9PcmFuZ2UvZGF0YXNldHMvYn
 Jvd24tc2VsZWN0ZWQu
 dGFilGgLaDdoDYwSYnJvd24tc2VsZWN0ZWQuudGFilGgPaBBoEWgQaBJOdW
 JoBimBIH2UKGgJjFZD
 Oi9Vc2Vycy9hbGxhbi9BcHBEYXRhL0xvY2FsL1Byb2dyYW1zL09yYW5nZS9M
 aWlvc2l0ZS1wYWNR
 YWdlcy9PcmFuZ2UvZGF0YXNldHMvem9vLnRhYpRoC2g3aA2MB3pvby50YW
 KUaA9oEGgRaBBoEk51
 YmWMC3JIY2VudF91cmxzIF2UjBNzYXZIZFdpZGdlEdlb21ldHJ5IENCAdnQy
 wADAAAAAAK7AAAB
 CAAABb4AAAPXAAACuwAAAQgAAAW+AAAD1wAAAAAAAAAAB4AAAAK7A
 AABCAAABb4AAAPXIIwLc2hl

ZXRfbmFtZXOUfZSMBnNvdXJjZZRLAlwDdXJslGgQjA1kb21haW5fZWRpdG9y
 IH2UjAtfX3ZlcnNp
 b25fX5RLAYwQY29udGV4dF9zZXROaW5nc5RdlwVb3Jhbmdld2lkZ2V0LnNld
 HRpbmdzllwHQ29u
 dGV4dJSTICmBIH2UKlwGdmFsdWVzIH2UKlwJdmFyaWFibGVzIF2UaFV9IGh
 hXZQoXZQojAFQllwU
 T3JhbmdlLmRhdGEudmFyaWFibGWUjBJDb250aW51b3VzVmFyaWFibGWUk
 5RLAGgQiGVdlCiMAUOU
 aGILAGgQiGVdlCiMAkFBIghpSwBoElhIXZQojAJBVJRoaUsAaBCIZV2UKlwCS
 FSUaGILAGgQiGVd
 ICiMAVKUaGILAGgQiGVdlCiMAUaUaGILAWgQiGVdlCiMAVOUaGeMEERpc2
 NyZXRIvmFyaWFibGWU
 k5RLA4wORmFpbGVkLCBTdGFibGWUiWVdlCiMAklkIGHnjA5TdHJpbmdWYX
 JpYWJsZZSTIEsDaBCJ
 ZWVzaFdLAXWMCmF0dHJpYnV0ZXOUKGhmSwKGIGhrSwKGllwCQUGUSw
 KGllwCQVSUSwKGllwCSFSU
 SwKGIGhzSwKGIGh1SwKGIGh3XZQojAZGYWlsZWSUjAZTdGFibGWUZYaUd
 JSMBW1ldGFzllwCSWSU
 SwOGIIWUjApjbGFzc192YXJzICmMEm1vZGImaWVkX3ZhcmllhYmxlc5RdlHV
 iYXUu
 </properties>

<properties node_id="1" format="literal">{'auto_apply': True,
 'class_weight': False, 'controlAreaVisible': True, 'index_output': 0,
 'learner_name': '', 'max_depth': 3, 'max_features': 5, 'min_samples_split': 5,
 'n_estimators': 200, 'savedWidgetGeometry':
 b'\x01\xd9\xd0\xcb\x00\x03\x00\x00\x00\x00\x03\x1e\x00\x00\x01j\x00\x00\x04\xaf\x00\x00\x02\xcd\x00\x00\x03\x1e\x00\x00\x01j\x00\x00\x04\xaf\x00\x00\x02\xcd\x00\x00\x00\x00\x00\x00\x00\x00\x07\x80\x00\x00\x03\x1e\x00\x00\x01j\x00\x00\x04\xaf\x00\x00\x02\xcd', 'use_max_depth': False, 'use_max_features': True, 'use_min_samples_split': True, 'use_random_state': False, '__version__': 1}</properties>

<properties node_id="2"
 format="pickle">gASVCgEAAAAAAAAAB9ICiMEmNvbnRyb2xBcmVhVmlzaWJsZ
 ZSIjBNzYXZIZFdpZGdlEdlb21ldHJ5
 IENCAdnQywADAAAAAABOAAAAHQAAAB38AAQA3AAAATgAAAB0AAAd/AA
 AENwAAAAACAAAAB4AAAAABO
 AAAAHQAAB38AAQA3llwJc2VsZWNOaW9uIF2UjAtzY29yZV90YWJsZZR9llw
 Mc2hvd25fc2NvcmlvZ
 II+UKlwDTUFFllwJUHJIY2lzaW9uIlwCQ0GUjAJGMZSMA0FVQ5SMBFJNU0W
 UjANNU0WUjAJSMpSM
 BIJIY2FsbJSQc4wLX192ZXJzaW9uX1+USwGMEGNvbnRleHRfc2V0dGluZ3O
 UXZR1Lg==
 </properties>

<properties node_id="3"
 format="pickle">gASV5QwAAAAAAAAAB9ICiMEmNvbnRyb2xBcmVhVmlzaWJsZ
 ZSIjAxyZWNIbnRfcGF0aHOUXZQojB5v
 cmFuZ2V3aWRnZXQudXRpbHMuZmlsZWVpYXVzOUjApSZWNlbnRQYXR
 olJOUKYGUfZQojAdhYnNw
 YXRollxMQzovVXNlcnMvYWxsYW4vT25IRHJpdmUvw4FyZWEgZGUgVHJhY
 mFsaG8vdHJhYmFsaG9f

amFpbmEvdGVzdGVfY2lyY3VsYXlueGxzeJSMBnByZWZpeJSMB2Jhc2VkaXK
 UjAdyZWxwYXRollwT
 dGVzdGVfY2lyY3VsYXlueGxzeJSMBXRpdGxllwAllwFc2hlZXSUaBCMC2Zpb
 GVfZm9ybWF0IE51
 YmgGKYGUfZQoaAmMTUM6L1VzZXJzL2FsbGFuL09uZURyaXZIL8OBcmVhI
 GRlIFRyYWJhbGhvL3Ry
 YWJhbGhvX2phaW5hL3RyZWlub19jaXJjdWxhci54bHN4IGgLaAxoDYwUdHJla
 W5vX2NpcmN1bGFy
 Lnhsc3iUaA9oEGgRaBBoEk51YmgGKYGUfZQoaAmMO0M6L1VzZXJzL2Fsb
 GFuL09uZURyaXZIL8OB
 cmVhIGRlIFRyYWJhbGhvL2JhbmNvX2xhdXJhMi54bHN4IGgL TmgNTmgPaBB
 oEWgQaBJOdWJoBimB
 IH2UKGgJjDpDOi9Vc2Vycy9hbGxhbi9PbmVEcmI2ZS/DgXJIYSBkZSBUcmFiY
 Wxoby9iYW5jb19s
 YXVyYS54bHN4IGgL TmgNTmgPaBB oEWgQaBJOdWJoBimBIH2UKGgJjGdD
 Oi9Vc2Vycy9hbGxhbi9t
 aW5pY29uZGEzL3BrZ3Mvb3JhbmdlMy0zLjMxLjEtcHkzOGg1ZDkyOGUyXzAv
 TGliL3NpdGUtcGFj
 a2FnZXMvT3JhbmdlL2RhdGFzZXRzL2lyaXMudGFilGgL TmgNTmgPaBB oEWg
 QaBJOdWJoBimBIH2U
 KGgJjDVDOi9Vc2Vycy9hbGxhbi9PbmVEcmI2ZS/DgXJIYSBkZSBUcmFiYWxob
 y9QYXN0YTMueGxz
 eJR0C05oDU5oD2gQaBFoEGgSTnViaAYpgZR9lChoCYxqQzovVXNlcnMvYW
 xsYW4vbWluaWNvbMh
 My9wa2dzL29yYW5nZTMtMy4zMS4xLXB5MzhoNWQ5MjhIMl8wL0xpYi9zaXRI
 LXBhY2thZ2VzL09y
 YW5nZS9kYXRhc2V0cy90aXRhbmljLnRhYpRoC05oDU5oD2gQaBFoEGgSTn
 ViaAYpgZR9lChoCYxD
 QzovVXNlcnMvYWxsYW4vT25IRHJpdmUvw4FyZWEgZGUgVHJhYmFsaG8vd
 HJhYmFsaG9fY2Fpby9Q
 YXN0YTEueGxzeJR0C05oDU5oD2gQaBFoEGgSTnViaAYpgZR9lChoCYw9Qz
 ovVXNlcnMvYWxsYW4v
 T25IRHJpdmUvw4FyZWEgZGUgVHJhYmFsaG8vUGFzdGExIC0gQ29waWEu
 eGxzeJR0C05oDU5oD2gQ
 aBFoEGgSTnViaAYpgZR9lChoCYw1QzovVXNlcnMvYWxsYW4vT25IRHJpdm
 Uvw4FyZWEgZGUgVHJh
 YmFsaG8vUGFzdGExLnhs3iUaAtOaA1OaA9oEGgRaBBoEk51YmgGKYGUf
 ZQoaAmMW0M6L1VzZXJz
 L2FsbGFuL09uZURyaXZIL8OBcmVhIGRlIFRyYWJhbGhvL2V4ZW1wbG9fMjU
 wMzlwMjlvZ3JpZF9q
 dXJhX2FsbGFuX2V4Y2VsX3RvdGFsLnhs3iUaAtOaA1OaA9oEGgRaBBoEk5
 1YmgGKYGUfZQoaAmM
 VUM6L1VzZXJzL2FsbGFuL09uZURyaXZIL8OBcmVhIGRlIFRyYWJhbGhvL2V
 4ZW1wbG9fMjUwMzlw
 MjlvZ3JpZF9qdXJhX2FsbGFuX2V4Y2VsLnhs3iUaAtOaA1OaA9oEGgRaBBo
 Ek51YmgGKYGUfZQo
 aAmMPUM6L1VzZXJzL2FsbGFuL09uZURyaXZIL8OBcmVhIGRlIFRyYWJhbG
 hvL2Jsb2Nvc19qdXJh
 X25uLnhs3iUaAtOaA1OaA9oEGgRaBBoEk51YmgGKYGUfZQoaAmMV0M6L
 1VzZXJzL2FsbGFuL0Fw

