



UTILIZAÇÃO DE REDE NEURAL ARTIFICIAL PARA PREDIÇÃO DA QUALIDADE DO EFLUENTE TRATADO DE UMA FÁBRICA DE CELULOSE KRAFT

Caux, L. S, Dias, F. V., Machado, G. F. M, Sá, E. R., Oliveira, V. C, Dalvi, L. C.



“Encontrar a harmonia entre o processo industrial e o ecossistema é um dos caminhos para a ecoeficiência”

Para isso...

precisamos de um adequado sistema de mitigação de impactos e...

capacidade para antecipar os problemas



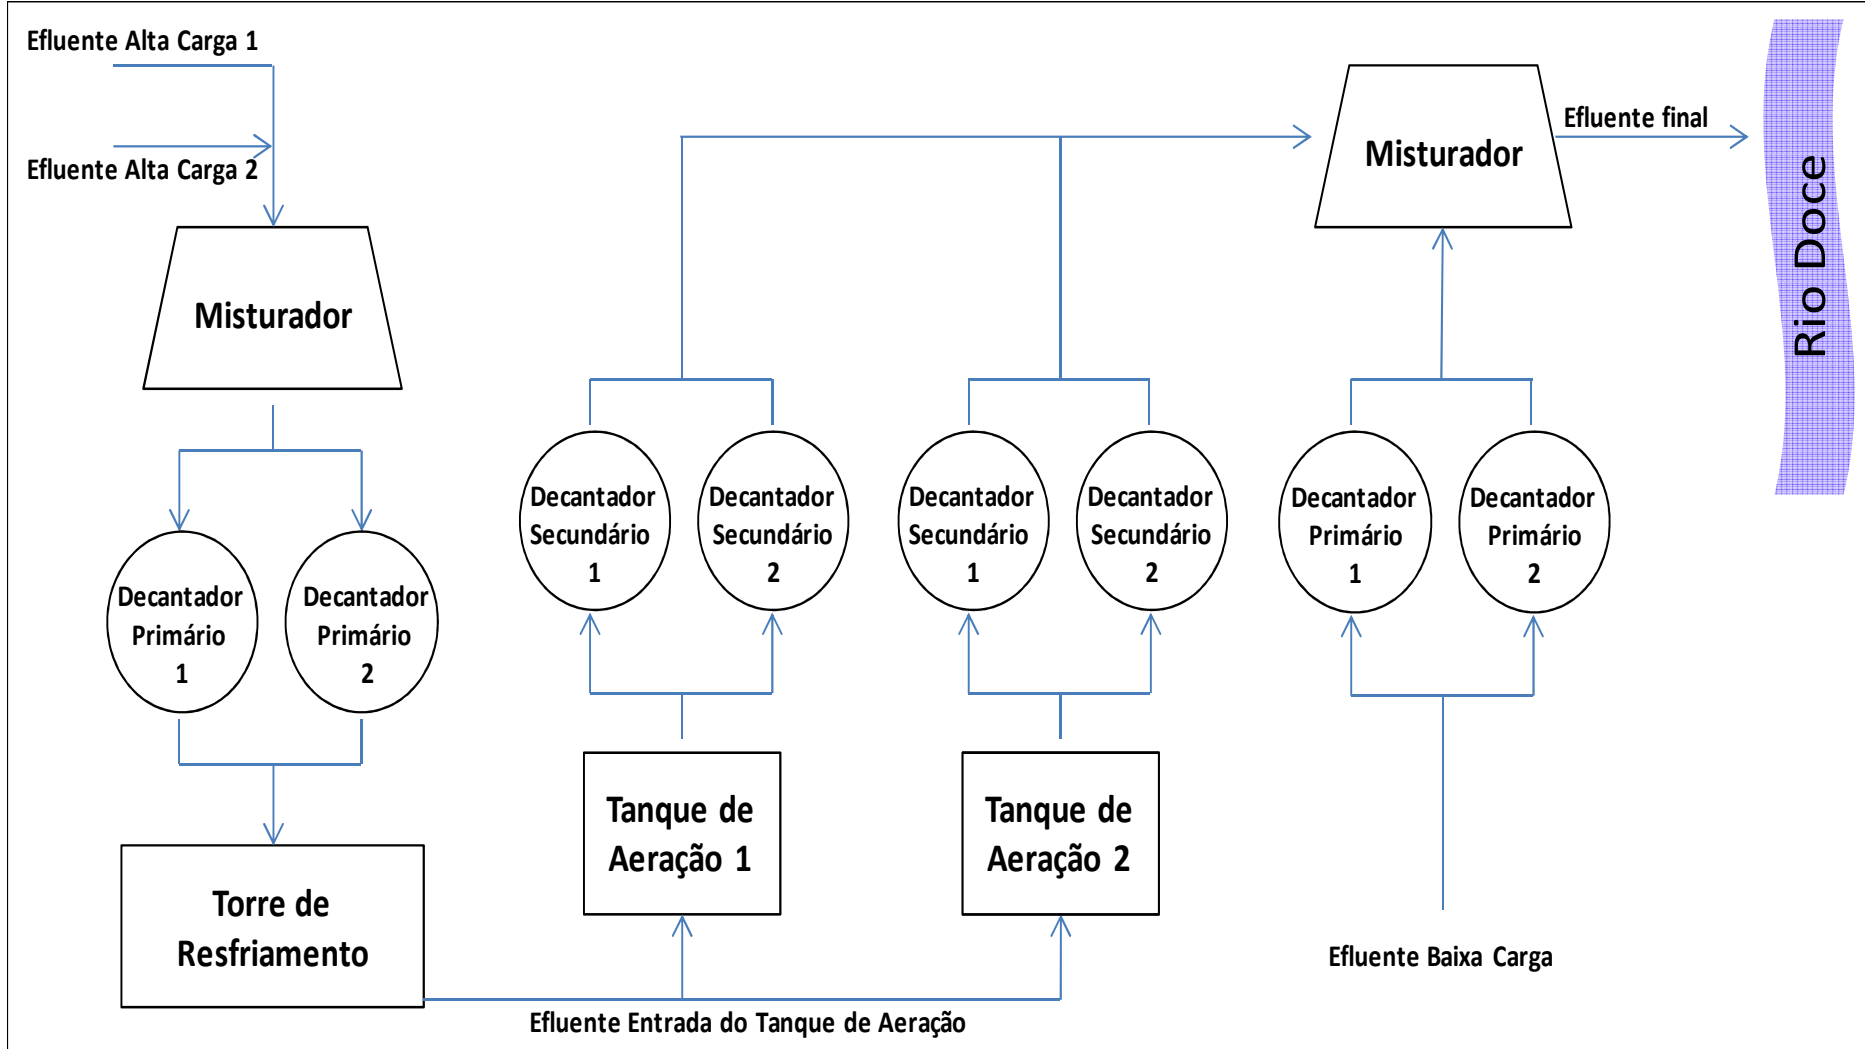
“A CENIBRA é uma fábrica de celulose Kraft branqueada de Eucalipto localizada no estado de Minas Gerais na Bacia Hidrográfica do Rio Doce”

