

Técnicas de Aprendizado de Máquina para Previsão de Perdas Severas em Rochas Carbonáticas de Reservatórios Do Pré-Sal

Giovani F. Machado*, Luciana F. Almeida**, Juan G. Lazo. Lazo***

* Centro Federal de Educação Tecnológica Celso Suckow da Fonseca, Rio de Janeiro, RJ, Brasil (e-mail: giovani.machado@gmail.com).

** Centro Federal de Educação Tecnológica Celso Suckow da Fonseca, Rio de Janeiro, RJ, Brasil (e-mail: lucianafaletti@gmail.com).

*** Facultad de Ingeniería, Universidad del Pacífico, Lima, Peru (e-mail: jg.lazol@up.edu.pe)

Abstract: This work aims to present binary classification models to assist in determining the occurrence of circulation loss phenomenon in the construction of subsea wells in the Santos Basin's pre-salt. Prior knowledge about the possibility of the phenomenon occurrence, makes it possible to allocate rigs with the appropriate technology for the well's construction. In this context, classification systems based on machine learning can support decision making. In this work, classifiers are proposed based on classic machine learning algorithms and the results are presented using the Area Under the ROC Curve (AUC) as the metric.

Resumo: Este trabalho visa apresentar modelos de classificadores binários para auxiliar na determinação da ocorrência do fenômeno de perda de circulação na construção de poços submarinos do pré-sal da Bacia de Santos. O conhecimento prévio sobre a possibilidade de ocorrência do fenômeno, possibilita alocar sondas com a tecnologia adequada para a construção dos poços. Neste contexto, os sistemas de classificação baseados em aprendizado de máquina podem apoiar a tomada de decisão. Neste trabalho, são propostos classificadores baseados em algoritmos clássicos de aprendizado de máquina e os resultados são apresentados utilizando a Área Sob a Curva ROC (AUC) como métrica.

Keywords: Circulation Loss; Classification; Machine learning; Pre-salt; Drilling.

Palavras-chaves: Perda de circulação; Classificação; Aprendizado de máquina, Pré-sal; Perfuração.

1. INTRODUÇÃO

A construção de poços em reservatórios carbonáticos do pré-sal pode apresentar muitos desafios técnicos. Um destes desafios é prever a ocorrência de perda de circulação em cada locação a ser explorada ou explotada.

Convencionalmente, a perfuração de um poço ocorre bombeando continuamente fluido de perfuração através da coluna e broca de perfuração com retorno para os tanques de fluido na superfície. Em um sistema de perfuração convencional, o retorno do fluido ocorre em modo aberto (pressão atmosférica), como mostra a Figura. 1a. Já as sondas de MPD têm, na superfície, no retorno de fluido, um sistema que permite que o poço seja pressurizado fechando válvulas ou bombeando fluido através do anular (na direção oposta à perfuração convencional), como mostra a Figura. 1b. A segurança das operações de perfuração depende da definição correta da densidade do fluido de perfuração. Este deve fornecer pressão hidrostática maior que a pressão dos reservatórios que serão atravessados. Em algumas locações, ocorre o fenômeno de perda de circulação severa ou total. Nesse fenômeno, parte (ou todo) fluido bombeado é perdido para a formação, assim, o nível do fluido diminui e, como

resultado, a pressão exercida por este também diminui, levando a uma situação operacional de descontrole que pode resultar em um blowout (produção descontrolada do poço).




Fig. 1 Técnicas de Perfuração na construção de poços. a Esquemático da técnica de perfuração convencional. b Esquemático da técnica de perfuração MPD.

Se o fenômeno de perda total de fluido de perfuração for observado nas atividades de perfuração, é necessário realizar operações de combate à perda, se esta operação for malsucedida, o poço deve ser abandonado temporariamente ou até definitivamente. Quando a perda total ou severa é prevista na fase do projeto, sondas com tecnologia MPD podem ser alocadas para construção do poço.