cERhdGEvTG9jYWwvUHJvZ3JhbXMvT3JhbmdlL0xpYi9zaXRILXBhY2thZ2VzL
 09yYW5nZS9kYXRh
 c2V0cy9pcmlzLnRhYpRoC4wPc2FtcGxILWRhdGFzZXRzIGgNjAhpcmlzLnRhY
 pRoD2gQaBFoEGgS
 TnViaAYpgZR9lChoCYxaQzovVXNlcnMvYWxsYW4vQXBwRGF0YS9Mb2Nhb
 C9Qcm9ncmFtcy9PcmFu
 Z2UvTGliL3NpdGUtcGFja2FnZXMvT3JhbmdlL2RhdGFzZXRzL3RpdGFuaWM
 udGFilGgLaDtdYwL
 dGI0YW5pYy50YWKUaA9oEGgRaBBoEk51YmgGKYGUfZQoaAmMWkM6L1V
 zZXJzL2FsbGFuL0FwcERh
 dGEvTG9jYWwvUHJvZ3JhbXMvT3JhbmdlL0xpYi9zaXRILXBhY2thZ2VzL09yY
 W5nZS9kYXRhc2V0
 cy9ob3VzaW5nLnRhYpRoC2g7aA2MC2hvdXNpbmcudGFilGgPaBBoEWgQaB
 JOdWJoBimBIH2UKGgJ
 jGBDOi9Vc2Vycy9hbGxhbi9BcHBEYXRhL0xvY2FsL1Byb2dyYW1zL09yYW5n
 ZS9MaWlvc2l0ZS1w
 YWNrYWdlcy9PcmFuZ2UvZGF0YXNldHMvaGVhcnRfZGlzZWZzZS50YWKUa
 AtoO2gNjBFoZWFydF9k
 aXNIYXNlLnRhYpRoD2gQaBFoEGgSTnViaAYpgZR9lChoCYxhQzovVXNlcnM
 vYWxsYW4vQXBwRGF0
 YS9Mb2NhbC9Qcm9ncmFtcy9PcmFuZ2UvTGliL3NpdGUtcGFja2FnZXMvT3Jh
 bmdlL2RhdGFzZXRz
 L2Jyb3duLXNlbGVjdGVkLnRhYpRoC2g7aA2MEmJyb3duLXNlbGVjdGVkLnRh
 YpRoD2gQaBFoEGgS
 TnViaAYpgZR9lChoCYxWQzovVXNlcnMvYWxsYW4vQXBwRGF0YS9Mb2Nhb
 C9Qcm9ncmFtcy9PcmFu
 Z2UvTGliL3NpdGUtcGFja2FnZXMvT3JhbmdlL2RhdGFzZXRzL3pvby50YWKU
 aAtoO2gNjAd6b28u
 dGFilGgPaBBoEWgQaBJOdWJlJAtyZWNIbnRfdXJsc5RdlwTc2F2ZWRXaWRn
 ZXRHZW9tZXRYeZRD
 QgHZ0MsAAwAAAAACuwAAAQgAAAW+AAAD1wAAARsAAAEIAAAAFvgAAA9c
 AAAAAAAAAAAeAAAAACuwAA
 AQgAAAW+AAAD15SMC3NoZWV0X25hbWVzIH2UjAZzb3VyY2WUSwCMA3V
 ybJRoElwNZG9tYWluX2Vk
 aXRvcvR9llwLX192ZXJzaW9uX1+USwGMEGNvbnRleHRfc2V0dGluZ3OUXZQ
 ojBVvcmFuZ2V3aWRn
 ZXQuc2V0dGluZ3OUjAdDb250ZXh0lJOUKYGUfZQojAZ2YWx1ZXOUfZQojAl2
 YXJpYWJsZXOUXZR0
 WX2UaGVdlChdlCiMAklklwUT3JhbmdlLmRhdGEudmFyaWFibGwUjBJDb250
 aW51b3VzVmFyaWFi
 bGWUk5RLA2gQiGVdlCiMAVCUaG1LAGgQiGVdlCiMAUOUaG1LAGgQiGVdl
 CiMAkFBIGhtSwBoElhl
 XZQojAJBVJRobUsAaBCIZV2UKlwCSFSUaG1LAGgQiGVdlCiMAVKUaG1LA
 GgQiGVdlCiMAUaUaG1L
 AWgQiGVlc2hbSwF1jAphdHRyaWJ1dGVzlc2h0lCiMAklklEsChpRob0sChpRocUsCh
 pSMAkFBIEsChpSM
 AkFUIEsChpSMAkhUIEsChpRoeUsChpRoe0sChpR0llwFbWV0YXOUKYwKY2
 xhc3NfdmFyc5QpJBjt
 b2RpZmllZF92YXJpYWJsZXOUXZR1YmhgKYGUfZQoaGN9lChoZV2UaFI9lGh
 IXZQoXZQoaG9obUsA

aBCIZV2UKGhxaG1LAGgQiGVdlCiMAkFBIghtSwBoElhlXZQojAJBVJRobUsA
aBCIZV2UKlwCSFSU
aG1LAGgQiGVdlChoeWhtSwBoElhlXZQoaHtobUsBaBCIZV2UKlwBU5Roa4w
QRGlzY3JldGVWYXJp
YWJsZZSTIEsDjA5GYWlsZWQsIFN0YWJsZZSJZV2UKlwCSWSUaGuMDIN0c
mluZ1ZhcmllhYmxllJOU
SwNoEIIIzXNoW0sBdWh8KGhvSwKGIGhxSwKGllwCQUGUSwKGllwCQVSUS
wKGllwCSFSUSwKGIGh5
SwKGIGh7SwKGIGifXZQojAZGYWlsZWSUjAZTdGFibGWUZYaUdJRoiowCSW
SUSwOGllWUalspalxd
IHViZXUu
</properties>

<properties node_id="4"
format="pickle">gASVNQMMAAAAAAAB9ICiMC2F1dG9fY29tbWI0lliMC2F1dG9f
c2FtcGxllliMEmNvbnRyb2xBcmVh
VmlzaWJsZZSljBNzYXZIZFdpZGdlEdlb21ldHJ5IENCAdnQywADAAAAAABO
AAAAHQAAB38AAAQ3
AAAATgAAAB0AAAd/AAAENwAAAAACAAAAB4AAAABOAAAAHQAAB38AAA
Q3llwJc2VsZWNoaW9uIE6M
EXRvb2x0aXBfc2hvd3NfYWxslllMD3Zpc3VhbF9zZXROaW5nc5R9llwFZ3JhcGi
UfZQojAthbHBo
YV92YWx1ZZRLglwNY2xhc3NfZGVuc2l0eZSJjBFqaXR0ZXJfY29udGludW91c
5SJjAtqaXR0ZXJf
c2l6ZZRLAlwTbGFIZWxib25seV9zZWxlY3RlZJSJjBZvcnRob25vcmlhbF9yZW
dyZXNzaW9uUllmM
C3BvaW50X3dpZHRoIEsKjAlzaG93X2dyaWSUiYwLc2hvd19sZWdlbmSUilwNc
2hvd19yZWdfbGlu
ZZSldYwLX192ZXJzaW9uX1+USwWMEGNvbnRleHRfc2V0dGluZ3OUXZQojB
VvcmlFuZ2V3aWRnZXQu
c2V0dGluZ3OUjAdDb250ZXh0lJOUKYGUfZQojAZ2YWx1ZXOUfZQojAphdHRy
X2NvbG9yIE5K/v//
/4aUjAphdHRyX2xhYmVslE5K/v///4aUjAphdHRyX3NoYXBllE5K/v///4aUjAlhdH
RyX3NpemWU
Tkr+////hpSMBmF0dHJfeJSMDVJhbmRvbSBGb3Jlc3US2aGllwGYXR0cl95llw
BRpRLZoaUaAp9
IGgWSwV1jAphdHRyaWJ1dGVzIH2UKlwBUJRLAowBQ5RLAowCQUGUSwK
MAkFUIEsCjAJIVJRLAowB
UpRLAmgsSwJ1jAVtZXRhc5R9lGgpSwJzdWJoGymBIH2UKGgefZQoaCBOSv
7///+GIGgiTkr+////
hpRoJE5K/v///4aUaCZOSv7///+GIGgoaCILZoaUaCtoMktmhpRoCn2UaBZLBXV
oL32UKGgxSwJo
MksCaDNLAmg0SwJoNUsCaDZLAnVoN32UaCILAnN1YmV1Lg==
</properties>

<properties node_id="5"
format="pickle">gASVOQMMAAAAAAAB9ICiMFGNvbXBhcmlzb25fY3JpdGVyaW
9uIEsAjBJjb250cm9sQXJlYVZpc2li
bGWUilwNY3Zfc3RyYXRpZmllZJSJjAduX2ZvbGRzIEsDjAluX3JlcGVhdHOUSw
OMCnJlc2FtcGxp
bmeUSwSMBHJvcGWURz+5mZmZmZmajAtzYW1wbGVfc2l6ZZRLC4wTc2F2
ZWRXaWRnZXRHZW9tZXRY
</properties>

eZRDQgHZ0MsAAwAAAAAB0AAAAS0AAATbAAADQQAAAdAAAAEtAAAE2w
 AAA0EAAAAAAAAAAAAAeAAAAAB
 0AAAAS0AAATbAAADQZSMEnNodWZmbGVfc3RyYXRpZmllZJSIjAh1c2Vfcm
 9wZZSJjAtzY29yZV90
 YWJsZZR9llwMc2hvd25fc2NvcmlVzII+UKIwDTUFFIlwJUHJIY2IzaW9uIlwCQ0G
 UjAJGMZSMA0FV
 Q5SMBFJNU0WUjANNU0WUjAJSMpSMBIJIY2FsbJSQc4wLX192ZXJzaW9uX
 1+USwOMEGNvbnRleHRf
 c2V0dGluZ3OUXZQojBVvcmFuZ2V3aWRnZXQuc2V0dGluZ3OUjAdDb250ZXh
 0IJOUKYGUfZQojAZ2
 YWx1ZXOUfZQojA9jbGFzc19zZWxlY3Rpb26UjBYoQXZlcmFnZSBvdmVylGNs
 YXNzZXMplEr////
 hpSMDGZvbGRfZmVhdHVyZZROSv7///+GllwVZm9sZF9mZWFOdXJIX3NlbGVj
 dGVklIIK/v///4aU
 aA19IGgaSwN1jAphdHRyaWJ1dGVzICiMAVCUSwKGllwBQ5RLAoaUjAJBQZ
 RLAAoaUjAJBVJRLAAoaU
 jAJIVJRLAAoaUjAFSIEsChpR0llwFbWV0YXOUKYwKY2xhc3NfdmFyc5SMAUa
 USwKGllWUdWJoHymB
 IH2UKGgifZQoaCSMFihBdmVYwDlIG92ZXIlgY2xhc3NlcymUSv////+GIggnTkr+
 ////hpRoKYIK
 /v///4aUaA19IGgaSwN1aCwoaC1LAoaUaC9LAoaUaDFLAoaUaDNLAAoaUaDVL
 AoaUaDdLAoaUdJRo
 OowNUMFuZG9tIEZvcmlVzdJRLAAoaUhZRoO2g8SwKGllWUdWJldS4=
 </properties>

<properties node_id="6"
 format="pickle">gASVAAIAAAAAAAB9ICiMEmNvbnRyb2xBcmVhVmlzaWJsZZ
 SljBNzYXZlZFdpZGdldEdlb21ldHJ5
 IENCAdnQywADAAAAAALiAAABlgAABOsAAAMVAAAC4gAAASIAAATrAAAD
 FQAAAAAAAAAAB4AAAAALi
 AAABlgAABOsAAAMVllwLX192ZXJzaW9uX1+USwKMEGNvbnRleHRfc2V0dG
 luZ3OUXZSMFW9yYW5n
 ZXdpZGdldC5zZXRoZW5nc5SMB0NvbnRleHSUk5QpgZR9ICiMBnZhbHVlc5R
 9ICiMDGN1cnJlbnRJ
 bmRleJRLAUr+////hpSMC2Rlc2NyaXB0b3JzIF2UKIwoT3JhbmdlLndpZGdldHM
 uZGF0YS5vd2ZI
 YXR1cmVjb25zdHJ1Y3RvcnRpbmVvdXNEZXNjcmlwdG9yIJOUjAR
 FcnJvllwPRi1SYW5k
 b21fRm9yZXN0IE6HIIGUaBSMAIlgxllwPRi1SYW5kb21fRm9yZXN0IE6HIIGUZY
 wXZXhwcmVzc2lv
 bnNfd2l0aF92YWx1ZXOUiUr+////hpRoBEsCdYwKYXR0cmllidXRlc5R9ICiMAVC
 USwKMAUOUSwKM
 AkFBIEsCjAJBVJRLAowCSFSUSwKMAVKUSwKMAUaUSwJ1jAVtZXRhc5R9II
 wNUMFuZG9tIEZvcmlVz
 dJRLAN1YmF1Lg==
 </properties>