“Que representa aproximadamente 15% do PIB de Minas Gerais”



CENIBRA

- 1.200.000 t/ano de celulose kraft branqueada (ECF) de Eucalipto;
- Captação de $\sim 6000 \text{ m}^3/\text{h}$;
- Efluente $\sim 5500 \text{ m}^3/\text{h}$;
- De acordo com a Deliberação Normativa Conjunta COPAM/CERH-MG nº 01, de 05 de maio de 2008, o efluente de fabricação de celulose somente poderá ser lançado em corpos hídricos após tratamento com média anual inferior a 15 Kg.tsa^{-1} de DQO;
- Tratamento biológico por lodo ativado;







O monitoramento do efluente na alimentação da estação de tratamento representa uma estratégia operacional importante;





2011 - Alternativa para controle operacional da ETE através dos resultados de DQO e DBO obtidos em analisador *on line* de TOC;


- Elevado tempo de execução das análises em laboratório;
- Taxa de amostragem insuficiente para atender as necessidades operacionais;
- Instabilidade de dosagem de nutrientes;



T.O.C, mg.L⁻¹ vs. D.Q.O, mg.L⁻¹

$$Y = 95,2339 + 2,2526*x$$

p<0,05 ; R = 0,983




Passos iniciais

TOC, mg.L⁻¹ vs. DBO₍₅₎, mgO₂.L⁻¹

$$Y = 48,7158 + 0,3121*x; 0,95 \text{ Pred.Int}$$

p < 0,05, R² = 0,9251



Para automação
do sistema




Antecipação...