A previsão de perda de fluido é realizada por especialistas (geólogos, geofísicos e engenheiros de petróleo), utilizando como insumos o modelo geológico da área e poços previamente perfurados na região. Para os casos onde não é prevista perda de circulação, uma sonda com técnica convencional (menor custo) é escolhida para perfurar o poço, por outro lado, quando é prevista a perda de circulação, uma sonda, mais complexa e maior custo, com a tecnologia de *Managed Pressure Drilling* (MPD) é escolhida. Utilizando esta abordagem, através da interpretação de especialistas, sem um sistema de apoio à decisão, para 38 poços perfurados no pré-sal, foi obtido o seguinte resultado:

- Previsão de perda de circulação para 23 poços, sendo 10 verdadeiros positivos e 13 falsos positivos;
- Previsão de não perda de circulação para 15 poços, sendo 8 negativos verdadeiros e 7 falsos negativos.

O resultado desta previsão pode ser representado através de uma matriz de confusão. A Figura 2 representa a matriz de confusão para as previsões dos especialistas.




Fig. 2 Matriz de confusão para previsão dos especialistas.

Atualmente, como mencionado, a previsão de perda de circulação para poços offshore é feita sem qualquer sistema de apoio à decisão, baseando-se na interpretação de geólogos, geofísicos e engenheiros de reservatórios. Uma abordagem semelhante à proposta neste trabalho foi realizada para poços terrestres (Toreifi, Hojjat et al. 2014), porém o cenário de poços terrestres é bastante distinto, pois a mobilização de recursos é menos complexa, o custo diário das operações é muito menor e a mudança no método de construção dos poços é mais simples.

2. SISTEMA DE SUPORTE A DECISÃO BASEADOS EM INTELIGÊNCIA ARTIFICIAL.

O objetivo deste trabalho é apresentar modelos que permitam a implementação de um sistema de suporte à decisão baseado em aprendizado de máquina para prever o fenômeno de perda severa de circulação. Para viabilizar essa abordagem, a Petrobras criou um grupo de trabalho multidisciplinar para

gerar um banco de dados com atributos que pudessem representar o cenário de perda de circulação (Duarte, S. B. et al., 2018). Foram analisados, inicialmente, os 38 poços já perfurados e determinados 14 atributos que são conhecidos antes de uma operação de perfuração (parte da base de dados é mostrada no apêndice). Destes atributos, 3 são numéricos e representam informações sísmicas, 11 são categóricos (valores sim ou não) e representam características geológicas da locação onde o poço foi ou será perfurado. É essencial mencionar que mais de um reservatório pode ser atravessado durante a perfuração do poço. Desta forma, esses 38 poços geraram 120 amostras. A Figura 3 representa a distribuição entre as ocorrências de perda (1) e não perda (0) de circulação para as formações atravessadas pelos 38 poços.




Fig. 3 Distribuição entre perda (1) e não perda (0) de circulação.

Como pode ser verificado na Figura 3, o problema tem uma distribuição de classe desbalanceada. Para avaliar os modelos, foram utilizadas as *Receiver Operating Characteristics* (ROC) e Área sob a curva ROC (AUC) (Fawcett, T. 2006). Essa escolha é baseada no fato de que a ROC possui propriedades que a torna especialmente útil para domínios com distribuição de classe assimétrica em problemas de classificação binária (Ling, C. X., Huang, J, Zhang, H. 2015).

Para avaliar as previsões dos especialistas, ilustrada na matriz de confusão da Figura.2, uma curva ROC foi traçada e a área sob o ROC calculada. A Figura 4 mostra os resultados.




Fig. 4 ROC obtida através da previsão dos especialistas.