<properties node_id="7"
 format="pickle">gASVjQIAAAAAAAB9ICiMCmF1dG9fYXBwbHmUilwSY29udHJ
 vbEFyZWFWaXNpYmxlllMEGN1bXVs
 YXRpdmVfZGlzdHKUiywTZml0dGVkX2Rpc3RyaWJ1dGlvpbRLAlwJaGlkZV9iY
 XJzllmMDWtkZV9z

bW9vdGhpbmeUSwqME3NhdmVkV2lkZ2V0R2VvbWV0cnmUQ0IB2dDLAAMA
 AAAAAE4AAAAAdAAAHfwAA
 BDcAAABOAAAAHQAAAB38AAQA3AAAAAIAAAAHgAAAAE4AAAAAdAAAHfw
 AABDeUjApzaG93X3Byb2Jz
 lImMDHNvcnRfYnlfZnJlcZSJjA9zdGFja2VkX2NvbHVtbnOUiYwLX192ZXJzaW9uX1+USwGMEGNv
 bnRleHRfc2V0dGluZ3OUXZQojBVvcmFuZ2V3aWRnZXQuc2V0dGluZ3OUjAdDb250ZXh0JOUKYGU
 fZQojAZ2YWx1ZXOUfZQojARjdmFyle5K/v///4aUjA5udW1iZXJfb2ZfYmluc5RLBER+////hpSM
 CXNlbGVjdGlvpbSPlEr+////hpSMA3ZhcpSMAIgxIEtmhpRoDEsBdYwKYXR0cmli dXRlc5R9lCiM
 AVCUSwKMAUOUSwKMAkFBIEsCjAJBVJRLAowCSFSUSwKMAVKUSwKMB EVycm+USwJoHksCjAFGIEsC
 dYwFbWV0YXOUfZSMDVJhbmRvbSBGb3Jlc3USwJzdWJoESmBIH2UKGgU fZQoaBZOSv7///+GIGgY
 SwRK/v///4aUaBqPIEr+////hpRoHWgoS2aGIGgMSwF1aCB9lCholksCaCNLAow CQUGUSwKMAkFU
 IEsCjAJIVJRLAmgnSwJoKEsCaCILAnVoKn2UaCxLAnN1YmV1Lg==
 </properties>

<properties node_id="8"
 format="pickle">gASVVgMAAAAAAAB9lCiMC2F1dG9fY29tbWI0lIiMC2F1dG9fc 2FtcGxlllIEMemNvbnRyb2xBcmVh
 VmlzaWJsZSjBNzYXZlZdpZGdlEdlb21ldHJ5IENCAdnQywADAAAAAABO AAAAAHQAAAB38AAQA3
 AAAATgAAAB0AAAd/AAAENwAAAAACAAAAB4AAAABOAAAAHQAAAB38AAA Q3llwJc2VsZWN0aW9uIE6M
 EXRvb2x0aXBfc2hvd3NfYWxslllMD3Zpc3VhbF9zZXR0aW5nc5R9llwFZ3JhcGi UfZQojAthbHBo
 YV92YWx1ZZRLglwNY2xhc3NfZGVuc2l0eZSJjBFqaXR0ZXJfY29udGludW91c 5SJjAtqaXR0ZXJf
 c2l6ZZRLAlwTbGFIZWxfb25seV9zZWxlY3RlZSjBZvcnRob25vcm1hbF9yZW dyZXNzaW9uIlmM
 C3BvaW50X3dpZHRoIEsKjAlzaG93X2dyaWSUiYwLc2hvd19sZWdlbmSUilwNc 2hvd19yZWdfbGlu
 ZZSJdYwLX192ZXJzaW9uX1+USwWMEGNvbnRleHRfc2V0dGluZ3OUXZQojB VvcmFuZ2V3aWRnZXQu
 c2V0dGluZ3OUjAdDb250ZXh0JOUKYGUfZQojAZ2YWx1ZXOUfZQojAphdHRy X2NvbG9yle5K/v//
 /4aUjAphdHRyX2xhYmVslE5K/v///4aUjAphdHRyX3NoYXBllE5K/v///4aUjAlhdH RyX3NpemWU
 Tkr+////hpSMBmF0dHJfeJSMAUaUS2aGllwGYXR0cl95llwERXJyb5RLZoaUaA p9lGgWSwV1jAph
 dHRyaWJ1dGVzIH2UKlwbUJRLAowBQ5RLAowCQUGUSwKMAkFUIEsCjAJIV JRLAowBUpRLAmgsSwKM
 AlgxlEsCaCILAnWMBW1ldGFzIH2UjA1SYW5kb20gRm9yZXN0IEsCc3ViaBspg ZR9lChoHn2UKGgg
 Tkr+////hpRolK5K/v///4aUaCROSv7///+GIGgmTkr+////hpRoKGgpS2aGIGgraCxL ZoaUaAp9

```

IGgWSwV1aC99lChoMUsCaDJLAowCQUGUSwKMAkFUIEsCjAJIVJRLAmg2S
wJoLEsCaCILAnVoOH2U
aDpLAnN1YmV1Lg==
</properties>
  </node_properties>
  <session_state>
    <window_groups />
  </session_state>
</scheme>

```

Script modelo de classificação:

```

<?xml version='1.0' encoding='utf-8'?>
<scheme version="2.0" title="" description="">
  <nodes>
    <node id="0" name="File"
qualified_name="Orange.widgets.data.owfile.OWFile" project_name="Orange3"
version="" title="File" position="(301.0, 273.0)" />
    <node id="1" name="Random Forest"
qualified_name="Orange.widgets.model.owrandomforest.OWRandomForest"
project_name="Orange3" version="" title="Random Forest" position="(534.0,
213.0)" />
    <node id="2" name="Predictions"
qualified_name="Orange.widgets.evaluate.owpredictions.OWPredictions"
project_name="Orange3" version="" title="Predictions" position="(739.0, 280.0)"
/>
    <node id="3" name="File"
qualified_name="Orange.widgets.data.owfile.OWFile" project_name="Orange3"
version="" title="File (1)" position="(573.0, 778.0)" />
    <node id="4" name="Test and Score"
qualified_name="Orange.widgets.evaluate.owtestandscore.OWTestAndScore"
project_name="Orange3" version="" title="Test and Score" position="(653.0,
59.0)" />
    <node id="5" name="Confusion Matrix"
qualified_name="Orange.widgets.evaluate.owconfusionmatrix.OWConfusionMa
trix" project_name="Orange3" version="" title="Confusion Matrix"
position="(887.0, 280.0)" />
    <node id="6" name="Scatter Plot"
qualified_name="Orange.widgets.visualize.owscatterplot.OWScatterPlot"
project_name="Orange3" version="" title="Scatter Plot" position="(845.0, 46.0)"
/>
    <node id="7" name="File"
qualified_name="Orange.widgets.data.owfile.OWFile" project_name="Orange3"
version="" title="File (2)" position="(360.0, 694.0)" />
  </nodes>
</scheme>

```

```

        <node id="8" name="Random Forest"
qualified_name="Orange.widgets.model.owrandomforest.OWRandomForest"
project_name="Orange3" version="" title="Random Forest (1)" position="(593.0,
634.0)" />
        <node id="9" name="Predictions"
qualified_name="Orange.widgets.evaluate.owpredictions.OWPredictions"
project_name="Orange3" version="" title="Predictions (1)" position="(798.0,
701.0)" />
        <node id="10" name="Test and Score"
qualified_name="Orange.widgets.evaluate.owtestandscore.OWTestAndScore"
project_name="Orange3" version="" title="Test and Score (1)" position="(712.0,
480.0)" />
        <node id="11" name="Scatter Plot"
qualified_name="Orange.widgets.visualize.owscatterplot.OWScatterPlot"
project_name="Orange3" version="" title="Scatter Plot (1)" position="(904.0,
467.0)" />
        <node id="12" name="Scatter Plot"
qualified_name="Orange.widgets.visualize.owscatterplot.OWScatterPlot"
project_name="Orange3" version="" title="Scatter Plot (2)" position="(925.0,
655.0)" />
    </nodes>
    <links>
        <link id="0" source_node_id="1" sink_node_id="2"
source_channel="Model" sink_channel="Predictors" enabled="true" />
        <link id="1" source_node_id="1" sink_node_id="4"
source_channel="Learner" sink_channel="Learner" enabled="true" />
        <link id="2" source_node_id="0" sink_node_id="4"
source_channel="Data" sink_channel="Data" enabled="true" />
        <link id="3" source_node_id="2" sink_node_id="5"
source_channel="Evaluation Results" sink_channel="Evaluation Results"
enabled="true" />
        <link id="4" source_node_id="4" sink_node_id="6"
source_channel="Predictions" sink_channel="Data" enabled="true" />
        <link id="5" source_node_id="0" sink_node_id="1"
source_channel="Data" sink_channel="Data" enabled="true" />
        <link id="6" source_node_id="0" sink_node_id="2"
source_channel="Data" sink_channel="Data" enabled="true" />
        <link id="7" source_node_id="8" sink_node_id="9"
source_channel="Model" sink_channel="Predictors" enabled="true" />
        <link id="8" source_node_id="8" sink_node_id="10"
source_channel="Learner" sink_channel="Learner" enabled="true" />
        <link id="9" source_node_id="7" sink_node_id="10"
source_channel="Data" sink_channel="Data" enabled="true" />
        <link id="10" source_node_id="10" sink_node_id="11"
source_channel="Predictions" sink_channel="Data" enabled="true" />
        <link id="11" source_node_id="7" sink_node_id="8"
source_channel="Data" sink_channel="Data" enabled="true" />
        <link id="12" source_node_id="3" sink_node_id="9"
source_channel="Data" sink_channel="Data" enabled="true" />