- Por se tratar de um sistema biológico, as estações de tratamento de efluentes por lodos ativados apresentam alguns desafios;
- Muitos modelos estatísticos são utilizados na otimização destes processos
 - Séries temporais;
 - Modelos de regressão;



Redes Neurais

- As redes de múltiplas camadas (MLP – *Multilayer Perceptron*) têm sido utilizadas com sucesso na modelagem de sistemas de tratamento de efluentes ;





Metodologia

- Variáveis de entrada:
 - $DQO_e; T_e; Ss_e; SST_e; Q_e;$
 - $Tr; \Theta_c; OD;$
 - $P;$
 - $DQO_{BC}; T_{BC}; Ss_{BC}; SST_{BC};$
- Variáveis de saída:
 - $DQO_f; T_f; SST_f;$
- Amostragem;
 - Dados históricos nos sistemas corporativos;
 - ERP;
 - Pims;



Metodologia

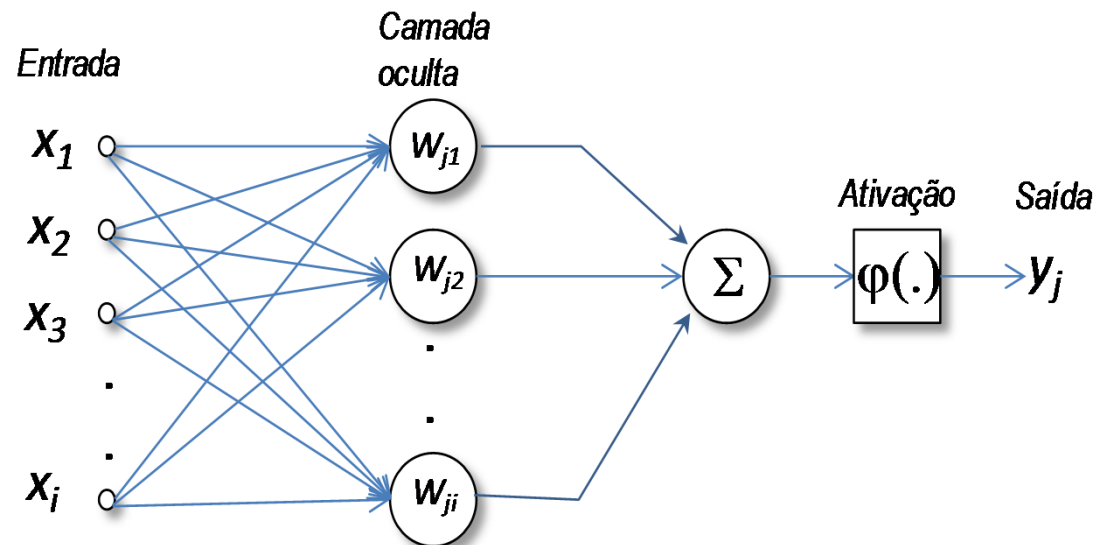
- Remoção dos *outliers*;
$$\mu - 3\sigma < X_i < \mu + 3\sigma$$
- Avaliação estatística
 - Análise descritiva;
 - Agrupamentos (*Cluster*)
 - Componentes principais (PCA).
- Para a análise multivariada os dados foram previamente normalizados;

$$Z_i = \frac{(X_i - \mu)}{\sigma}$$



Metodologia

- O modelo de rede
 - MLP com uma camada de entrada, uma camada de neurônios ocultos e uma camada de saída e alimentação em único sentido (*feedforward*);





Metodologia

- Foram treinadas 5000 redes com mínimo de 5 e máximo de 20 neurônios na camada oculta;
- Foram retidas as cinco melhores RNAs
 - O erro da rede foi computado pela soma de quadrados;

$$Err = \sum_{i=1}^N (y_i - t_i)^2$$



Metodologia

- A função de ativação foi definida pelo *software* e ajustada de acordo com desempenho durante o treinamento;

<i>Identidade:</i>	$a; (-\infty, \infty)$
<i>Logística:</i>	$\frac{1}{1+e^{-a}}; (0,1)$
<i>Tangente hiperbólica:</i>	$\frac{e^a+e^{-a}}{e^a-e^{-a}}; (-1,1)$
<i>Exponencial:</i>	$e^a; (0, \infty)$
<i>Seno:</i>	$\text{sen}(a); [0,1]$
<i>Softmax:</i>	$\frac{e^{ai}}{\sum e^{ai}}; [0,1]$
<i>Gausiana:</i>	$\frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$