O valor da AUC varia no intervalo de 0 a 1. Um classificador perfeito tem AUC igual a 1, enquanto um classificador puramente aleatório tem AUC igual a 0,5 (curva pontilh). É essencial destacar que a AUC é um parâmetro

estatisticamente consistente, que é muito útil para análise de discriminabilidade e geralmente é uma métrica mais apropriada que a precisão, especialmente em uma base de dados desbalanceada (Ling, C. X., Huang, J, Zhang, H. 2015). Através da Figura 4, é possível concluir que a previsão de especialistas sem o uso de um sistema suporte à decisão foi pior do que um classificador aleatório. Isso pode ser explicado pelo fato de que uma sonda MPD pode executar a perfuração com ou sem perda de circulação, mas é incerto que uma sonda convencional possa concluir a perfuração com perda de circulação. Então os especialistas são influenciados por esse fato.

Outro aspecto sobre a base de dados é a relação entre o número de amostras (120 amostras) e o número de atributos (14 atributos). No caso da base de dados deste trabalho, pode-se afirmar que, para a maioria dos métodos clássicos de classificação / regressão, ela não possui atributos em demasia, considerando o número de amostras existentes (Hua, J. et al. 2004).

Para a aplicação de alguns algoritmos de classificação, que operam somente com atributos numéricos, foi realizada a conversão de dados categóricos em numéricos. Essa conversão pode ser realizada definindo como 0 a distância entre dois valores categóricos iguais e como 1 a distância entre dois valores diferentes, independentemente dos valores reais envolvidos. Uma alternativa à modificação envolvendo distância é a substituição de um atributo que possua k valores distintos para atributos binários sintéticos k (ou k - 1), um para cada valor (Tan, P. N., Steinback, M., Kumar. 2014), (Witten, I. H. et al. 2016). Para este trabalho as duas abordagens resultam na mesma base de dados.

Para o desenvolvimento e avaliação dos modelos propostos no presente trabalho, a base de dados foi dividida em dois conjuntos: treinamento/validação e teste, nas seguintes proporções: 70% e 30%. O primeiro conjunto foi usado para ajustar e validar os parâmetros dos classificadores, enquanto o segundo, para sua avaliação. A validação cruzada foi realizada através de *K-fold* e *leave-one-out*. A configuração inicial dos hiperparâmetros foi obtida através de busca realizada com o método *GridSearchCV()* (Pedregosa, F. et al. 2011). Foram utilizados três algoritmos de aprendizado de máquina supervisionados: *Random Forest*, *Redes Neurais Artificiais* e *Support Vector Machine*. A figura 5 apresenta o fluxo de trabalho realizado para treinamento, validação e teste do modelo.

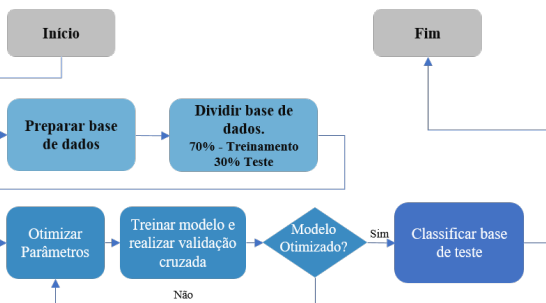


Fig. 5 Fluxo de trabalho com otimização dos parâmetros e validação cruzada

O primeiro resultado apresentado refere-se ao algoritmo *Support Vector Machine* (SVM). SVM é um modelo de aprendizado de máquina potente e versátil, capaz de executar classificação linear ou não-linear e regressão. É um dos modelos mais populares de aprendizado de máquina. O algoritmo SVM é adequado para classificar conjuntos de dados pequenos ou médios, independentemente de sua complexidade (Géron, A. 2017). Inicialmente, a configuração que apresentou o melhor desempenho na busca de parâmetros ótimos, relativo às amostras de treinamento, e não apresentou *overfitting* possui hiperparâmetros conforme a Figura 6.

```

SVC(C=5.860652869760619, cache_size=200, class_weight=None, coef0=0.0,
decision_function_shape='ovr', degree=3, gamma=0.08832478821901962, kernel='rbf',
max_iter=-1, probability=True, random_state=None, shrinking=True, tol=0.001, verbose=False)
  
```

Fig. 6 Hiperparâmetros obtidos para o classificador SVM.