```

```

        <link id="13" source_node_id="9" sink_node_id="12"
source_channel="Predictions" sink_channel="Data" enabled="true" />
    </links>
    <annotations />
    <thumbnail />
    <node_properties>
        <properties node_id="0"
format="pickle">gASVgAsAAAAAAB9lCiMEmNvbnRyb2xBcmVhVmlzaWJsZZ
SljAxyZWNIbnRfcGF0aHOXZQojB5v
cmFuZ2V3aWRnZXQudXRpbHMuZmlsZWRpYWxvZ3OUjApSZWNlbnRQYXR
olJOUKYGUfZQojAdhYnNw
YXRollxNQzovVXNlcnMvYWxsYW4vT25lRHJpdmUvw4FyZWEgZGUgVHJhY
mFsaG8vdHJhYmFsaG9f
amFpbmEvdHJlaW5vX2NpcmN1bGFyLnhsc3iUjAZwcmVmaXiUjAdiYXNIZGlyll
wHcmVscGF0aJSM
FHRyZWlub19jaXJjdWxhci54bHN4IlwFdGI0bGWUjACUjAVzaGVldJR0ElwLZm
lsZV9mb3JtYXSU
TnViaAYpgZR9lChoCYw7QzovVXNlcnMvYWxsYW4vT25lRHJpdmUvw4FyZW
EgZGUgVHJhYmFsaG8v
YmFuY29fbGF1cmEyLnhsc3iUaAtOaA1OaA9oEGgRaBBoEk51YmgGKYGUfZ
QoaAmMOKM6L1VzZXJz
L2FsbGFuL09uZURyaXZIL8OBcmVhIGRIIFRyYWJhbGhvL2JhbmNvX2xhdXJh
Lnhsc3iUaAtOaA1O
aA9oEGgRaBBoEk51YmgGKYGUfZQoaAmMZ0M6L1VzZXJzL2FsbGFuL21pb
mljb25kYTMvcGtnCy9v
cmFuZ2UzLTmuMzEuMS1weTM4aDVkOTI4ZTJfMC9MaWlvc2l0ZS1wYWNRy
Wdlcy9PcmFuZ2UvZGF0
YXNldHMvaXJpcy50YWKUaAtOaA1OaA9oEGgRaBBoEk51YmgGKYGUfZQoa
AmMNUM6L1VzZXJzL2Fs
bGFuL09uZURyaXZIL8OBcmVhIGRIIFRyYWJhbGhvL1Bhc3RhMy54bHN4IGg
L
TmgNTmgPaBBoEWgQ
aBJOdWJoBimBIH2UKGgJjGpDOi9Vc2Vycy9hbGxhbi9taW5pY29uZGEzL3BrZ
3Mvb3JhbmdlMy0z
LjMxLjEtcHkzOGg1ZDkyOGUyXzAvTGliL3NpdGUtcGFja2FnZXMvT3JhbmdlL2
RhdGFzZXRzL3Rp
dGFuaWMudGFilGgLTmgNTmgPaBBoEWgQaBJOdWJoBimBIH2UKGgJjEND
Oi9Vc2Vycy9hbGxhbi9P
bmVEcmI2ZS/DgXJIYSBkZSBUcmFiYWxoby90cmFiYWxob19jYWlvL1Bhc3Rh
MS54bHN4IGgLTmgN
TmgPaBBoEWgQaBJOdWJoBimBIH2UKGgJjD1DOi9Vc2Vycy9hbGxhbi9Pbm
VEcmI2ZS/DgXJIYSBk
ZSBUcmFiYWxoby9QYXN0YTEgLSBDb3BpYS54bHN4IGgLTmgNTmgPaBBo
EWgQaBJOdWJoBimBIH2U
KGgJjDVDOi9Vc2Vycy9hbGxhbi9PbmVEcmI2ZS/DgXJIYSBkZSBUcmFiYWxob
y9QYXN0YTEueGxz
eJR0C05oDU5oD2gQaBFoEGgSTnViaAYpgZR9lChoCYxbQzovVXNlcnMvYW
xsYW4vT25lRHJpdmUv
w4FyZWEgZGUgVHJhYmFsaG8vZXhlcXBsb18yNTAzMjAyMi9ncmlkX2p1cmFf
YWxsYW5fZXhjZWxf

```

dG90YWwueGxzeJR0C05oDU5oD2gQaBFoEGgSTnViaAYpgZR9lChoCYxVQ
 zovVXNlcnMvYWxsYW4v
 T25lRHJpdmUvw4FyZWEgZGUgVHJhYmFsaG8vZXhpbXBsb18yNTAzMjAyMi9
 ncmkX2p1cmFfYWxs
 YW5fZXhjZWwueGxzeJR0C05oDU5oD2gQaBFoEGgSTnViaAYpgZR9lChoCY
 w9QzovVXNlcnMvYWxs
 YW4vT25lRHJpdmUvw4FyZWEgZGUgVHJhYmFsaG8vYmxvY29zX2p1cmFfb
 m4ueGxzeJR0C05oDU5o
 D2gQaBFoEGgSTnViaAYpgZR9lChoCYxXQzovVXNlcnMvYWxsYW4vQXBwR
 GF0YS9Mb2NhbC9Qcm9n
 cmFtcy9PcmFuZ2UvTGliL3NpdGUtcGFja2FnZXMvT3JhbmdlL2RhdGFzZXRzL
 2lyaXMudGFilGgL
 jA9zYW1wbGUtZGF0YXNldHOUaA2MCGIyaXMudGFilGgPaBBoEWgQaBJOd
 WJoBimBIH2UKGgJjFpD
 Oi9Vc2Vycy9hbGxhbi9BcHBEYXRhL0xvY2FsL1Byb2dyYW1zL09yYW5nZS9M
 aWlvc2l0ZS1wYWNR
 YWdlcy9PcmFuZ2UvZGF0YXNldHMvdGI0YW5pYy50YWKUaAtoN2gNjAt0aXR
 hbmljLnRhYpRoD2gQ
 aBFoEGgSTnViaAYpgZR9lChoCYxaQzovVXNlcnMvYWxsYW4vQXBwRGF0Y
 S9Mb2NhbC9Qcm9ncmFt
 cy9PcmFuZ2UvTGliL3NpdGUtcGFja2FnZXMvT3JhbmdlL2RhdGFzZXRzL2hvd
 XNpbmcudGFilGgL
 aDdoDYwLaG91c2luZy50YWKUaA9oEGgRaBBoEk51YmgGKYGUfZQoaAmM
 YEM6L1VzZXJzL2FsbGFu
 L0FwcERhdGEvTG9jYWwvUHJvZ3JhbXMvT3JhbmdlL0xpYi9zaXRILXBhY2thZ
 2VzL09yYW5nZS9k
 YXRhc2V0cy9oZWYydF9kaXNIYXNlLnRhYpRoC2g3aA2MEWhlYXJ0X2Rpc2V
 hc2UudGFilGgPaBBo
 EWgQaBJOdWJoBimBIH2UKGgJjGFDOi9Vc2Vycy9hbGxhbi9BcHBEYXRhL0x
 vY2FsL1Byb2dyYW1z
 L09yYW5nZS9MaWlvc2l0ZS1wYWNRYWdlcy9PcmFuZ2UvZGF0YXNldHMvYn
 Jvd24tc2VsZWNOZWQu
 dGFilGgLaDdoDYwSYnJvd24tc2VsZWNOZWQuudGFilGgPaBBoEWgQaBJOdW
 JoBimBIH2UKGgJjFZD
 Oi9Vc2Vycy9hbGxhbi9BcHBEYXRhL0xvY2FsL1Byb2dyYW1zL09yYW5nZS9M
 aWlvc2l0ZS1wYWNR
 YWdlcy9PcmFuZ2UvZGF0YXNldHMvem9vLnRhYpRoC2g3aA2MB3pvby50YW
 KUaA9oEGgRaBBoEk51
 YmWMC3JIY2VudF91cmxzIF2UjBNzYXZIZFdpZGdlEdlb21ldHJ5IENCAdnQy
 wADAAAAAAK6AAAA
 4gAABb8AAAPYAAACuwAAAQgAAAW+AAAD1wAAAAAAAAAAB4AAAAK7A
 AABCAAABb4AAAPXIlwLc2hl
 ZXRfbmFtZXOUfZSMBnNvdXJjZZRLAlwDdXJslGgQjA1kb21haW5fZWRpdG9y
 IH2UjAtfX3ZlcnNp
 b25fX5RLAYwQY29udGV4dF9zZXR0aW5nc5RdlwVb3Jhbmdld2lkZ2V0LnNld
 HRpbmdzllwHQ29u
 dGV4dJSTICmBIH2UKlwGdmFsdWVzIH2UKlwJdmFyaWFibGVzIF2UaFV9IGh
 hXZQoXZQojAFQllwU
 T3JhbmdlLmRhdGEudmFyaWFibGWUjBJDb250aW51b3VzVmFyaWFibGWUk
 5RLAGgQiGVdlCiMAUOU

```

aGILAGgQiGVdlCiMAkFBIGhpSwBoElhIXZQojAJBVJRoaUsAaBCIZV2UKlwCS
FSUaGILAGgQiGVd
ICiMAVKUaGILAGgQiGVdlCiMAUaUaGILA2gQiGVdlCiMAVOUaGeMEERpc2N
yZXRIvmFyaWFibGWU
k5RLAYwORMFpbGVkLCBTdGFibGWUiWVdlCiMAklGhnjA5TdHJpbmdWYX
JpYWJsZZSTIEsDaBCJ
ZWVzaFdLAXWMCmF0dHJpYnV0ZXOUKGhmSwKGIGhrSwKGllwCQUGUSw
KGllwCQVSUSwKGllwCSFSU
SwKGIGhzSwKGIGh1SwKGIGh3XZQojAZGYWlsZWSUjAZTdGFibGWUZYaUd
JSMBW1ldGFzllwCSWSU
SwOGIIWUjApjbGFzc192YXJzICmMEm1vZGImaWVhX3ZhcmlhYmxlc5RdlHVl
YXUu

```

```

</properties>

```

```

    <properties node_id="1" format="literal">{'auto_apply': True,
'class_weight': False, 'controlAreaVisible': True, 'index_output': 0,
'learner_name': '', 'max_depth': 3, 'max_features': 5, 'min_samples_split': 5,
'n_estimators': 200, 'savedWidgetGeometry':
b'\x01\xd9\xd0\xcb\x00\x03\x00\x00\x00\x00\x03\x1e\x00\x00\x01j\x00\x00\x04\
xaf\x00\x00\x02\xcd\x00\x00\x03\x1e\x00\x00\x01j\x00\x00\x04\xaf\x00\x00\x02\
\xcd\x00\x00\x00\x00\x00\x00\x00\x00\x07\x80\x00\x00\x03\x1e\x00\x00\x01j\x
00\x00\x04\xaf\x00\x00\x02\xcd', 'use_max_depth': False, 'use_max_features':
True, 'use_min_samples_split': True, 'use_random_state': False, '__version__':
1}</properties>

```

```

    <properties node_id="2"
format="pickle">gASVCgEAAAAAAB9ICiMEmNvbnRyb2xBcmVhVmlzaWJsZ
ZSIjBNzYXZIZFdpZGdlEdlb21ldHJ5
IENCAdnQywADAAAAAABOAAAAAHQAAB38AAQ3AAAATgAAAB0AAAd/AA
AENwAAAAACAAAAB4AAAABO
AAAAHQAAB38AAQ3llwJc2VsZWNOaW9uIF2UjAtzY29yZV90YWJsZZR9llw
Mc2hvd25fc2NvcmlvZ
II+UKlwDTUFFIlwCUjKUjANBVUOUjARSTVNFIlwJUHJIY2lzaW9uIlwCRjGUjA
NNU0WUjAJDQZSM
BIJIY2FsbJSQc4wLX192ZXJzaW9uX1+USwGMEGNvbnRleHRfc2V0dGluZ3O
UXZR1Lg==
</properties>

