

METODOLOGIA PARA AVALIAÇÃO DE DESEMPENHO DA ALOCAÇÃO DINÂMICA DE EQUIPAMENTOS DE MINA

Alexandre Marinho, Marinho & Associados Consultoria Empresarial Ltda.,
Alisson César de Souza, Devex Tecnologia e Sistemas S/A,
Robert Fabricio Subtil, Devex Tecnologia e Sistemas S/A
marinhoass@gmail.com

RESUMO

O presente trabalho visa apresentar uma metodologia para quantificar os ganhos obtidos com o uso do programa SmartMine com e sem a aplicação do módulo de otimização. O SmartMine é desenvolvido pela Devex, desde 1997, e trata-se de um programa para controle do tráfego de equipamentos em operações mineiras, incluindo o despacho de caminhões para frentes de lavra, pilhas de estéril, britadores, etc., ponto ao qual se aplica o módulo de otimização. A metodologia que será apresentada ao longo deste trabalho faz uso dos seguintes métodos de aproximação de função: Redes Neurais, Regressão Global e Regressão Local. Além disso, são levados em conta os desvios, visando que a quantificação de ganhos seja a mais confiável possível.

Palavras Chaves: redes neurais; regressão linear; SmartMine; quantificação de ganhos.

ABSTRACT

In this study a methodology to quantify gains obtained by the use of the SmartMine software with and without the optimization module will be presented. The SmartMine software has been developed by Devex, since 1997, and it is a software that deals with traffic control of equipment in mineral operations, including the dispatch of trucks to the mine fronts, waste dumps, crushers, etc., where the optimization module works. The methodology that will be presented in this study, uses the following function fit methods: Neural Networks, Global Regression and Local Regression. Beyond that, the deviations are taken in consideration aiming more reliable results for the quantification of gains.

Keywords: neural networks; linear regression; SmartMine; quantification of gains.

INTRODUÇÃO

A avaliação entre períodos distintos, no meio da mineração, é muito comum e é usada para, por exemplo, medir se a entrada de um novo produto trouxe melhoria para o desempenho da operação.

Entretanto, dependendo da forma com que os dados são comparados, pode-se fazer uma avaliação superficial demais ou até mesmo equivocada. As soluções atuais negligenciam fatores importantes que influenciam na produtividade, o que pode gerar uma avaliação enganosa ao serem desconsiderados fatores naturais.

Não é considerado que de um período para outro variáveis que influenciam na produtividade podem sofrer alterações. Por isso, a metodologia proposta é importante para que a mineração que a utilize saiba o real ganho proporcionado por um novo produto, pois, além de considerar as mudanças nas variáveis aponta quais são as variáveis que realmente tem impacto significativo na produtividade.

Além disso, a qualidade dos resultados obtidos sofre interferência da forma e quantidade de dados coletados. É também parte da metodologia estimar os desvios obtidos em cada caso, aplicando ajustes, com o intuito de fazer com que desvios positivos compensem os negativos, tentando respeitar a distribuição dos registros estimados.

Descrição do Problema

Segundo Alarie e Gamache (2002), para resolver o problema de despachar caminhões em uma mina a céu aberto é preciso responder à pergunta: 'qual é o próximo destino do caminhão?'. Esse problema pode ser resolvido dinamicamente ou não.

Nas minas onde não há sistemas de alocação dinâmica, geralmente o controlador da mina determina uma alocação inicial que persiste até o final do turno. Estudos como os de Costa *et al.* (2004), Pinto e Merschmann (2001), Merschmann (2002) e Pinto *et al.* (2003) mostram que com a alocação dinâmica é possível melhorar o desempenho da operação, atendendo rapidamente às variações que podem ocorrer ao longo da operação. A figura 1 mostra a diferença entre a operação normal e a operação dinâmica nas minas.

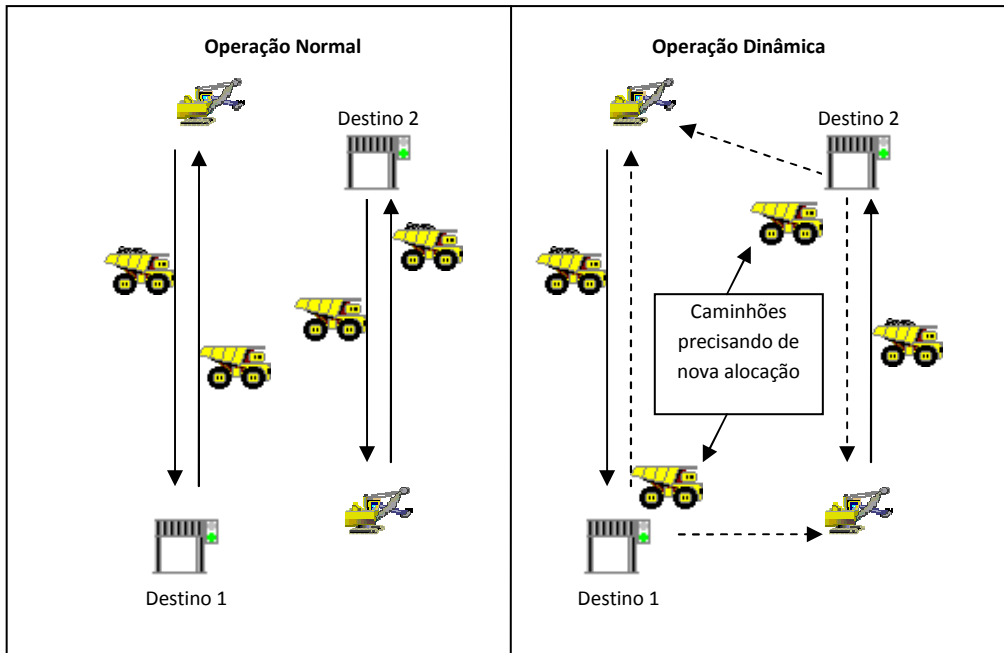


Figura 1: Diferença entre uma operação normal e uma operação com despachos dinâmicos.