Para otimizar o classificador, variou-se o valor do hiperparâmetro *gamma*. O classificador de melhor desempenho apresentou hiperparâmetros *gamma* igual a 1 e *kernel Radial Basis Function* (RBF), pois as amostras não são linearmente separáveis. O parâmetro *gamma* pode ser interpretado como o inverso do raio de influência das amostras selecionadas pelo modelo como vetores de suporte. Quando o valor de *gamma* é muito pequeno, o modelo não captura a complexidade ou a "forma" dos dados. Quando *gamma* é muito grande, o modelo tende a realizar *overfitting* da base de treinamento. A figura 7 apresenta os valores da AUC para diversos valores de *gamma*.




Fig. 7 Variação da AUC em função do valor de *gamma*

A Figura 8 mostra a curva ROC e a Figura 9 mostra a matriz de confusão para o conjunto de teste quando classificado por este modelo.




Fig. 8 ROC para o classificador SVM.




Fig. 9 Matriz de confusão para o classificador SVM.

O segundo resultado refere-se ao classificador modelado utilizando o algoritmo *Random Forest*. O *Random Forest* utiliza a técnica denominada Ensemble Learning, esta técnica consiste na combinação de vários preditores fracos, que mesmo apresentando resultados fracos individualmente, quando combinados apresentam resultados robustos. *Random Forest* é a combinação de várias árvores de decisão. Cada árvore de decisão é treinada através de uma combinação aleatória do conjunto de treinamento (Kittler, J., Hater, M., Duin, R. P. W. 1996). Inicialmente, a configuração que apresentou o melhor desempenho na busca de hiperparâmetros é mostrada na Figura 10.

```
RandomForestClassifier(bootstrap=False, class_weight=None,
criterion='entropy', max_depth=5, max_features='auto',
max_leaf_nodes=None, min_impurity_decrease=0.0,
min_impurity_split=None, min_samples_leaf=1,
min_samples_split=2, min_weight_fraction_leaf=0.0,
n_estimators=1000, n_jobs=-1, oob_score=False, random_state=42,
verbose=0, warm_start=False)
```

Fig. 10 Hiperparâmetros obtidos para o classificador Random Forest.

Para otimizar o classificador, o fluxo de trabalho da Figura 5 foi seguido. A fig 11 mostra o valor da AUC ao variar o hiperparâmetro de regularização *max_depth* (profundidade máxima das árvores).

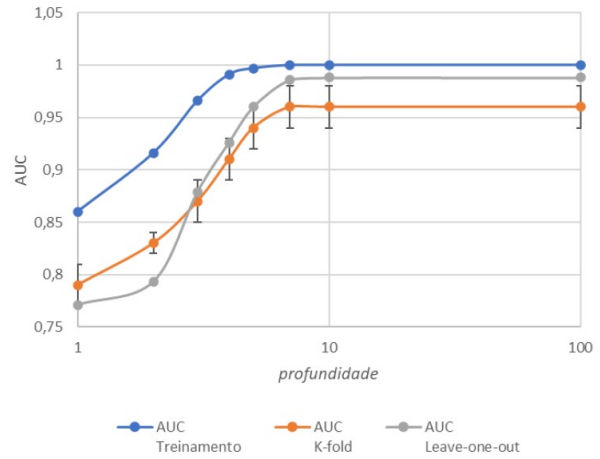


Fig. 11 Variação da AUC em função do valor da profundidade das árvores.

A Figura 12 apresenta a curva ROC obtida e a Figura 13 mostra a matriz de confusão obtida para o conjunto de teste quando utilizado o classificador Random Forest.




Fig. 12 ROC para o classificador Random Forest.




Fig. 13 Matriz de confusão para o classificador Random Forest.