```

```

    <properties node_id="3"
format="pickle">gASV/QwAAAAAAB9ICiMEmNvbnRyb2xBcmVhVmlzaWJsZZ
SIjAxyZWNIbnRfcGF0aHOUXZQojB5v
cmFuZ2V3aWRnZXQudXRpbHMuzmlsZWRpYWxvZ3OUjApSZWNlbnRQYXR
olJOUKYGUfZQojAdhYnNw
YXRollxMQzovVXNlcnMvYWxsYW4vT25IRHJpdmUvw4FyZWEgZGUgVHJhY
mFsaG8vdHJhYmFsaG9f
amFpbmEvdGVzdGVfY2lyY3VsYXlueGxzeJSMBnByZWZpeJSMB2Jhc2VkaXK
UjAdyZWxwYXRollwT
dGVzdGVfY2lyY3VsYXlueGxzeJSMBXRpdGxllwAllwFc2hlZXSUaBCMC2Zpb
GVfZm9ybWF0IE51
YmgGKYGUfZQoaAmMTUM6L1VzZXJzL2FsbGFuL09uZURyaXZIL8OBcmVhI
GRlIFRyYWJhbGhvL3Ry
YWJhbGhvX2phaW5hL3RyZWlub19jaXJjdWxhci54bHN4IGgLaXoDYwUdHJla
W5vX2NpcmlvZGFy

```

Lnhsc3iUaA9oEGgRaBBoEk51YmgGKYGUfZQoaAmMO0M6L1VzZXJzL2Fsb
 GFuL09uZURyaXZIL8OB
 cmVhIGRIIFRyYWJhbGhvL2JhbmdNvX2xhdXJhMi54bHN4IGgL TmgNTmgPaBB
 oEWgQaBJOdWJoBimB
 IH2UKGgJjDpDOi9Vc2Vycy9hbGxhbi9PbmVEcmI2ZS/DgXJIYSBkZSBUcmFiY
 Wxoby9iYW5jb19s
 YXVyYS54bHN4IGgL TmgNTmgPaBB oEWgQaBJOdWJoBimBIH2UKGgJjGdD
 Oi9Vc2Vycy9hbGxhbi9t
 aW5pY29uZGEzL3BrZ3Mvb3JhbmdlMy0zLjMxLjEtcHkzOGg1ZDkyOGUyXzAv
 TGliL3NpdGUtcGFj
 a2FnZXMvT3JhbmdlL2RhdGFzZXRzL2IyaXMudGFilGgL TmgNTmgPaBB oEWg
 QaBJOdWJoBimBIH2U
 KGgJjDpDOi9Vc2Vycy9hbGxhbi9PbmVEcmI2ZS/DgXJIYSBkZSBUcmFiYWxob
 y9QYXN0YTMueGxz
 eJRoC05oDU5oD2gQaBFoEGgSTnViaAYpgZR9lChoCYxqQzovVXNlcnMvYW
 xsYW4vbWluaWNvbmdRh
 My9wa2dzL29yYW5nZTMtMy4zMS4xLXB5MzhoNWQ5MjhlMI8wL0xpYi9zaXRl
 LXBhY2thZ2VzL09y
 YW5nZS9kYXRhc2V0cy90aXRhbmljLnRhYpRoC05oDU5oD2gQaBFoEGgSTn
 ViaAYpgZR9lChoCYxD
 QzovVXNlcnMvYWxsYW4vT25lRHJpdmUvw4FyZWEgZGUgVHJhYmFsaG8vd
 HJhYmFsaG9fY2Fpby9Q
 YXN0YTEueGxeJR0C05oDU5oD2gQaBFoEGgSTnViaAYpgZR9lChoCYw9Qz
 ovVXNlcnMvYWxsYW4v
 T25lRHJpdmUvw4FyZWEgZGUgVHJhYmFsaG8vUGFzdGExlC0gQ29waWEu
 eGxeJR0C05oDU5oD2gQ
 aBFoEGgSTnViaAYpgZR9lChoCYw1QzovVXNlcnMvYWxsYW4vT25lRHJpdm
 Uvw4FyZWEgZGUgVHJh
 YmFsaG8vUGFzdGExLnhsc3iUaAtOaA1OaA9oEGgRaBBoEk51YmgGKYGUf
 ZQoaAmMW0M6L1VzZXJz
 L2FsbGFuL09uZURyaXZIL8OBcmVhIGRIIFRyYWJhbGhvL2V4ZW1wbG9fMjU
 wMzlwMjlvZ3JpZF9q
 dXJhX2FsbGFuX2V4Y2VsX3RvdGFsLnhsc3iUaAtOaA1OaA9oEGgRaBBoEk5
 1YmgGKYGUfZQoaAmM
 VUM6L1VzZXJzL2FsbGFuL09uZURyaXZIL8OBcmVhIGRIIFRyYWJhbGhvL2V
 4ZW1wbG9fMjUwMzlw
 MjlvZ3JpZF9qdXJhX2FsbGFuX2V4Y2VsLnhsc3iUaAtOaA1OaA9oEGgRaBBo
 Ek51YmgGKYGUfZQo
 aAmMPUM6L1VzZXJzL2FsbGFuL09uZURyaXZIL8OBcmVhIGRIIFRyYWJhbG
 hvL2Jsb2Nvc19qdXJh
 X25uLnhsc3iUaAtOaA1OaA9oEGgRaBBoEk51YmgGKYGUfZQoaAmMV0M6L
 1VzZXJzL2FsbGFuL0Fw
 cERhdGEvTG9jYWwvUHJvZ3JhbXMvT3JhbmdlL0xpYi9zaXRILXBhY2thZ2VzL
 09yYW5nZS9kYXRh
 c2V0cy9pcmlzLnRhYpRoC4wPc2FtcGxILWRhdGFzZXRzIGgNjAhpcmlzLnRhY
 pRoD2gQaBFoEGgS
 TnViaAYpgZR9lChoCYxaQzovVXNlcnMvYWxsYW4vQXBwRGF0YS9Mb2Nhb
 C9Qcm9ncmFtcy9PcmFu
 Z2UvTGliL3NpdGUtcGFja2FnZXMvT3JhbmdlL2RhdGFzZXRzL3RpdGFuaWM
 udGFilGgLaDtdDYwL

dGI0YW5pYy50YWKUaA9oEGgRaBBoEk51YmgGKYGUfZQoaAmMWkM6L1V
 zZXJzL2FsbGFuL0FwcERh
 dGEvTG9jYWwvUHJvZ3JhbXMvT3JhbmdlL0xpYi9zaXRILXBhY2thZ2VzL09yY
 W5nZS9kYXRhc2V0
 cy9ob3VzaW5nLnRhYpRoC2g7aA2MC2hvdXNpbmcudGFilGgPaBBoEWgQaB
 JOdWJoBimBIH2UKGgJ
 jGBDOi9Vc2Vycy9hbGxhbi9BcHBEYXRhL0xvY2FsL1Byb2dyYW1zL09yYW5n
 ZS9MaWlvc2l0ZS1w
 YWNrYWdlcy9PcmFuZ2UvZGF0YXNldHMvaGVhcnRfZGlzZWZzZS50YWKUa
 AtoO2gNjBFoZWFydF9k
 aXNIYXNlLnRhYpRoD2gQaBFoEGgSTnViaAYpgZR9lChoCYxhQzovVXNlcnM
 vYWxsYW4vQXBwRGF0
 YS9Mb2NhbC9Qcm9ncmFtcy9PcmFuZ2UvTGliL3NpdGUtcGFja2FnZXMvT3Jh
 bmdlL2RhdGFzZXRz
 L2Jyb3duLXNlbGVjdGVkLnRhYpRoC2g7aA2MEEmJyb3duLXNlbGVjdGVkLnRh
 YpRoD2gQaBFoEGgS
 TnViaAYpgZR9lChoCYxWQzovVXNlcnMvYWxsYW4vQXBwRGF0YS9Mb2Nhb
 C9Qcm9ncmFtcy9PcmFu
 Z2UvTGliL3NpdGUtcGFja2FnZXMvT3JhbmdlL2RhdGFzZXRzL3pvby50YWKU
 aAtoO2gNjAd6b28u
 dGFilGgPaBBoEWgQaBJOdWJlJAtyZWNIbnRfdXJsc5RdlIwTc2F2ZWRXaWRn
 ZXRHZW9tZXRYeZRD
 QgHZ0MsAAwAAAAACuwAAAQgAAAW+AAAD1wAAArsAAAEIAAAAFvgAAA9c
 AAAAAAAAAAAeAAAAACuwAA
 AQgAAAW+AAAD15SMC3NoZWV0X25hbWVzIH2UjAZzb3VyY2WUSwCMA3V
 ybJRoElwNZG9tYWluX2Vk
 aXRvcvR9llwLX192ZXJzaW9uX1+USwGMEGNvbnRleHRfc2V0dGluZ3OUXZQ
 ojBVvcmFuZ2V3aWRn
 ZXQuc2V0dGluZ3OUjAdDb250ZXh0lJOUKYGUfZQojAZ2YWx1ZXOUfZQojAl2
 YXJpYWJsZXOUXZR0
 WX2UaGVdlChdlCiMAklklwUT3JhbmdlLmRhdGEudmFyaWFibGWUjBJDb250
 aW51b3VzVmFyaWFi
 bGWUk5RLA2gQiGVdlCiMAVCUaG1LAGgQiGVdlCiMAUOUaG1LAGgQiGVdl
 CiMAkFBIGhtSwBoElhl
 XZQojAJBVJRobUsAaBCIZV2UKlwCSFSUaG1LAGgQiGVdlCiMAVKUaG1LA
 GgQiGVdlCiMAUaUaG1L
 AmgQiGVlc2hbSwF1jAphdHRyaWJ1dGVzIiMAklklEsChpRob0sChpRocUsCh
 pSMAkFBIEsChpSM
 AkFUIEsChpSMAkhUIEsChpRoeUsChpRoe0sChpR0llwFbWV0YXOUKYwKY2
 xhc3NfdmFyc5QpjBJt
 b2RpZmlZF92YXJpYWJsZXOUXZR1YmhgKYGUfZQoaGN9lCiMCXZhcmllhYm
 xlc5RdlIwNZG9tYWlu
 X2VkaXRvcvR9lGiRXZQoXZQoaG9obUsAaBCIZV2UKGhxaG1LAGgQiGVdlCi
 MAkFBIGhtSwBoElhl
 XZQojAJBVJRobUsAaBCIZV2UKlwCSFSUaG1LAGgQiGVdlChoeWhtSwBoElh
 lXZQoaHtobUsBaBCI
 ZV2UKlwBU5Roa4wQRGlzY3JldGVWYXJpYWJsZZSTIEsDjA5GYWlsZWQsIF
 N0YWJsZZSJZV2UKlwC
 SWSUaGuMDIN0cmIuZ1ZhcmllhYmxlIJOUSwNoEIIIzXNoW0sBdWh8KGhvSwK
 GIGhxSwKGllwCQUGU

SwKGIlwCQVSUSwKGIlwCSFSUSwKGIGh5SwKGIGh7SwKGIGihXZQojAZGY
 WlsZWSUjAZTdGFibGWU
 ZYaUdJRoiowCSWSUSwOGIIWUalspalxdIHViZXUu
 </properties>