Quando a mina possui uma ferramenta de alocação dinâmica, é possível implementar o ciclo conjugado, que promove a redução do tempo de deslocamento vazio ao fazer a ligação entre dois ciclos, ou seja, um caminhão ao terminar o basculamento é enviado para carregar em uma máquina mais próxima que está enviando material para outro destino. As figuras 2 mostram o funcionamento dos ciclos simples e conjugado, respectivamente.

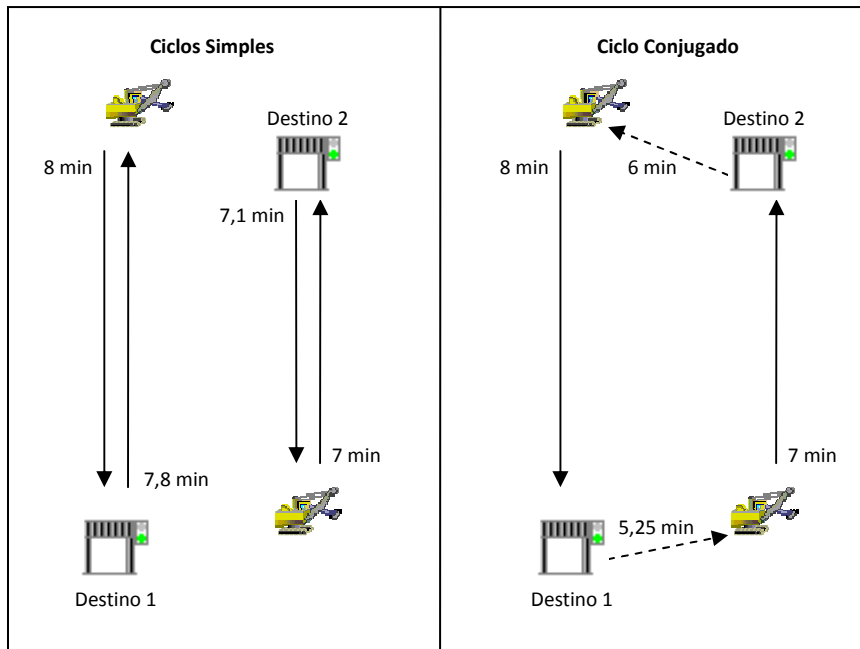


Figura 2: Ciclos Simples X Ciclo Conjugado.

Além dos ganhos apresentados nesse exemplo, a alocação otimizada do SmartMine avalia as produções definidas para cada frente de lavra, produtividades dos equipamentos de carga, tempos de espera em filas, distâncias de transporte, dentre outros, para tomar as decisões de forma a obter um melhor aproveitamento da frota disponível, dentro das especificidades momentâneas da mina.

Disposição dos Dados Coletados

O banco de dados de cada mina, após exportado do SmartMine, encontra-se organizado em uma planilha, com registros divididos por equipe. Para cada equipe, consta o modelo de caminhão utilizado no transporte, bem como o tipo de material transportado (minério e/ou estéril). Cada registro resume, em 30 variáveis, os resultados de um turno de trabalho, informando dia e horário de início e fim das operações. As variáveis estão representadas na tabela 1.

Tabela 1: Lista de variáveis exportadas pelo SmartMine

Data	Uso Efe. Otim.	Tempos Manobra
Aguad. Desp. Vazio	Horas Disponíveis	Horas Manut.
HIO	HAO	Horas Ociosas
Horas Vazio	Horas Filas	Horas Manobra
Horas Cheio	Horas Basculam	Variáveis Otim
Uso Global Otim	Produtividade	Produção
Carga Média	Tempo Ciclo	Tempo Vazio
Tempos Fila	Tempo Carga	Tempo Cheio
Tempo Basculam	Distâncias	Velocidades
Horas Utilizadas	Viagens	Massas

METODOLOGIA

Variável de Estudo

A forma de uso da otimização do SmartMine varia de mina para mina. Há casos em que os períodos otimizados e não otimizados são disjuntos, e outros em que há alternância do uso. Há minas que possuem variações gradativas, enquanto outras exigem mudanças radicais no planejamento, principalmente no tocante à escolha de frentes de lavra e suas produções. Em suma, é preciso definir uma variável de estudo que normalize, ao máximo, essas possíveis oscilações operacionais, que não podem ser controladas pelo sistema de despacho.

O ponto de partida para tal definição foi a variável já existente no banco de dados que registra a produtividade média horária por caminhão. Essa variável considera as horas efetivamente trabalhadas, eliminando do problema discussões relativas a horas improdutivas, ou horas de manutenção. Além disso, a produção e quantidade de caminhões operando também estão consideradas dentro dessa variável.

Analisando as demais variáveis do banco, foi possível normalizar também a carga média dos caminhões. Ao se dividir a produtividade pela carga, criou-se uma nova variável que passa a denotar a quantidade de viagens por caminhão por hora (VCH), que representa diretamente a capacidade produtiva de uma mina.

$$VCH = \frac{\textit{Produtividade}}{\textit{CargaMédia}}$$

$$VCH = \frac{\textit{Viagens}}{\textit{cam. hora}}$$

A única forma de modificar o resultado dessa variável é alterando o tempo de ciclo. Portanto, os tempos médios são os pontos mais importantes a serem estudados, conforme será apresentado em maiores detalhes nos próximos capítulos.