Resultados

Variável	Média	Mínimo	Máximo	Desvio Padrão
$DQO_e, \text{mg.L}^{-1}$	965,8	594,0	1356,0	133,3
$DQO_{BC}, \text{mg.L}^{-1}$	112,1	40,0	189,0	26,4
$DQO_f, \text{mg.L}^{-1}$	218,0	104,0	361,0	48,1
$Q_e, \text{m}^3.\text{h}^{-1}$	3389	1968	4518	483
$Q_{BC}, \text{m}^3.\text{h}^{-1}$	1758	1065	2445	242
$Q_f, \text{m}^3.\text{h}^{-1}$	5197	3647	6557	526
$Ss_e, \text{mg.L}^{-1}$	18,2	1,0	63,0	15,3
$Ss_{BC}, \text{mg.L}^{-1}$	10,4	2,0	26,0	5,5
$Ss_f, \text{mg.L}^{-1}$	0,4	0,0	1,0	0,2
$SST_e, \text{mg.L}^{-1}$	109,2	35,5	219,0	36,8
$SST_{BC}, \text{mg.L}^{-1}$	268,4	37,1	575,0	107,7
$SST_f, \text{mg.L}^{-1}$	46,6	10,4	87,0	14,7
$T_e, ^\circ\text{C}$	36,3	32,8	40,0	1,2
$T_{BC}, ^\circ\text{C}$	34,6	31,2	37,4	1,2
$T_f, ^\circ\text{C}$	36,4	32,3	39,9	1,4
tr, h	20,3	15,3	27,8	2,5
$P, \text{tsa.h}^{-1}$	147,3	124,8	162,3	7,9
OD, mg.L^{-1}	2,3	0,0	4,6	0,8
Θ_c, dias	4,7	2,9	7,2	0,9