<properties node_id="4"
 format="pickle">gASVBwQAAAAAAB9ICiMFGNvbXBhcmlzb25fY3JpdGVyaW
 9ulEsAjBJjb250cm9sQXJlYVZpc2li
 bGWUilwNY3Zfc3RyYXRpZmllZJSIjAduX2ZvbGRzIEsBjAluX3JlcGVhdHOUSw
 OMCnJlc2FtcGxp
 bmeUSwCMBHJvcGWURz+5mZmZmZmajAtzYW1wbGVfc2l6ZZRLC4wTc2F2
 ZWRXaWRnZXRHZW9tZXRY
 eZRDQgHZ0MsAAwAAAAAB0AAAAAS0AAATbAAADQQAAdAAAAEtAAAE2w
 AAA0EAAAAAAAAAAAAAeAAAAAB
 0AAAAAS0AAATbAAADQZSMEnNodWZmbGVfc3RyYXRpZmllZJSIjAh1c2Vfcm
 9wZZSJjAtzY29yZV90
 YWJsZZR9llwMc2hvd25fc2NvcmlvZlI+UKlwDTUFFIlwCUjKUjANBVUOUjARST
 VNFIlwJUHJIY2lz
 aW9ullwCRjGUjANNU0WUjAJDQZSMBIJIY2FsbJSQc4wLX192ZXJzaW9uX1+
 USwOMEGNvbnRleHRf
 c2V0dGluZ3OUXZQojBVvcmFuZ2V3aWRnZXQuc2V0dGluZ3OUjAdDb250ZXh
 0IJOUKYGUfZQojAZ2
 YWx1ZXOUfZQojA9jbGFzc19zZWx1Y3Rpb26UjBYoQXZlcmFnZSBvdmVylGNs
 YXNzZXMplEr////
 hpSMDGZvbGRfZmVhdHVyZZROSv7///+GllwVZm9sZF9mZWFOdXJlX3NlbGVj
 dGVklIIK/v///4aU
 aA19IGgaSwN1jAphdHRyaWJ1dGVzICiMAVCUSwKGIlwBQ5RLAoaUjAJBQZ
 RLAoaUjAJBVJRLAoaU
 jAJIVJRLAoaUjAFSIEsChpR0llwFbWV0YXOUKYwKY2xhc3NfdmFyc5SMAVO
 USwGGIIWUdWJoHymB
 IH2UKGgifZQoaCSMFihBdmVyYWdlIG92ZXIlgY2xhc3NlcymUSv////+GIGgnTkr+
 ////hpRoKYIK
 /v///4aUaA19IGgaSwN1aCwoaC1LAoaUaC9LAoaUjAJBQZRLAoaUjAJBVJRLA
 oaUjAJIVJRLAoaU
 aDdLAoaUdJR0OilO4wBRpRLAoaUhZR1YmgfKYGUfZQoaCJ9ICiMD2NsYX
 NzX3NlbGVjdGlvpSM
 FihBdmVyYWdlIG92ZXIlgY2xhc3NlcymUSv////+GllwMZm9sZF9mZWFOdXJlIE5
 K/v///4aUjBVm
 b2xkX2ZIYXR1cmVfc2VsZWNOZWSUiUr+////hpSMC3Njb3JlX3RhYmxlIH2UaBp
 LA3VoLChoLUsc
 hpRoL0sChpRoSUsChpRoS0sChpRoTUsChpRoN0sChpR0IGg6jA1SYW5kb20
 gRm9yZXN0IEsChpSF
 IGg7aFFLAoaUhZR1YmV1Lg==
 </properties>

<properties node_id="5"
 format="pickle">gASVpQEAAAAAAAAAB9ICiMEfWcGVuZF9wcmVkaWN0aW9u
 c5SljBRhcHBibmRfcHJvYmFiaWxpdlGll
 c5SJjAphdXRvY29tbWl0lIEMfNvbnRyb2xBcmVhVmlzaWJsZZSljBNzYXZlZFd
 pZGdlEdlb21l
 dHJ5IENCAdnQywADAAAAAAAJwAAABcgAABV0AAALFAAACcAAAAAXIAAAVd
 AAACxQAAAAAAAAAAAAAB4AA

AAJwAAABcgAABV0AAALFIwQc2VsZWN0ZWRfbGVhcm5lcpSMB2NvcHlyZ
 WeUjA5fcmVjb25zdHJ1
 Y3RvcpSTllwIYnVpbHRpbmOUjARsaXN0IJOuaA0ph5RSIEsAYYwRc2VsZWN
 0ZWRfcXVhbnRpdHmU
 SwCMC19fdmVyc2lvbl9fEsBjBBjb250ZXh0X3NldHRpbmdzIF2UjBVvcmFuZ2V
 3aWRnZXQuc2V0
 dGluZ3OUjAdDb250ZXh0IJOUKYGUfZQojAZ2YWx1ZXOUfZQojAlzZWxlY3Rp
 b26Uj5RoEUsBdYwH
 Y2xhc3Nlc5SMBkZhaWxlZJSMBIN0YWJsZZSGIHViYXUu
 </properties>

<properties node_id="6"
 format="pickle">gASV+wIAAAAAAAB9ICiMC2F1dG9fY29tbWI0IliMC2F1dG9fc
 2FtcGxllliMEmNvbnRyb2xBcmVh
 VmlzaWJsZZSljBNzYXZIZFdpZGdldEdlb21ldHJ5IENCAdnQywADAAAAAABN//
 //9wAAB4AAAAQ4
 AAAATgAAAB0AAAd/AAAENwAAAAACAAAAB4AAAABOAAAAHQAAAB38AAA
 Q3llwJc2VsZWN0aW9uIE6M
 EXRvb2x0aXBfc2hvd3NfYWxsllliMD3Zpc3VhbF9zZXR0aW5nc5R9llwFZ3JhcGi
 UfZQojAthbHBo
 YV92YWx1ZZRLglwNY2xhc3NfZGVuc2l0eZSJjBFqaXR0ZXJfY29udGludW91c
 5SJjAtqaXR0ZXJf
 c2l6ZZRLAlwTbGFIZWxfb25seV9zZWxlY3RlZJSJjBZvcnRob25vcm1hbF9yZW
 dyZXNzaW9uIImM
 C3BvaW50X3dpZHRoIEsKjAlzaG93X2dyaWSUiYwLc2hvd19sZWdlbmSUilwNc
 2hvd19yZWdfbGlu
 ZZSldYwLX192ZXJzaW9uX1+USwWMEGNvbnRleHRfc2V0dGluZ3OUXZSMF
 W9yYW5nZXdpZGdldC5z
 ZXR0aW5nc5SMB0NvbnRleHSUk5QpgZR9ICiMBnZhbHVlc5R9ICiMCmF0dHJf
 Y29sb3KUjAFTIeti
 hpSMCmF0dHJfbGFIZWYUTkr+////hpSMCmF0dHJfc2hhcGWUTkr+////hpSMCW
 F0dHJfc2l6ZZRO
 Sv7///+GllwGYXR0cl94llwERm9sZJRLZYaUjAZhdHRyX3mUjAFDIEtmhpRoCn
 2UaBZLBXWMCmF0
 dHJpYnV0ZXOUfZQojAFQIEsCaC1LAowCQUGUSwKMAkFUIEsCjAJIVJRLAo
 wBUpRLAmghSwF1jAVt
 ZXRhc5R9ICiMDVJhbmRvbSBGb3Jlc3USwGMFIJhbmRvbSBGb3Jlc3QgKEZ
 haWxlZCmUSwKMFIJh
 bmRvbSBGb3Jlc3QgKFN0YWJsZSmUSwJoKksBdXViYXUu
 </properties>

<properties node_id="7"
 format="pickle">gASVgAsAAAAAAB9ICiMEmNvbnRyb2xBcmVhVmlzaWJsZZ
 SljAxyZWNIbnRfcGF0aHOUXZQojB5v
 cmFuZ2V3aWRnZXQudXRpbHMuzmlsZWRpYWxvZ3OUjApSZWNlbnRQYXR
 olJOUKYGUfZQojAdhYnNw
 YXRollxNQzovVXNlcnMvYWxsYW4vT25IRHJpdMUVw4FyZWEgZGUgVHJhY
 mFsaG8vdHJhYmFsaG9f
 amFpbmEvdHJlaW5vX2NpcmN1bGFyLnhs3iUjAZwcmVmaXiUjAdiYXNIZGlyll
 wHcmVscGF0aJSM
 FHRyZWlub19jaXJjdWxhci54bHN4llwFdGI0bGWUjACUjAVzaGVldJRoeIwLZm
 lsZV9mb3JtYXSU