As variáveis relacionadas ao ciclo não podem ser incluídas na variável de estudo, pois questões como o tempo médio de carregamento devem ser diluídas em todo o ciclo, além do fato do tempo de ciclo ser influenciado pela otimização. Por exemplo, poderia se pensar em dividir VCH pela Dist. Cheio, encontrando uma variável que representaria o número de viagens por caminhão por hora por km transportado cheio. A influência do T. Carga na VCH em cada km depende da distância, ou seja, quanto maior a Dist. Cheio, menor será a influência do T. Carga, já que esse tempo seria diluído para cada km. Assim, apesar de incluir a Dist. Cheio dentro da variável de estudo, o resultado continua sendo dependente dessa variável, ou seja, não houve normalização. Raciocínio semelhante pode ser feito para as demais variáveis que não foram incluídas na variável de estudo.

Tratamento dos Dados

Antes da análise dos dados, é necessário que o banco de dados esteja consistente e unificado. Registros com campos inválidos precisam ser eliminados. É preciso criar uma chave primária capaz de identificar os registros, que pode ser uma composição da data, convertida em valor inteiro, um código que identifique a frota e outro que identifique o turno.

Além do código, deve-se incluir também a variável REM (Relação Estéril/Minério), calculada a partir das massas produzidas em cada turno. Essa variável destaca bem os turnos operados fora do padrão.

O banco de dados original possui uma série de variáveis que não agregam nenhum valor ao estudo e foram descartadas. Parte dessas variáveis entrou em desuso e parte trata-se de variáveis de quantidade de horas total do turno, que são redundantes, já que existem as mesmas variáveis descrevendo o tempo médio. A tabela 2 contém a lista dessas variáveis.

Tabela 2: Lista de variáveis que não agregam valor

Data (embutida no código)	Uso Efe. Otim.	Aguad. Desp. Vazio
Horas Disponíveis	Horas Manut.	HIO
HAO	Horas Ociosas	Horas Vazio
Horas Filas	Horas Manobra	Horas Cheio
Horas Basculam	Variáveis Otim	

Para possibilitar uma análise inicial dos dados contidos no banco fornecido, é necessário o cálculo da estatística descritiva e geração dos histogramas de todas as variáveis, tornando possível identificar dados, de cada variável, que fogem do comportamento do grupo (*outliers*). Esses dados configuram exceções à regra e podem influenciar indesejavelmente o resultado da análise, por isso são excluídos.

Para o caso das minas com diferentes frotas de caminhões, é perceptível que o tipo de caminhão é um fator de grande influência nos resultados obtidos. Como as variáveis analisadas são influenciadas pela capacidade e desempenho do caminhão, é natural que

caminhões de dimensões diferentes afetem os dados. Por isso é feita a divisão dos dados pelo tipo de caminhão, sempre confirmada pelos histogramas.

Após a eliminação de *outliers* e a separação por tipo de caminhão, quando necessária, é preciso identificar se existem outras separações naturais no conjunto de registros analisados. Para tanto, é utilizada a técnica de análise grupal ou análise de agrupamentos, que foi primeiramente apresentada por Tryon (1939).

A análise grupal tem como objetivo dividir os elementos da amostra em grupos, de forma que a semelhança entre os indivíduos de um mesmo grupo seja máxima, e a similaridade entre indivíduos de grupos diferentes seja mínima (Mingoti, 2005). O objetivo desta análise é descobrir agrupamentos naturais de variáveis, de acordo com suas similaridades.

Para determinar a semelhança entre dois dados, existem vários critérios. Ao considerarmos que cada dado amostral tem armazenado em um vetor informações de p-variáveis é possível definir e usar como critério a distância entre estes vetores.

A medida de semelhança utilizada para determinar a proximidade entre os elementos, selecionada para o presente estudo, é dada por:

$$\cos \theta_{jk} = \frac{\sum_{i=1}^p X_{ji} X_{ki}}{(\sum_{i=1}^p X_{ji}^2 \sum_{i=1}^m X_{ki}^2)^{1/2}}$$

onde, X_{ji} e X_{ki} são os i-ésimo e k-ésimo vetores, respectivamente, que contém as informações das p-variáveis e para os quais a distância será calculada.

Ao se adotar a correlação como medida de similaridade, temos que o cosseno do ângulo entre os vetores irá determinar o grau de semelhança entre as amostras. Quando o valor do cosseno é zero, não existe nada em comum entre as amostras. Se o cosseno for igual a um, as amostras são idênticas. Essa medida de similaridade, após alguns testes, foi a que melhor se aplicou ao caso.

No início do processo de agrupamento, o conjunto é composto por n (número de elementos) grupos. A cada iteração, esse número é reduzido até atingir o número k de grupos desejados. A escolha do número final de grupos ou *clusters* é subjetiva. O objetivo é encontrar o número de *clusters* que represente a ‘partição natural’ dos elementos comparados.

Para determinar a maneira que será feita a ligação entre os grupos foi escolhido o método de Ligação Simples, onde se define a similaridade dos conglomerados pelos elementos mais parecidos entre si. A equação que calcula a similaridade é:

$$d(C_i, C_j) = \min \left(d \left(\max \sum \sqrt{\sum (X_1, X_i)} \right) \right)$$

onde d é a distância entre os *clusters* e similaridade é a medida de semelhança entre os elementos.