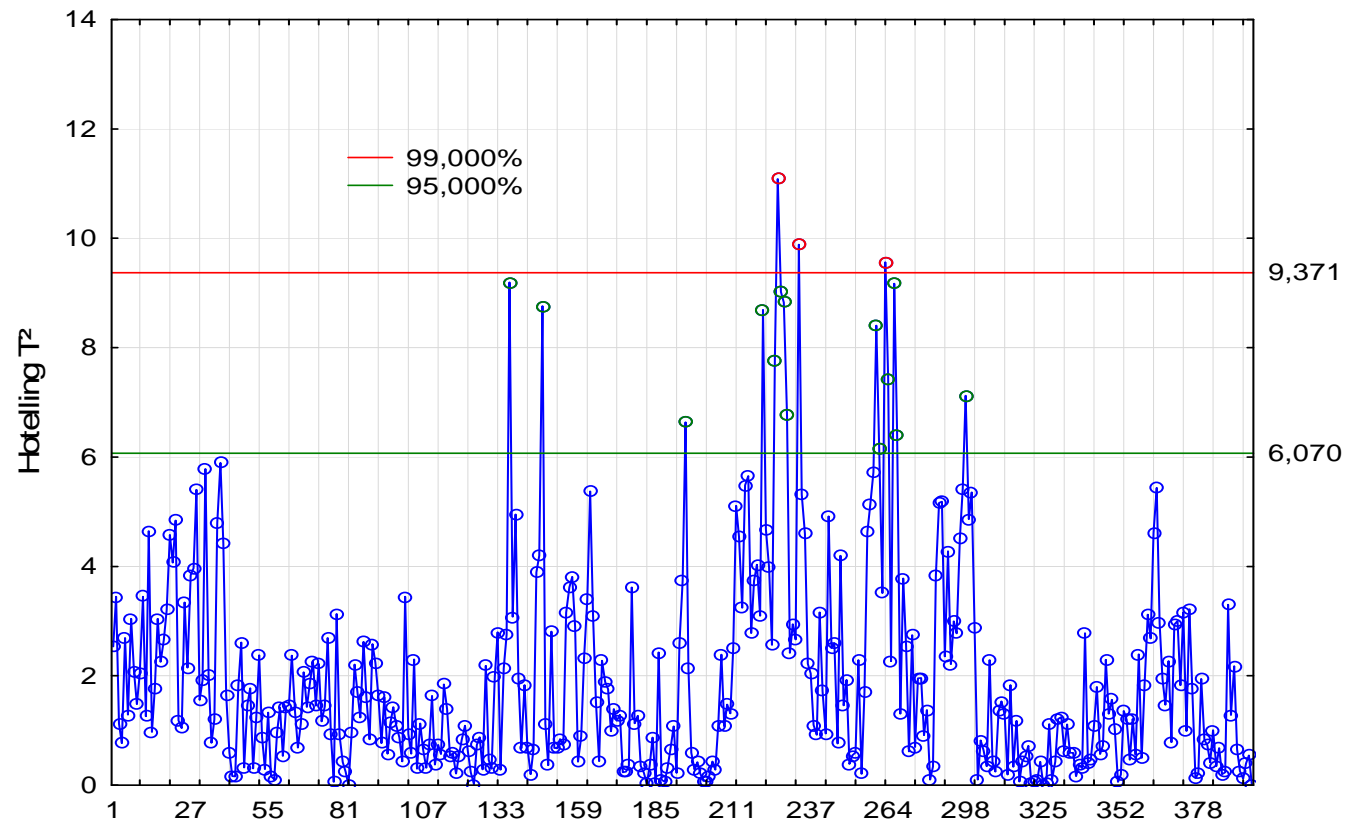


Resultados PCA







Resultados





Resultados



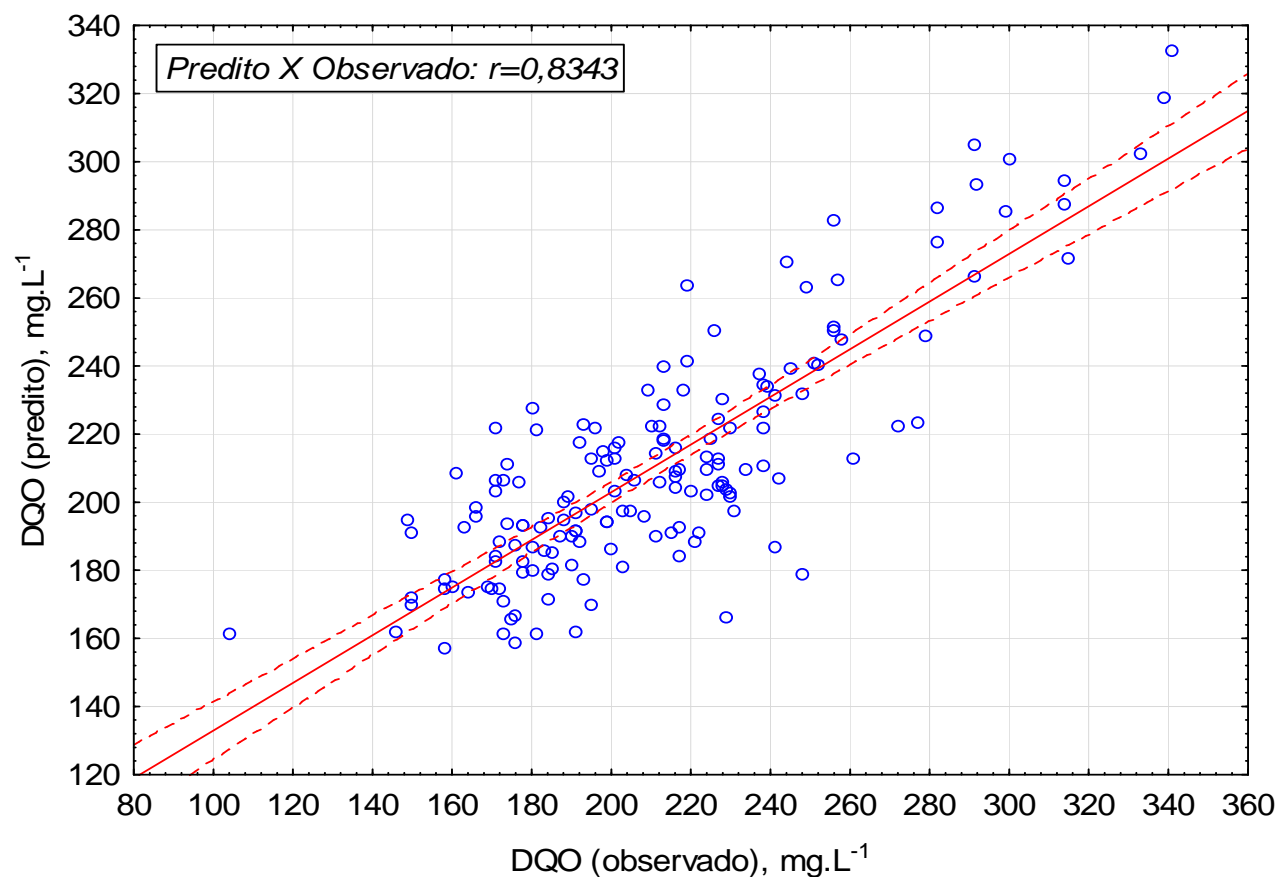


Resultados

Predição da DQO


DQO_e, Q_e, Q_{BC}, Ss_e, SST_e, T_e, OD, θ_c , tr e P