TnViaAYpgZR9lChoCYw7QzovVXNlcnMvYWxsYW4vT25lRHJpdmUvw4FyZW
 EgZGUgVHJhYmFsaG8v
 YmFuY29fbGF1cmEyLnhsc3iUaAtOaA1OaA9oEGgRaBBoEk51YmgGKYGUfZ
 QoaAmMOkM6L1VzZXJz
 L2FsbGFuL09uZURyaXZIL8OBcmVhIGRIIFRyYWJhbGhvL2JhbmNvX2xhdXJh
 Lnhsc3iUaAtOaA1O
 aA9oEGgRaBBoEk51YmgGKYGUfZQoaAmMZ0M6L1VzZXJzL2FsbGFuL21pb
 mljb25kYTMvcGtnCy9v
 cmFuZ2UzLTmuMzEuMS1weTM4aDVkOTI4ZTJfMC9MaWlvc2l0ZS1wYWNRy
 Wdlcy9PcmFuZ2UvZGF0
 YXNldHMvaXJpcy50YWKUaAtOaA1OaA9oEGgRaBBoEk51YmgGKYGUfZQoa
 AmMNUM6L1VzZXJzL2Fs
 bGFuL09uZURyaXZIL8OBcmVhIGRIIFRyYWJhbGhvL1Bhc3RhMy54bHN4IGgL
 TmgNTmgPaBBoEWgQ
 aBJOdWJoBimBIH2UKGgJjGpDOi9Vc2Vycy9hbGxhbi9taW5pY29uZGEzL3BrZ
 3Mvb3JhbmdlMy0z
 LjMxLjEtcHkzOGg1ZDkyOGUyXzAvTGliL3NpdGUtcGFja2FnZXMvT3JhbmdlL2
 RhdGFzZXRzL3Rp
 dGFuaWMudGFilGgL TmgNTmgPaBBoEWgQaBJOdWJoBimBIH2UKGgJjEND
 Oi9Vc2Vycy9hbGxhbi9P
 bmVEcmI2ZS/DgXJIYSBkZSBUcmFiYWxoby90cmFiYWxob19jYWlvL1Bhc3Rh
 MS54bHN4IGgL TmgN
 TmgPaBBoEWgQaBJOdWJoBimBIH2UKGgJjD1DOi9Vc2Vycy9hbGxhbi9Pbm
 VEcmI2ZS/DgXJIYSBk
 ZSBUcmFiYWxoby9QYXN0YTEgL SBD3BpYS54bHN4IGgL TmgNTmgPaBBo
 EWgQaBJOdWJoBimBIH2U
 KGgJjDVDOi9Vc2Vycy9hbGxhbi9PbmVEcmI2ZS/DgXJIYSBkZSBUcmFiYWxob
 y9QYXN0YTEueGxz
 eJR0C05oDU5oD2gQaBFoEGgSTnViaAYpgZR9lChoCYxbQzovVXNlcnMvYW
 xsYW4vT25lRHJpdmUv
 w4FyZWEgZGUgVHJhYmFsaG8vZXhlcXBsb18yNTAzMjAyMi9ncmlkX2p1cmFf
 YWxsYW5fZXhjZWxf
 dG90YWwueGxzeJR0C05oDU5oD2gQaBFoEGgSTnViaAYpgZR9lChoCYxVQ
 zovVXNlcnMvYWxsYW4v
 T25lRHJpdmUvw4FyZWEgZGUgVHJhYmFsaG8vZXhlcXBsb18yNTAzMjAyMi9
 ncmlkX2p1cmFfYWxs
 YW5fZXhjZWwueGxzeJR0C05oDU5oD2gQaBFoEGgSTnViaAYpgZR9lChoCY
 w9QzovVXNlcnMvYWxs
 YW4vT25lRHJpdmUvw4FyZWEgZGUgVHJhYmFsaG8vYmxvY29zX2p1cmFfb
 m4ueGxzeJR0C05oDU5o
 D2gQaBFoEGgSTnViaAYpgZR9lChoCYxXQzovVXNlcnMvYWxsYW4vQXBwR
 GF0YS9Mb2NhbC9Qcm9n
 cmFtcy9PcmFuZ2UvTGliL3NpdGUtcGFja2FnZXMvT3JhbmdlL2RhdGFzZXRzL
 2lyaXMudGFilGgL
 jA9zYW1wbGUtZGF0YXNldHOUaA2MCGIyaXMudGFilGgPaBBoEWgQaBJOd
 WJoBimBIH2UKGgJjFpD
 Oi9Vc2Vycy9hbGxhbi9BcHBEYXRhL0xvY2FsL1Byb2dyYW1zL09yYW5nZS9M
 aWlvc2l0ZS1wYWNR
 YWdlcy9PcmFuZ2UvZGF0YXNldHMvdGI0YW5pYy50YWKUaAtoN2gNjAt0aXR
 hbmljLnRhYpRoD2gQ

```

aBFoEGgSTnViaAYpgZR9lChoCYxaQzovVXNlcnMvYWxsYW4vQXBwRGF0Y
S9Mb2NhbC9Qcm9ncmFt
cy9PcmFuZ2UvTGliL3NpdGUtcGFja2FnZXMvT3JhbmdlL2RhdGFzZXRzL2hvd
XNpbmcudGFilGgL
aDdoDYwLaG91c2luZy50YWKUaA9oEGgRaBBoEk51YmgGKYGUfZQoaAmM
YEM6L1VzZXJzL2FsbGFu
L0FwcERhdGEvTG9jYWwvUHJvZ3JhbXMvT3JhbmdlL0xpYi9zaXRILXBhY2thZ
2VzL09yYW5nZS9k
YXRhc2V0cy9oZWYydF9kaXNIYXNlLnRhYpRoC2g3aA2MEWhlYXJ0X2Rpc2V
hc2UudGFilGgPaBBo
EWgQaBJOdWJoBimBIH2UKGgJjGFDOi9Vc2Vycy9hbGxhbi9BcHBEYXRhL0x
vY2FsL1Byb2dyYW1z
L09yYW5nZS9MaWlvc2l0ZS1wYWNRYWdlcy9PcmFuZ2UvZGF0YXNldHMvYn
Jvd24tc2VsZWNoZWQu
dGFilGgLaDdoDYwSYnJvd24tc2VsZWNoZWQuudGFilGgPaBBoEWgQaBJOdW
JoBimBIH2UKGgJjFZD
Oi9Vc2Vycy9hbGxhbi9BcHBEYXRhL0xvY2FsL1Byb2dyYW1zL09yYW5nZS9M
aWlvc2l0ZS1wYWNR
YWdlcy9PcmFuZ2UvZGF0YXNldHMvem9vLnRhYpRoC2g3aA2MB3pvby50YW
KUaA9oEGgRaBBoEk51
YmWMC3JIY2VudF91cmxzIF2UjBNzYXZlZdpZGdlEdlb21ldHJ5IENCAdnQy
wADAAAAAAK6AAAA
4gAABb8AAAPYAAACuwAAAQgAAAW+AAAD1wAAAAAAAAAAB4AAAAK7A
AABCAAABb4AAAPXllwLc2hl
ZXRfbmFtZXOUfZSMBnNvdXJjZZRLAlwDdXJslGgQjA1kb21haW5fZWRpdG9y
IH2UjAtfX3ZlcnNp
b25fX5RLAYwQY29udGV4dF9zZXR0aW5nc5RdlwVb3Jhbmdld2lkZ2V0LnNld
HRpbmdzllwHQ29u
dGV4dJSTICmBIH2UKlwGdmFsdWVzIH2UKlwJdmFyaWFibGVzIF2UaFV9IGh
hXZQoXZQojAFQllwU
T3JhbmdlLmRhdGEudmFyaWFibGWUjBJDb250aW51b3VzVmFyaWFibGWUk
5RLAGgQiGVdlCiMAUOU
aGILAGgQiGVdlCiMAkFBIGhpSwBoElhIXZQojAJBVJRoaUsAaBCIZV2UKlwCS
FSUaGILAGgQiGVd
ICiMAVKUaGILAGgQiGVdlCiMAUaUaGILA2gQiGVdlCiMAVOUaGeMEERpc2N
yZXRIVmFyaWFibGWU
k5RLAYwORmFpbGVkLCBTdGFibGWUiWVdlCiMAkklGhnjA5TdHJpbmdWYX
JpYWJsZZSTIEsDaBCJ
ZWVzaFdLAXWMCmF0dHJpYnV0ZXOUKGhmSwKGIGhrSwKGllwCQUGUSw
KGllwCQVSUSwKGllwCSFSU
SwKGIGhzSwKGIGh1SwKGIGh3XZQojAZGYWlsZWSUjAZTdGFibGWUZYaUd
JSMBW1ldGFzllwCSWSU
SwOGllWUjApjbGFzc192YXJzICmMEm1vZGlmaWVhX3ZhcmlhYmxlc5RdlHVl
YXUu
</properties>

```

```

<properties node_id="8" format="literal">{'auto_apply': True,
'class_weight': False, 'controlAreaVisible': True, 'index_output': 0,
'learner_name': '', 'max_depth': 3, 'max_features': 5, 'min_samples_split': 5,
'n_estimators': 200, 'savedWidgetGeometry':
b'\x01\xd9\xd0\xcb\x00\x03\x00\x00\x00\x00\x03\x1e\x00\x00\x01j\x00\x00\x04\

```

```

xaf\x00\x00\x02\xcd\x00\x00\x03\x1e\x00\x00\x01j\x00\x00\x04\xaf\x00\x00\x02
\xcd\x00\x00\x00\x00\x00\x00\x00\x00\x07\x80\x00\x00\x03\x1e\x00\x00\x01j\x
00\x00\x04\xaf\x00\x00\x02\xcd', 'use_max_depth': False, 'use_max_features':
True, 'use_min_samples_split': True, 'use_random_state': False, '__version__':
1}</properties>

```

```

    <properties node_id="9"
format="pickle">gASVCgEAAAAAAAAAB9ICiME mNvbnRyb2xBcmVhVmlzaWJsZ
ZSIjBNzYXZIZFdpZGdldEdlb21ldHJ5
IENCAdnQywADAAAAAABOAAAAHQAAAB38AAQA3AAAATgAAAB0AAAd/AA
AENwAAAAACAAAAB4AAAABO
AAAAHQAAAB38AAQA3IlwJc2VsZWNOaW9uIF2UjAtzY29yZV90YWJsZZR9llw
Mc2hvd25fc2NvcmlvZy
II+UKIwDTUFFIlwCUjKUjANBVUOUjARSTVNFIlwJUHJIY2lzaW9uIlwCRjGUjA
NNU0WUjAJDQZSM
BIJIY2FsbJSQc4wLX192ZXJzaW9uX1+USwGMEGNvbnRleHRfc2V0dGluZ3O
UXZR1Lg==
</properties>

```

```

    <properties node_id="10"
format="pickle">gASVBwQAAAAAAAAAB9ICiMFGNvbXBhcmllzb25fY3JpdGVyaW
9uIEsAjBJjb250cm9sQXJlYVZpc2li
bGWUilwNY3Zfc3RyYXRpZmllZSIjAduX2ZvbGRzIEsBjAluX3JlcGVhdHOUSw
OMCnJlc2FtcGxp
bmeUSwCMBHJvcGWURz+5mZmZmZmajAtzYW1wbGVfc2l6ZZRLC4wTc2F2
ZWRXaWRnZXRHZW9tZXRY
eZRDQgHZ0MsAAwAAAAAAB0AAAAS0AAATbAAADQQAAdAAAAEtAAAE2w
AAA0EAAAAAAAAAAAAAAeAAAAB
0AAAAS0AAATbAAADQZSMEnNodWZmbGVfc3RyYXRpZmllZSIjAh1c2Vfcm
9wZZSJjAtzY29yZV90
YWJsZZR9llwMc2hvd25fc2NvcmlvZyII+UKIwDTUFFIlwCUjKUjANBVUOUjARST
VNFIlwJUHJIY2lzaW9uIlwCRjGUjANNU0WUjAJDQZSMBIJIY2FsbJSQc4wLX192ZXJzaW9uX1+
USwOMEGNvbnRleHRf
c2V0dGluZ3OUXZQojBVvcmFuZ2V3aWRnZXQuc2V0dGluZ3OUjAdDb250ZXh
0IJOUKYGUfZQojAZ2
YWx1ZXOUfZQojA9jbGFzc19zZWx1Y3Rpb26UjBYoQXZlcmFnZSBvdmVylGNs
YXNzZXMPleR/////
hpSMDGZvbGRfZmVhdHVyZZROSv7///+GllwVZm9sZF9mZWFOdXJlX3NlbGVj
dGVklIIK/v///4aU
aA19IGgaSwN1jAphdHRyaWJ1dGVzICiMAVCUSwKGllwBQ5RLAoaUjAJBQZ
RLAoaUjAJBVJRLAoaU
jAJIVJRLAoaUjAFSIEsChpR0llwFbWV0YXOUKYwKY2xhc3NfdmFyc5SMAVO
USwGGIIWUdWJoHymB
IH2UKGgifZQoaCSMFihBdmVyYWdlIG92ZXIlgY2xhc3NlcymUSv/////+GIGgnTkr+
////hpRoKYIK
/v///4aUaA19IGgaSwN1aCwoaC1LAoaUaC9LAoaUjAJBQZRLAoaUjAJBVJRLA
oaUjAJIVJRLAoaU
aDdLAoaUdJRoOiloO4wBRpRLAoaUhZR1YmgfKYGUfZQoaCJ9ICiMD2NsYX
NzX3NlbGVjdGlvpSM
FihBdmVyYWdlIG92ZXIlgY2xhc3NlcymUSv/////+GllwMZm9sZF9mZWFOdXJlIE5
K/v///4aUjBVm