Figura 3: Visualização em montanhas de exemplo de uma forte divisão em dois grupos

Cada conjunto de dados, separado anteriormente por tipo de caminhão, é analisado através pela análise de grupo. Após o estudo dos possíveis grupos e subgrupos contidos em cada um desses conjuntos, os dados são separados, criando-se um banco de dados para cada grupo definido.

Com os grupos definidos e separados, variáveis redundantes e variáveis influenciadas pela otimização, listadas na tabela 5, são retiradas do banco.

Tabela 3: Lista de variáveis que são retiradas do banco e o principal motivo da exclusão

Influenciada pela Otimização	Tempo Ciclo, Tempo Vazio, Tempos Fila, Distância Vazio, Velocidade Vazio, Massa Estéril, Massa Minério
Embutida na VCH	Produtividade, Produção, Carga Média, Hora Util Transp, Viagens
Embutida no T. Cheio	Distância Cheio, Velocidade Cheio
Não agrega valor	Hora Util Carga
Não normalizada	REM

Considerando que o objetivo é estimar o valor da variável VCH utilizando otimização, mas para períodos não otimizados, ou vice versa, é preciso encontrar aproximações de funções que considerem apenas variáveis que não possuam nenhuma influência da otimização. Caso isso não seja respeitado, as conclusões certamente serão equivocadas.

Após essa análise, a variável 'Tempo de Manobra' também foi descartada, por haver falhas na coleta de tal informação. Portanto, apenas as seguintes variáveis foram consideradas nas etapas seguintes deste estudo:

- Uso Global Otim %;
- VCH;
- T. Carga (min);
- T. Cheio (min);
- T. Basc (min);

Separação dos Registros

Os registros restantes após a criação de novos histogramas e a eliminação dos *outliers* são separados em otimizados e não otimizados. Para isso, é preciso determinar o ponto em que a utilização da otimização influencia de maneira significativa o valor de VCH.

Para se ter uma noção da variação da VCH de acordo com o percentual de otimização utilizado, é calculado, então, o valor acumulado de VCH, decrescendo o percentual de otimização. Sabe-se que não há precisão alguma nos resultados desse gráfico, porém esse é apenas orientativo, não alterando significativamente os valores finais.

O gráfico VCH_Acm x Uso_Otm é gerado e, a partir da análise desse, é decidido o ponto a partir do qual serão separados os registros otimizados. São considerados não otimizados os registros com 0% de uso da otimização e os demais registros são descartados. Esse percentual de corte deve ser um valor entre 30% e 70%, variando de acordo com a quantidade de dados disponíveis, a experiência prática e as possíveis conclusões retiradas da análise gráfica.

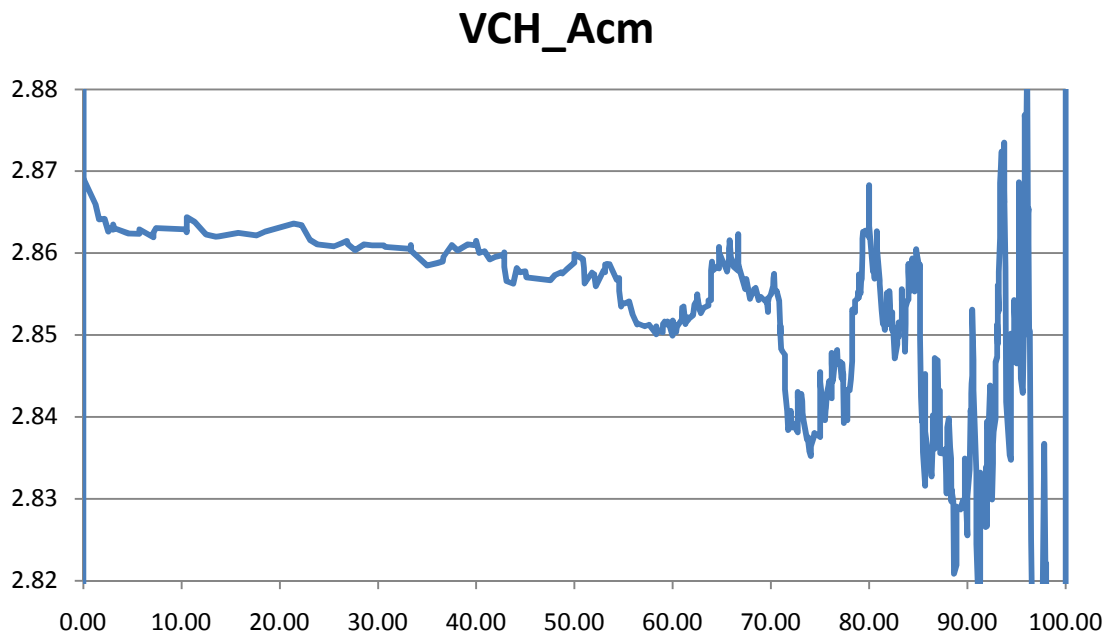


Figura 4: Gráfico V CH_Acm x Uso_Otm

Portanto, em um banco de dados teremos os registros com $Ot\%=0$ e no outro os dados com $Ot\%> corte$.

Para cada novo banco são gerados novos histogramas de cada variável, otimizado e não otimizado juntos, para que sejam realizados cortes até que os histogramas dos grupos menores estejam contidos nos histogramas dos grupos maiores. Estar contido significa dizer que os máximos e mínimos de um conjunto estão contidos entre os máximos e mínimos do outro, porém essa análise deve ir um pouco além desse conceito, visto que deve-se evitar que poucos registros gerem um modelo para estimar muitos resultados. Isso tornaria o modelo localmente, ou até globalmente, mal estimado, mas a análise deve variar caso a caso, efetuando cortes maiores quando possível e necessário. Esse passo é essencial para o bom funcionamento das

estimativas que serão apresentadas na próxima seção. A figura 5 mostra um exemplo desses histogramas.