O terceiro resultado refere-se ao classificador modelado utilizando Redes Neurais Artificiais (RNA). Foi utilizado uma rede neural com uma camada de entrada, duas camadas ocultas, contendo 50 e 32 neurônios e a camada de saída com um neurônio. RNA são treinadas através do algoritmo *backpropagation* (Rumelhart, D.E., Hinton, G.E. e Williams. 1985). As camadas ocultas costumam operar com funções de ativação, sendo as mais comuns ReLU, Tanh e logística. A Figura 14 apresenta os hiperparâmetros utilizados, a rede

modelada neste trabalho utilizou a ReLU como função de ativação.

```

Pipeline(memory=None,
steps=[('scaler', StandardScaler(copy=True, with_mean=True, with_std=True)), ('neural', MLPClassifier(activation='relu', alpha=0.1, batch_size='auto', beta_1=0.9, beta_2=0.999, early_stopping=False, epsilon=1e-08, hidden_layer_sizes=(50, 32), learning_rate='constant', learning_rate_search=False, max_iter=1000, n_iter_no_change=10, solver='adam', tol=0.0001, validation_fraction=0.1, verbose=False, warm_start=False))])

```

Fig. 14 Hiperparâmetros obtidos para o classificador RNA.

Novamente, o fluxo de trabalho descrito na Figura 5 foi seguido. A Figura 15 mostra o valor da AUC ao variar o hiperparâmetro de regularização α . α é um hiperparâmetro de regularização, também conhecido como termo de penalidade, que busca evitar o *overfitting* restringindo a magnitude dos pesos. O aumento do α incentiva pesos menores, resultando em limite de decisão com curvaturas mais suaves. Da mesma forma, a diminuição do α pode corrigir um viés alto, incentivando pesos maiores, resultando potencialmente em um limite de decisão mais ajustado aos dados de treinamento, com a possibilidade de ocorrência de *overfitting*. É possível observar que o valor de α que maximiza a AUC da validação cruzada no limiar da ocorrência de *overfitting* das amostras de treino é em torno de 0,5.




Fig. 15 Variação da AUC em função do valor de α .

A Figura 16 mostra a curva ROC e a Figura 17 mostra a matriz de confusão para este modelo.

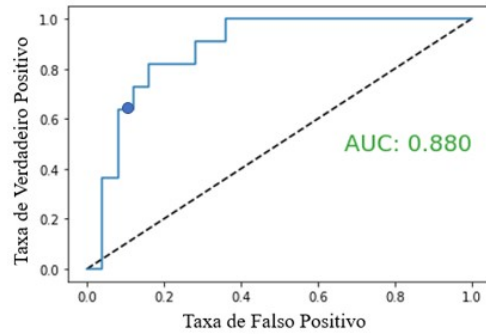


Fig. 16 ROC para o classificador baseado em RNA.




Fig. 17 Matriz de confusão para o classificador baseado em RNA.

A tabela I resume os resultados obtidos para o conjunto de teste para cada um dos três algoritmos utilizados, considerando a AUC como métrica.

Tabela 1. Resultado Comparativo entre os Classificadores

Classificador	AUC (base de teste)	AUC teste / AUC especialista
Especialista	0,485	-
SVM	0,724	149%
Random Forest	0,847	175%
RNA	0,887	183%

3. RESUMO DOS RESULTADOS

A tabela II é um resumo do resultado da classificação da base de testes que é apresentado no apêndice A. Na Tabela II é possível verificar que 20 amostras da base de teste foram classificadas corretamente por todos os classificadores, enquanto 3 amostras não foram classificadas corretamente por nenhum dos classificadores. A tabela indica que um ensemble destes modelos teria capacidade de classificar corretamente 29 amostras.

Tabela 2. Frequência de classificações corretas.