```

b2xkX2ZIYXR1cmVfc2VsZWN0ZWSUiUr+////hpSMC3Njb3JlX3RhYmxlIH2UaBp
 LA3VoLChoLUsc
 hpRoL0sChpRoSUsChpRoS0sChpRoTUsChpRoN0sChpR0IGg6jA1SYW5kb20
 gRm9yZXN0IEsChpSF
 IGg7aFFLAoaUhZR1YmV1Lg==
 </properties>

<properties node_id="11"
 format="pickle">gASVFwQAAAAAAAAAB9ICiMC2F1dG9fY29tbWI0IiMC2F1dG9fc
 2FtcGxllliMEmNvbnRyb2xBcmVh
 VmlzaWJsZZSljBNzYXZlZFdpZGdldEdlb21ldHJ5IENCAdnQywADAAAAAABN//
 //9wAAB4AAAAQ4
 AAAATgAAAB0AAAd/AAAENwAAAAACAAAAB4AAAABOAAAAHQAAAB38AAA
 Q3llwJc2VsZWN0aW9uIE6M
 EXRvb2x0aXBfc2hvd3NfYWxsllliMD3Zpc3VhbF9zZXR0aW5nc5R9llwFZ3JhcGi
 UfZQojAthbHBo
 YV92YWx1ZZRLglwNY2xhc3NfZGVuc2l0eZSJjBFqaXR0ZXJfY29udGludW91c
 5SJjAtqaXR0ZXJf
 c2l6ZZRLAlwTbGFiZWxfb25seV9zZWxlY3RlZJSJjBZvcnRob25vcm1hbF9yZW
 dyZXNzaW9uIiM
 C3BvaW50X3dpZHRoIEsKjAlzaG93X2dyaWSUiYwLc2hvd19sZWdlbmSUilwNc
 2hvd19yZWdfbGlu
 ZZSlcYwLX192ZXJzaW9uX1+USwWMEGNvbnRleHRfc2V0dGluZ3OUXZQojB
 VvcmFuZ2V3aWRnZXQu
 c2V0dGluZ3OUjAdDb250ZXh0IJOUKYGUfZQojAZ2YWx1ZXOUfZQojAphdHRy
 X2NvbG9yllwBU5RL
 ZYaUjAphdHRyX2xhYmVslE5K/v///4aUjAphdHRyX3NoYXBllE5K/v///4aUjAlhdH
 RyX3NpemWU
 Tkr+////hpSMBmF0dHJfeJSMBEZvbGSUS2WGllwGYXR0cl95llwBQ5RLZoaUa
 Ap9IGgWSwV1jAph
 dHRyaWJ1dGVzIH2UKlwBUJRLAmgtSwKMAkFBIEsCjAJBVJRLAowCSFSUS
 wKMAVKUSwJoIUsBdYwF
 bWV0YXOUfZQojBFSYW5kb20gRm9yZXN0ICgxKZRLAYwaUmFuZG9tIEZvc
 mVzdCAoMSkgKEZhaWxl
 ZCmUSwKMGIJhbmRvbSBGb3Jlc3QgKDEpIChTdGFibGUplEsCaCpLAXV1Y
 mgbKYGUfZQoaB59ICiM
 CmF0dHJfY29sb3KUaCFLZYaUjAphdHRyX2xhYmVslE5K/v///4aUjAphdHRyX3
 NoYXBllE5K/v//
 /4aUjAlhdHRyX3NpemWUTkr+////hpSMBmF0dHJfeJSMBEZvbGSUS2WGllwG
 YXR0cl95IGgtS2aG
 llwFZ3JhcGiUfZRoFksFdWgwFZQoaDJLAmgtSwKMAkFBIEsCjAJBVJRLAowC
 SFSUSwJoNksCaCFL
 AXVoN32UKlwNUmFuZG9tIEZvcmlwZJRLAYwWUmFuZG9tIEZvcmlwZCAoR
 mFpbGVkKZRLAowWUmFu
 ZG9tIEZvcmlwZCAoU3RhYmxlKZRLAmhISwF1dWJldS4=
 </properties>

<properties node_id="12"
 format="pickle">gASVAAMAAAAAAB9ICiMC2F1dG9fY29tbWI0IiMC2F1dG9f
 c2FtcGxllliMEmNvbnRyb2xBcmVh
 VmlzaWJsZZSljBNzYXZlZFdpZGdldEdlb21ldHJ5IENCAdnQywADAAAAAABN//
 //9wAAB4AAAAQ4

```

AAAATgAAAB0AAAd/AAAENwAAAAACAAAAB4AAAABOAAAAHQAAAB38AAA
Q3llwJc2VsZWN0aW9uIE6M
EXRvb2x0aXBfc2hvd3NfYWxslllMD3Zpc3VhbF9zZXR0aW5nc5R9llwFZ3JhcGi
UfZQojAthbHBo
YV92YWx1ZZRLglwNY2xhc3NfZGVuc2l0eZSJjBFqaXR0ZXJfY29udGludW91c
5SJjAtqaXR0ZXJf
c2l6ZZRLAlwTbGFiZWxfb25seV9zZWxlY3RlZJSJjBZvcnRob25vcm1hbF9yZW
dyZXNzaW9uIlmM
C3BvaW50X3dpZHRoIEsKjAlzaG93X2dyaWSUiYwLc2hvd19sZWdlbmSUilwNc
2hvd19yZWdfbGlu
ZZSldYwLX192ZXJzaW9uX1+USwWMEGNvbnRleHRfc2V0dGluZ3OUXZSMF
W9yYW5nZXdpZGldC5z
ZXR0aW5nc5SMB0NvbnRleHSUk5QpgZR9lCiMBnZhbHVlc5R9lCiMCmF0dHJf
Y29sb3KUTkr+////
hpSMCmF0dHJfbGFiZWYUTkr+////hpSMCmF0dHJfc2hhcGWUTkr+////hpSMCW
F0dHJfc2l6ZZRO
Sv7///+GllwGYXR0cl94llwRUmFuZG9tIEZvcnVzdCAoMSmUS2WGllwGYXR0c
l95llwBRpRLZoaU
aAp9lGgWSwV1jAphdHRyaWJ1dGVzIH2UKlwBUJRLAowBQ5RLAowCQUGU
SwKMAkFUIEsCjAJIVJRL
AowBUpRLAnWMBW1ldGFzIH2UKGgsSwJoKUsBjBpSYW5kb20gRm9yZXN0l
CgxKSAoRmFpbGVkKZRL
AowaUmFuZG9tIEZvcnVzdCAoMSkgKFN0YWJsZSmUSwJ1dWJhdS4=
</properties>
  </node_properties>
  <session_state>
    <window_groups />
  </session_state>
</scheme>

```

ANEXOS

Banco de dados Ferentinou

Figura B1 - Desempenho da rede neural para o conjunto de treinamento para cada rede neural.

No.	Target value $F d_i$	Predicted F value from ANN y_i	Error $E= y_i - d_i $	No.	Target value $S d_i$	Predicted S value from ANN y_i	Error $E= y_i - d_i $
1	1.110	1.105	0.005	1	0.000	0.000	0.000
2	1.000	0.885	0.115	2	0.000	0.026	0.026
3	1.875	1.950	0.075	3	1.000	0.999	0.001
4	2.045	2.002	0.043	4	1.000	0.993	0.007
5	1.780	1.788	0.008	5	1.000	1.000	0.000
6	1.990	1.904	0.086	6	1.000	1.000	0.000
7	1.250	1.243	0.007	7	0.000	0.014	0.014
8	1.130	1.109	0.021	8	0.000	0.000	0.000
9	1.020	0.994	0.026	9	1.000	0.986	0.014
10	1.300	1.300	0.000	10	1.000	0.992	0.008
11	1.200	1.238	0.038	11	0.000	0.006	0.006
12	1.090	1.022	0.068	12	0.000	0.006	0.006
13	0.780	0.931	0.151	13	1.000	0.962	0.038
14	2.000	2.001	0.001	14	1.000	1.000	0.000
15	1.700	1.750	0.050	15	0.000	0.006	0.006
16	1.020	0.960	0.060	16	0.000	0.011	0.011
17	0.890	0.924	0.034	17	1.000	0.990	0.010
18	1.460	1.452	0.008	18	0.000	0.000	0.000
19	0.800	0.817	0.017	19	0.000	0.470	0.470
20	1.440	1.452	0.012	20	0.000	0.000	0.000
21	0.860	0.817	0.043	21	1.000	0.470	0.530
22	1.080	1.077	0.003	22	0.000	0.010	0.010
23	1.110	1.122	0.012	23	0.000	0.000	0.000
24	1.400	1.430	0.030	24	0.000	0.013	0.013
25	1.350	1.295	0.055	25	0.000	0.002	0.002
26	1.030	1.049	0.019	26	0.000	0.000	0.000
27	1.280	1.274	0.006	27	1.000	1.000	0.000
28	1.630	1.618	0.012	28	0.000	0.001	0.001
29	1.050	1.124	0.074	29	0.000	0.001	0.001
30	1.030	1.020	0.010	30	0.000	0.004	0.004
31	1.090	1.116	0.026	31	1.000	0.984	0.016
32	1.110	1.097	0.013	32	0.000	0.001	0.001
33	1.010	0.980	0.030	33	0.000	0.005	0.005
34	0.625	0.675	0.050	34	1.000	0.994	0.006
35	1.120	1.109	0.011	35	0.000	0.013	0.013
36	1.200	1.177	0.023	36	1.000	1.000	0.000
37	1.800	1.755	0.045	37	0.000	0.000	0.000
38	0.900	0.909	0.009	38	0.000	0.000	0.000
39	0.960	0.911	0.049	39	0.000	0.006	0.006
40	0.830	0.710	0.120	40	0.000	0.000	0.000
41	0.790	0.878	0.088	41	0.000	0.001	0.001
42	0.670	0.703	0.033	42	0.000	0.000	0.000
43	1.450	1.466	0.016	43	0.000	0.000	0.000
44	1.580	1.586	0.006	44	1.000	0.998	0.002
45	1.370	1.397	0.027	45	1.000	1.000	0.000
46	2.050	1.981	0.069	46	1.000	1.000	0.000
MSE (E)			0.0025	MSE (E)			0.01

Fonte: Ferentinou, 2004.

Ábacos de Bishop e Morgenstern

Figura B2- Ábacos para a obtenção m', n' : $c'/\gamma H = 0$




Figura B3- Ábacos para a obtenção m', n' : $c'/\gamma H = 0,025$; $D = 1$





Figura B4- Ábacos para a obtenção m', n' : $c'/\gamma H = 0,025$; $D = 1,25$





Figura B5- Ábacos para a obtenção m', n' : $c'/\gamma H = 0,05$; $D = 1,00$





Figura B6- Ábacos para a obtenção m', n' : $c'/\gamma H = 0,05$; $D = 1,25$








Figura B7- Ábacos para a obtenção m', n' : $c'/\gamma H = 0,05$; $D = 1,50$




Ábacos de Taylor

Figura C1- Ábaco de Taylor para $\phi \neq 0$ e $c \neq 0$




Fonte: Taylor(1948)

Figura C2- Ábaco para fator de estabilidade de Taylor inclinação inferior a 54°



Fonte: Taylor(1948)

Figura C3- Ábaco para fator de estabilidade de Taylor inclinação superior a 54°



Fonte: Taylor(1948)