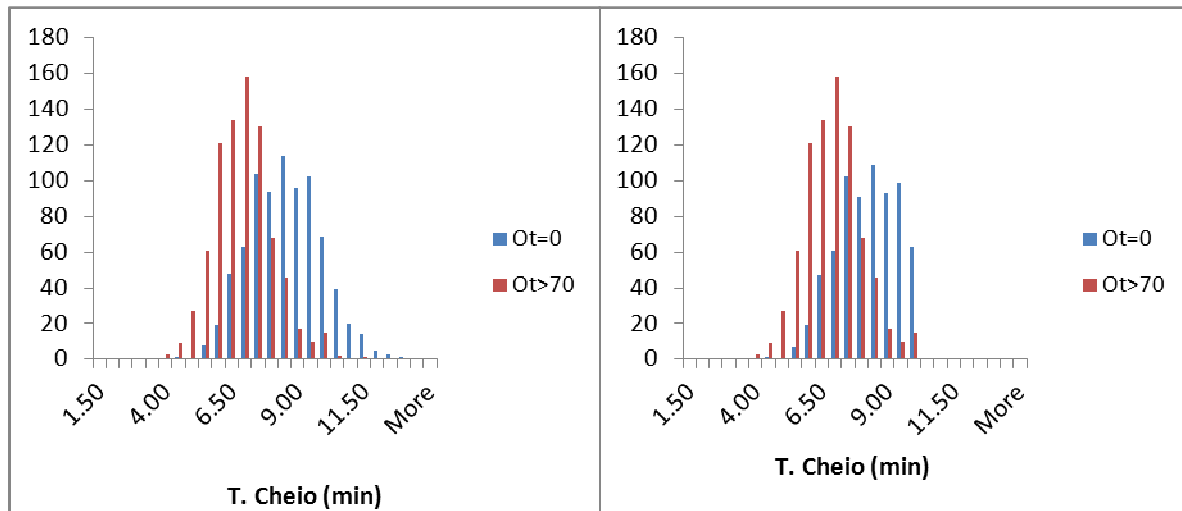


Figura 5: Histograma dos BD's Ot%=0 e Ot%>30 antes e depois dos cortes

Em alguns casos especiais, dependendo principalmente das médias, assimetrias e curtoses das distribuições, a decisão pode ser de estimar o grupo maior a partir do menor. Além disso, sempre que as distribuições permitirem, há preferência por estimar o grupo não otimizado, por não haver mistura de graus diferentes de otimização, fato que implica em alguma influência na estimativa. Para fins de descrição da metodologia no presente documento, fixou-se o caso em que o grupo maior estima o menor, mas fica registrada a necessidade de uma avaliação prévia.

Nas próximas seções serão apresentados os métodos utilizados para prever o valor de VCH. Partindo do maior banco, serão realizadas aproximações, através dos métodos de Redes Neurais (RN), Regressão Multivariável Global (RG) e Regressão Multivariada Local (RL). Em seguida, os modelos gerados serão aplicados aos registros do banco menor, estimando qual seria o resultado, caso o período não otimizado fosse otimizado, ou o contrário, dependendo de qual for o grupo maior.

Redes Neurais

O uso de redes neurais na aproximação de funções é extremamente indicado pois é possível estimar qualquer função não linear contínua (Suykens; Vandewalle; Joos; Moor, 1996), (Liu, 1996), (Graupe, 2007), apesar de apresentarem algumas restrições práticas (Haykin, 2001).

A modelagem do i -ésimo neurônio pode ser feita através das equações:

$$z_i = \sum w_{ij}x_j$$

$$y_i = F(z_i)$$

onde, z_i é a saída do neurônio, w_{ij} é o peso sináptico entre os neurônios i e j , x_j é a entrada do neurônio i e saída do neurônio j , y é a saída e F a função de avaliação. Para simplicidade na notação o peso sináptico $w_{k0}=b_k$ (bias) e $x_0=1$.

Uma rede neural é formada por vários neurônios artificiais que se conectam através de sinapses. Os neurônios possuem dados individuais (pesos e bias) que realizam operações sobre as entradas gerando uma saída que poderá servir de entrada para outro neurônio. Os parâmetros individuais dos neurônios podem ser ajustados através de treinamento.

Para treinar a rede neural utilizada na metodologia foi usado o método de Levenberg-Marquardt backpropagation, que pode ser resumido nos seguintes passos:

1. Obter uma atribuição inicial de pesos: o método de Levenberg-Marquardt é um aperfeiçoamento do método de Gauss-Newton (Gonçalves *et al.*, 2005) e portanto, partindo da solução para a equação 1 através do método de Gauss-Newton e usando a expansão de Taylor serão obtidas as equações 2 e 3

$$\nabla V(w) = 0 \quad (1)$$

$$\Delta V(w) = -[\nabla^2 V(w_0)]^{-1} \nabla V(w_0) \quad (2)$$

$$\Delta w = -[\nabla^2 V(w)]^{-1} \nabla V(w) \quad (3)$$

2. 2 - Atualizar os pesos e avaliar os erros, propagando os padrões: a partir das equações 2 e 3 é possível calcular a hessiana e o gradiente em função da matriz jacobiana de V

$$\nabla V(\bar{w}) = J^T(\bar{w}) \bar{e}(\bar{w})$$

$$\nabla^2 V(\bar{w}) = J^T(\bar{w}) + J$$

com

$$S = \sum e_i(\bar{w}) \nabla^2 e_i(\bar{w})$$

e a atualização dos pesos e a avaliação dos erros, respectivamente:

$$\Delta \bar{w} = -[J^T(\bar{w})J(\bar{w}) + \mu \text{diag}[J^T(\bar{w})J(\bar{w})]]^{-1} J^T(\bar{w}) \bar{e}(\bar{w})$$

$$V(\bar{w}) = \sum (e_i)^2(\bar{w})$$

- 3 Se houver acréscimo no erro, desfazer a atualização de z e decrementar; caso contrário, validar w e incrementar z .
- 4 4. Se convergir, interromper; caso contrário voltar ao item 2.