Nº de classificadores com classificações corretas	Quantidade de amostras
4	20
3	9
2	1
1	3
0	3

4. CONCLUSÕES

Os resultados de desempenho dos classificadores apresentados mostram que a criação de um sistema de apoio à decisão para prever perda severa nas rochas carbonáticas dos reservatórios do pré-sal da Bacia de Santos melhoraria o processo de previsão de perda de circulação, elevando a AUC em até 83% para um modelo baseado em redes neurais. Os classificadores foram treinados e validados com amostras aleatórias de 70% da base de dados e testados em 30% das amostras. Devido ao desequilíbrio dos dados, a principal métrica adotada foi a Área sob a curva ROC. Com essa métrica, é possível concluir, como mostrado na tabela I, que a abordagem de aprendizado de máquina tem um grande potencial para melhorar o processo de determinar os poços com possibilidade de perda de circulação e, assim, escolher a melhor tecnologia para perfuração dos poços. O uso dos classificadores projetados neste trabalho, como sistema de apoio à decisão, reduziria drasticamente o número de falsos positivos, evitando o uso de sondas MPD em poços sem a necessidade e alocando esse recurso para cenários onde é de fato necessário. Conforme observado, todos os classificadores apresentaram resultado superior ao obtido pelos especialistas, sendo a rede neural o classificador de melhor desempenho com AUC de 0,887. Com este resultado, é possível economizar em média US\$ 1,08 milhão por poço com custos de abandono e taxa diária de sonda.

Um trabalho futuro é o uso de *deep-learning* para substituir os atributos sísmicos, utilizando as imagens sísmicas como atributos na camada de entrada.

AGRADECIMENTOS

A Coordenação Técnica do SBA 2020 pela organização do evento, ao CEFET-RJ por permitir o desenvolvimento deste trabalho e à Petrobras por disponibilizar os dados.

REFERÊNCIAS

Duarte, S. B. et al., 2018 Artificial Intelligence Use To Predict Severe Fluid Losses in Pre-Salt Carbonates. In: *SPWLA 59th Annual Logging Symposium*. Society of Petrophysicists and Well-Log Analysts.

Fawcett, T., 2006. An introduction to ROC analysis. *Pattern recognition letters*, 27(8), pp.861-874.

Géron, A., 2019. *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. O'Reilly Media.

Kittler, J., 1998. Combining classifiers: A theoretical framework. *Pattern analysis and Applications*, 1(1), pp.18-27.

Hua, J., Xiong, Z., Lowey, J., Suh, E. and Dougherty, E.R., 2005. Optimal number of features as a function of sample size for various classification rules. *Bioinformatics*, 21(8), pp.1509-1515.

Ling, C.X., Huang, J. and Zhang, H., 2003, August. AUC: a statistically consistent and more discriminating measure than accuracy. In *Ijcai* (Vol. 3, pp. 519-524).

Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V. and Vanderplas, J., 2011. Scikit-

learn: Machine learning in Python. *the Journal of machine Learning research*, 12, pp.2825-2830.

Rumelhart, D.E., Hinton, G.E. and Williams, R.J., 1985. *Learning internal representations by error propagation* (No. ICS-8506). California Univ San Diego La Jolla Inst for Cognitive Science.

Tan, P.N., Steinbach, M. and Kumar, V., 2016. *Introduction to data mining*. Pearson Education India.

Toreifi, H. and Rostami, H., 2014. New method for prediction and solving the problem of drilling fluid loss using modular neural network and particle swarm optimization algorithm. *Journal of Petroleum Exploration and Production Technology*, 4(4), pp.371-379.

Witten, I.H., Frank, E. and Hall, M.A., 2005. Practical machine learning tools and techniques. *Morgan Kaufmann*, p.578.

Apêndice A. CLASSIFICAÇÕES DA BASE TESTE

Nesta seção são apresentados os resultados de classificação da base de teste. A Tabela III traz os resultados obtidos pelos algoritmos SVM, Random Forest e Rede Neural.

Tabela 3. Classificação da base de teste.