O tamanho da rede utilizada, bem como a taxa de validação e teste podem variar de acordo com a massa de dados que será analisada. Esta variação é subjetiva. A arquitetura da rede

pode ser observada na figura 6. Esta arquitetura foi escolhida por ser a mais eficiente na aproximação de funções.

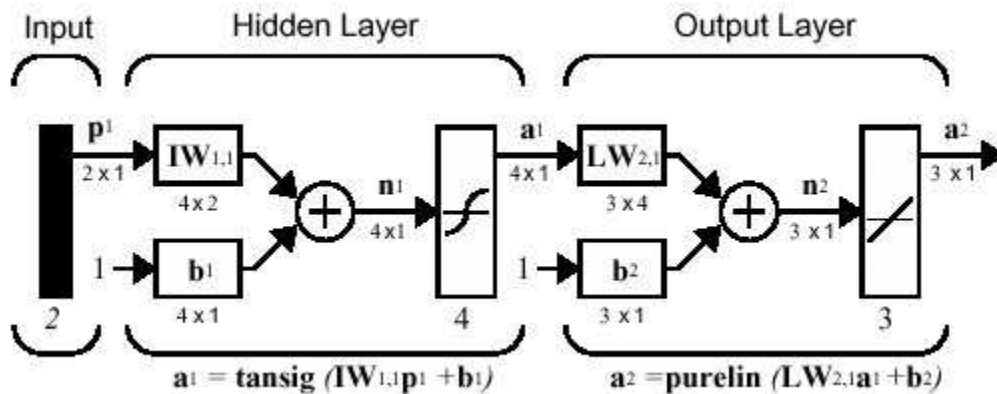


Figura 6: Arquitetura escolhida para a rede neural.

Após o treinamento da rede com o maior banco de dados, aplica-se a rede treinada ao menor, estimando, então, os ganhos com a aplicação da otimização através da variável VCH.

A qualidade da aproximação é registrada com o cálculo do R^2 e do desvio médio, que deve estar próximo de zero, indicando que desvios positivos estão compensando os negativos. Portanto, esse resultado mede se os dados foram super ou subestimados. Porém, vale frisar que as populações otimizada e não otimizada nem sempre possuem comportamento similar. Sendo assim, deve-se buscar o valor do desvio médio para a população estimada, caso contrário, pode-se obter resultados perfeitos com a população utilizada no treinamento, mas que não refletem a realidade da outra população, implicando em super ou subestimações não controladas.

Regressão Multivariada Global

A análise de regressão é uma técnica estatística popular na análise de dados. Um dos objetivos da análise de regressão é estimar e modelar a relação entre variáveis (Montgomery, Peck e Vining, 2001).

A forma de aplicação de tal metodologia deve ser muito cuidadosa, visto que busca-se uma equação linear para estimar fenômenos que não são necessariamente lineares. É muito comum regressões lineares atenderem bem a médias, mas subestimarem valores em uma região e superestimar em outra. De toda forma, essa serve como um guia, para aferir os resultados obtidos pelas redes neurais, visto que não é de se esperar diferenças absurdas entre os métodos.

A regressão linear multivariável envolve duas ou mais variáveis preditoras e uma variável dependente. Recebe esse nome devido ao caráter linear dos parâmetros b .

$$Y_c = a + b_1x_1 + b_2x_2 + \dots + b_kx_k + \epsilon_i \quad (4)$$

onde, a é intercepto do eixo y ; b_i o coeficiente angular da i -ésima variável; k o número de variáveis independentes $i=1, \dots, n$.

O componente de erro ϵ_i é aleatório, que segue distribuição normal com média zero e variância desconhecida normal, com distribuição σ^2 .

No problema estudado, as variáveis de tempo (cheio, carga e basculamento) serão usadas como variáveis predictoras x enquanto a variável VCH será Y .

O método dos mínimos quadrados pode ser usado para estimar os coeficientes da equação 4, que pode ser reescrita como:

$$y_i = \beta_0 + \sum \beta_j x_{ij} + \epsilon_i, i = 1, 2, \dots, n$$

A função de mínimos quadrados é dada por:

$$S(\beta_0, \beta_1, \dots, \beta_k) = \sum_{i=1}^n \epsilon_i^2 = \sum_{i=1}^n (y_i - \beta_0 - \sum_{j=1}^k \beta_j x_{ij})^2$$

E finalmente, na notação matricial, tem-se

$$y = X\beta + \epsilon$$

onde,

$$y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}, \quad X = \begin{bmatrix} 1 & x_{11} & x_{12} & \dots & x_{1k} \\ 1 & x_{21} & x_{22} & \dots & x_{2k} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & x_{n2} & \dots & x_{nk} \end{bmatrix}, \quad \beta = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{bmatrix} \text{ e } \epsilon = \begin{bmatrix} \epsilon_0 \\ \epsilon_1 \\ \vdots \\ \epsilon_k \end{bmatrix}$$

O objetivo é encontrar a matriz X tal que $\hat{\beta}$ seja o menor possível.

$$\hat{\beta} = (X'X)^{-1}X'y$$

O índice de confiança deste método pode ser calculado através da equação:

$$IC(95\%, \beta_j) = \hat{\beta}_j \pm t_{(\alpha/2, n-p)} \sqrt{\hat{\sigma}^2 C_{jj}}$$

Algumas variáveis podem não exercer influência na determinação do VCH. Uma das formas de determinar quais variáveis devem ser excluídas é avaliando o *P-value* (probabilidade estimada) obtido através da regressão. Caso isso ocorra, a variável em questão deve ser excluída e a regressão refeita.

A fórmula obtida através da regressão será aplicada ao banco de dados menor, avaliando então o ganho da otimização.

Finalmente, o mesmo estudo dos desvios, aplicado às redes neurais, deve também ser feito aqui.

Regressão Multivariada Local

A Regressão Global pode levar a estimativas pouco precisas em alguns pontos, justificando-se a calibração de coeficientes específicos para diferentes regiões do espaço, o que significa fazer uma estimativa localizada (Allen, 1974) (Cleveland e Devlin, 1988) (Cleveland; Grosse e Shyu, 1993) (Loader, 1999).

Nem sempre os resultados dessa metodologia são confiáveis, visto que o refinamento para a região de maior concentração de dados pode obrigar a eliminação de boa parte dos registros, reduzindo a representatividade do resultado final. Em casos nos quais os dados otimizados estão deslocados dos não otimizados, essa análise torna-se ainda mais perigosa, se não for feita com muito critério e, até mesmo, desconsiderada em alguns casos.

Para obter uma massa mais homogênea de dados, são realizados cortes iguais nos bancos de dados (otimizado e não otimizado) até que ambos possuam um comportamento semelhante.

Esse é o único passo adicional específico à essa metodologia. Após isso, deve-se repetir os mesmos passos apresentados da Regressão Global

Cálculo de Ajustes

As análises de variáveis e as estimativas de ganhos são capazes de indicar qual variável é a maior responsável pelo valor do VCH, que será a variável mais influente no cálculo dos ajustes. Nesse caso, a variável TCheio será sempre a mais representativa.

Para cada classe obtida na etapa de análise dos histogramas da variável TCheio, são calculados os desvios relativos para os dados da faixa. Os desvios definidos por classe passam a ser adotados também para a população estimada. O desvio médio final é calculado pela média ponderada dos desvios pela quantidade de registros em cada uma das classes da população estimada. As figura 7 mostra um exemplo do cálculo dos desvios para o método de redes neurais.

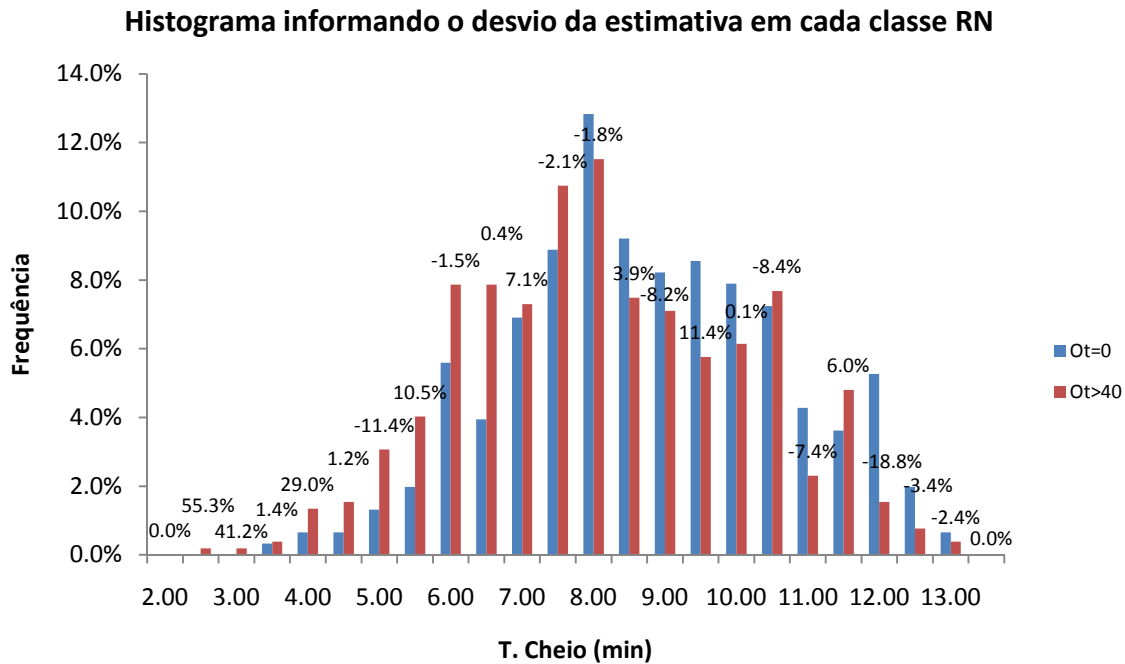


Figura 7: Histograma da variável TCheio com os desvios relativos de cada classe para o método RN.

Considerando que busca-se obter uma metrificação adequada, evitando desvios que super ou subestimem os ganhos finais estimados, deve-se subtrair os desvios encontrados dos ganhos obtidos diretamente pelos métodos, obtendo-se, assim, a compensação de desvios positivos e negativos.