	ATRIB_MAXI	ATRIB_DIST1	DIFP	MG P1	MG P2	MG P3	MG P4	MG P5	MG P6	MG P7	MG P8	MG P9	MG P10	MG P11	MG P12	MG P13	MG P14	Perda30	Classificação (SVM)	Classificação (RF)	Classificação (RN)
11	0,95	120	0,363	0	1	1	1	0	0	0	0	1	1	1	1	0	1	1	1	1	1
12	0,05	1000	0,35	0	1	1	1	0	0	0	0	1	1	1	0	1	1	1	1	0	1
14	0,14	238	0,9	0	0	0	0	0	0	0	1	0	0	0	0	0	1	0	0	0	0
19	0,95	0	12774	1	0	0	1	1	0	0	0	1	1	1	1	1	1	1	1	0	0
20	0,95	40	1,1	1	0	0	1	1	0	0	0	1	1	1	1	1	1	1	1	0	0
22	0,23	35	0,094	1	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
25	0,05	488	0,17	0	0	0	0	1	0	0	0	1	0	0	0	0	0	0	0	0	0
28	0,05	1000	0,235	0	0	0	0	1	0	0	0	1	0	0	0	0	0	0	0	0	0
38	0,05	1000	0,53	0	0	0	0	0	1	0	1	1	0	0	0	0	0	1	0	0	0
40	0,28	1000	0,57	0	0	0	0	0	1	0	1	1	0	0	0	0	1	0	0	0	0
42	0,26	205	0,673	0	0	0	0	0	0	1	1	0	1	1	0	1	0	1	0	0	0
43	0,91	50	0,667	0	0	0	0	0	0	0	1	1	0	1	1	0	1	0	0	0	0
47	0,95	350	1,77	1	1	0	0	0	0	0	1	1	1	0	1	0	1	0	0	0	0
54	0,07	1000	1,01	0	1	0	1	0	1	1	0	1	1	1	1	0	1	0	0	0	0
55	0,95	145	1,29	0	1	0	1	0	1	1	0	1	1	1	1	0	1	0	1	1	1
60	0,95	302	0,62	1	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
62	0,95	190	0,53	1	1	0	1	1	1	1	1	1	1	1	1	1	1	0	1	1	1
63	0,92	150	0,74	1	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
64	0,94	201	0,39	1	1	0	1	1	1	1	1	1	1	1	1	1	1	1	0	1	0
65	0,95	0	0,55	1	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
76	0,66	397,85	1,26	0	1	0	1	0	0	0	0	1	0	1	1	0	0	0	1	1	1
78	0,05	566,79	0,656	0	1	0	1	0	0	0	0	1	1	1	1	0	1	1	1	0	1
81	0,05	1000	0,794	0	1	0	0	0	0	0	0	0	1	0	0	0	1	0	0	0	0
83	0,95	25	1147	0	1	0	0	0	0	0	0	0	1	0	0	1	0	0	0	0	0
85	0,33	206,16	0,17	0	1	1	1	1	0	0	0	1	1	1	1	0	1	1	0	1	0
89	0,95	125	0,92	0	1	0	0	1	0	0	0	1	1	0	1	0	1	0	0	0	0
92	0,81	25	0,52	0	1	0	1	1	1	0	0	1	1	1	1	1	1	1	0	0	1
97	0,27	262,8	1	0	1	0	1	1	1	1	1	1	1	1	1	0	1	1	1	1	1
101	0,05	350,22	0,76	0	1	0	0	0	0	0	0	1	1	0	0	1	0	0	0	0	0
108	0,18	1000	0,43	0	1	0	1	1	0	0	0	1	0	1	1	0	1	0	0	0	1
111	0,05	1000	0,44	0	1	0	0	0	1	0	0	0	1	1	0	1	0	0	0	0	0
115	0,95	277,55	0,47	0	1	0	1	0	0	0	0	1	0	1	0	0	0	0	0	0	0
119	0,95	1000	0,67	0	1	0	1	0	0	0	0	1	0	1	1	0	1	0	0	0	1
123	0,95	409,46	0,74	0	1	0	0	0	1	0	0	0	1	0	0	1	0	0	0	0	0
124	0,33	162,98	0,68	0	1	0	0	0	1	0	0	0	0	1	0	0	1	0	0	0	0
125	0,17	168,17	0,7	0	1	0	0	0	1	0	0	0	0	1	0	0	1	0	0	0	0