Por exemplo, supondo que foi obtido ganho de 10,0%, com desvio de 0,5%, isso significa que os resultados estão sendo, em média, superestimados em 0,5%. Portanto o ganho médio de 10% é falso, sendo mais adequado adotar o valor final de 9,5% (10,0 - 0,5).

RESULTADOS E CONCLUSÕES

Após obter os resultados através das estimativas são calculados os percentuais de ganho da situação otimizada em relação à não otimizada. O percentual de ganho médio é calculado, bem como o valor do ajuste de cada estimativa, e, então, é possível calcular o ganho total para cada caso.

Os resultados, assim como os ajustes obtidos, devem ser tabulados e, então, os resultados finais serão obtidos pela média dos ganhos ponderada pela produção total de cada conjunto de registros, de acordo com os grupos definidos nas etapas anteriores.

Para definição do método que será aceito como resultado final, deve-se calcular as variâncias dos desvios obtidos. Essa análise depende de vários fatores, mas, se tais fatores envolvidos estiverem em iguais condições, o resultado aceito será aquele com menor variância. De toda forma, vale frisar que os ajustes feitos anteriormente visam evitar super ou subestimação do resultado final, sendo a variância vista apenas como um critério de desempate.

A regressão multivariada linear, por definição, calcula os valores de maneira que a média dos erros seja zero, para os registros utilizados no modelo, já o método de redes neurais não possui essa preocupação e portanto, será preciso observar o erro médio do método RN e, se necessário, realizar novos treinamentos para a rede neural, obtendo desvios próximos a zero, de forma que os erros positivos compensem os negativos. Tendo atenção nessa etapa, evita-se ajustes maiores nas etapas seguintes, quando busca-se erro médio zero para a população estimada.

O método de RN é considerado mais aplicável a esse caso por ser capaz de estimar melhor funções não lineares (Gonçalves *et al.* 2005). Nos três métodos é importante traçar um gráfico Real x Estimado e incluir uma reta de regressão, a fim de se comparar os R^2 obtidos, além do cálculo das variâncias e desvios propostos. Eventualmente, o R^2 da RL pode ser maior que o da RN, e/ou as variâncias menores, mas esta, em geral, ainda é preferida por conter uma quantidade maior de registros.

REFERÊNCIAS BIBLIOGRÁFICAS

Alarie, S.; Gamache, M. (2002). Overview of solution strategies used in truck dispatching systems for open pit mines. *International Journal of Surface Mining, Reclamation and Environment*, v. 16, p.59-76.

Allen, D. M. (1974). The relationship between variable and data augmentation and method of prediction. *Technometrics*, v. 16, p. 125-127.

Cleveland, W. S. and Devlin, S. J. (1988). Locally weighted regression: An approach to regression analysis by local fitting. *Journal of the American Statistical Association*, 83:596-610.

Cleveland, W. S.; Grosse, E., and Shyu, W. M. (1993). Local regression models. In Chambers, J. M. and Hastie, T. J., editors, *Statistical Models in S*, chapter 8, pages 309-376. Chapman & Hall, New York.

Costa, F. P.; Souza, M. J. F. e Pinto, L. R. (2004). Um modelo de alocação dinâmica de caminhões, *Revista Brasil Mineral*, v. 231, p. 26-31.

Graupe, D. (2007). *Principles of Artificial Neural Networks*. [S.l.]:World Scientific Publishing Co. Pte. Ltd.

Gonçalves, H. I. V.; Coimbra, R. C. M.; Ladeira, M. e Prado, H. A. (2005) Ferramenta de Regressão Não-linear Múltipla com Redes Neurais Artificiais. [online] <www.sbc.org.br/bibliotecadigital/download.php?paper=388>

Haykin, S. S. (2001). *Redes Neurais: Princípios e Prática*. [S.l.]: Bookman. (Tradução de Paulo Martins Engel).

Liu, Y. (1996). Calibrating an industrial microwave six-port instrument using artificial neural network technique. *IEEE Trans IM*, v. 45, p. 651-656.

Loader, C. R. (1999). *Local Regression and Likelihood*, New York: Springer

Merschmann, L. H. C. (2002) Desenvolvimento de um sistema de otimização e simulação para análise de cenários de produção em minas a céu aberto. Dissertação de mestrado, Programa de Engenharia de Produção/COPPE/UFRJ, Rio de Janeiro.

Mingoti, S. A. (2005). Análise de Dados Através de Métodos de Estatística Multivariada: Uma Abordagem Aplicada. [S.l.]: Editora UFMG, p..

Montgomery D. C.; Peck, E. A.; Vining, G. G. (2001). Introduction to Linear Regression Analysis, Wiley Series in Probability and Statistics: Texts, References and Pocketbooks Section. [S.l.]: Wiley-Interscience.

Pinto, L. R. e Merschmann, L. H. C. (2001) Planejamento operacional da lavra de mina usando modelos matemáticos. Revista Escola de Minas, v. 54, n. 3, p. 211-214.

Pinto, L. R.; Biajoli, F. L. e Mine, O. M. (2003) Uso de otimizador em planilhas eletrônicas para auxílio ao planejamento de lavra. Relatório técnico, Programa de Pós-graduação em Engenharia Mineral, Universidade Federal de Ouro Preto, Ouro Preto, Minas Gerais.

Suykens, J. A.; Vandewalle; Joos, P. L.; Moor, B. L. (1996). Artificial Neural Networks for Modelling and Control of Non-Linear Systems.

Tryon, R. C. (1939). Cluster analysis. New York: McGraw-Hill.