MLP 11-19-1





Resultados Predição da DQO



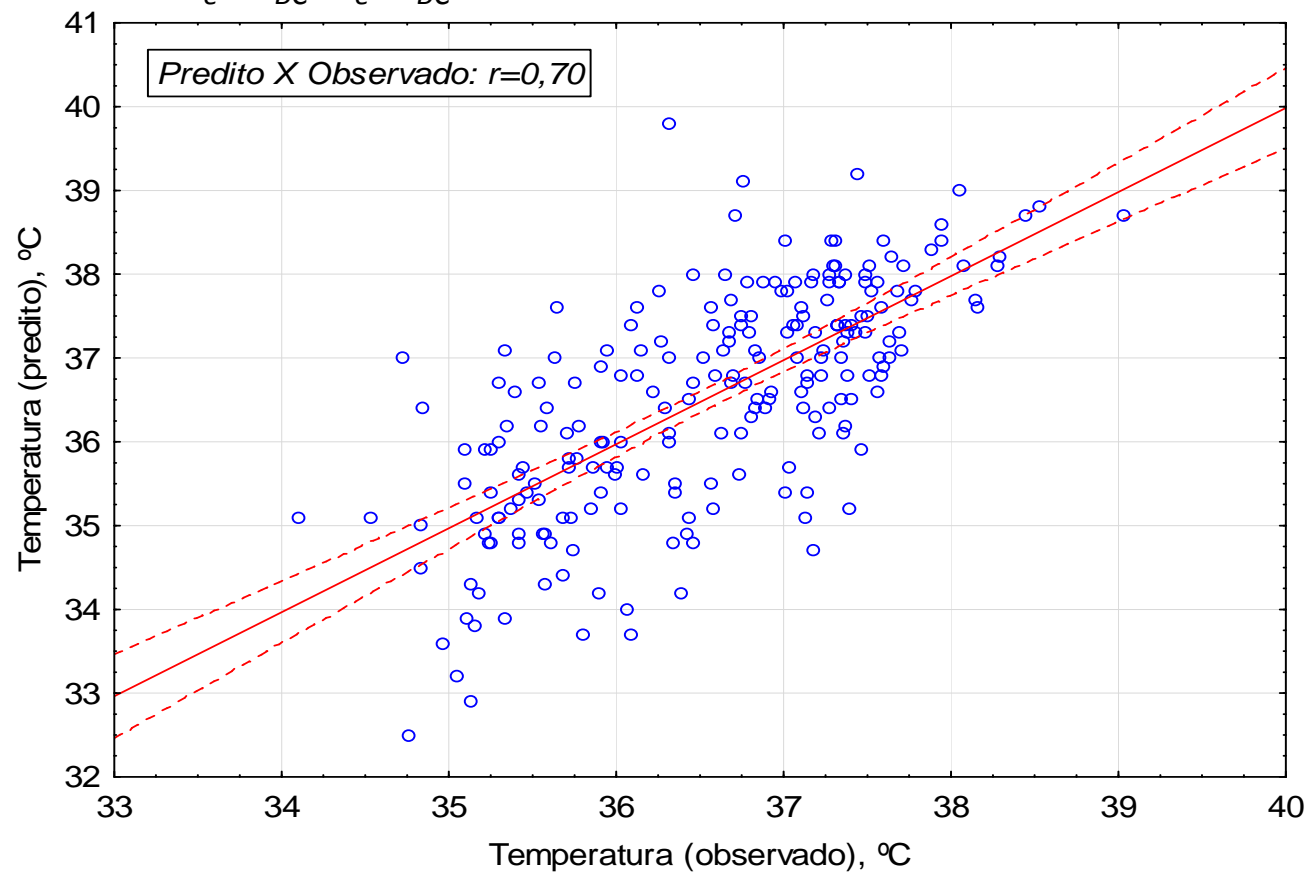


Resultados

Predição da temperatura

$Q_e, Q_{BC}, T_e, T_{BC}, tr$ e P


MLP 6-8-1





Resultados

Predição da temperatura



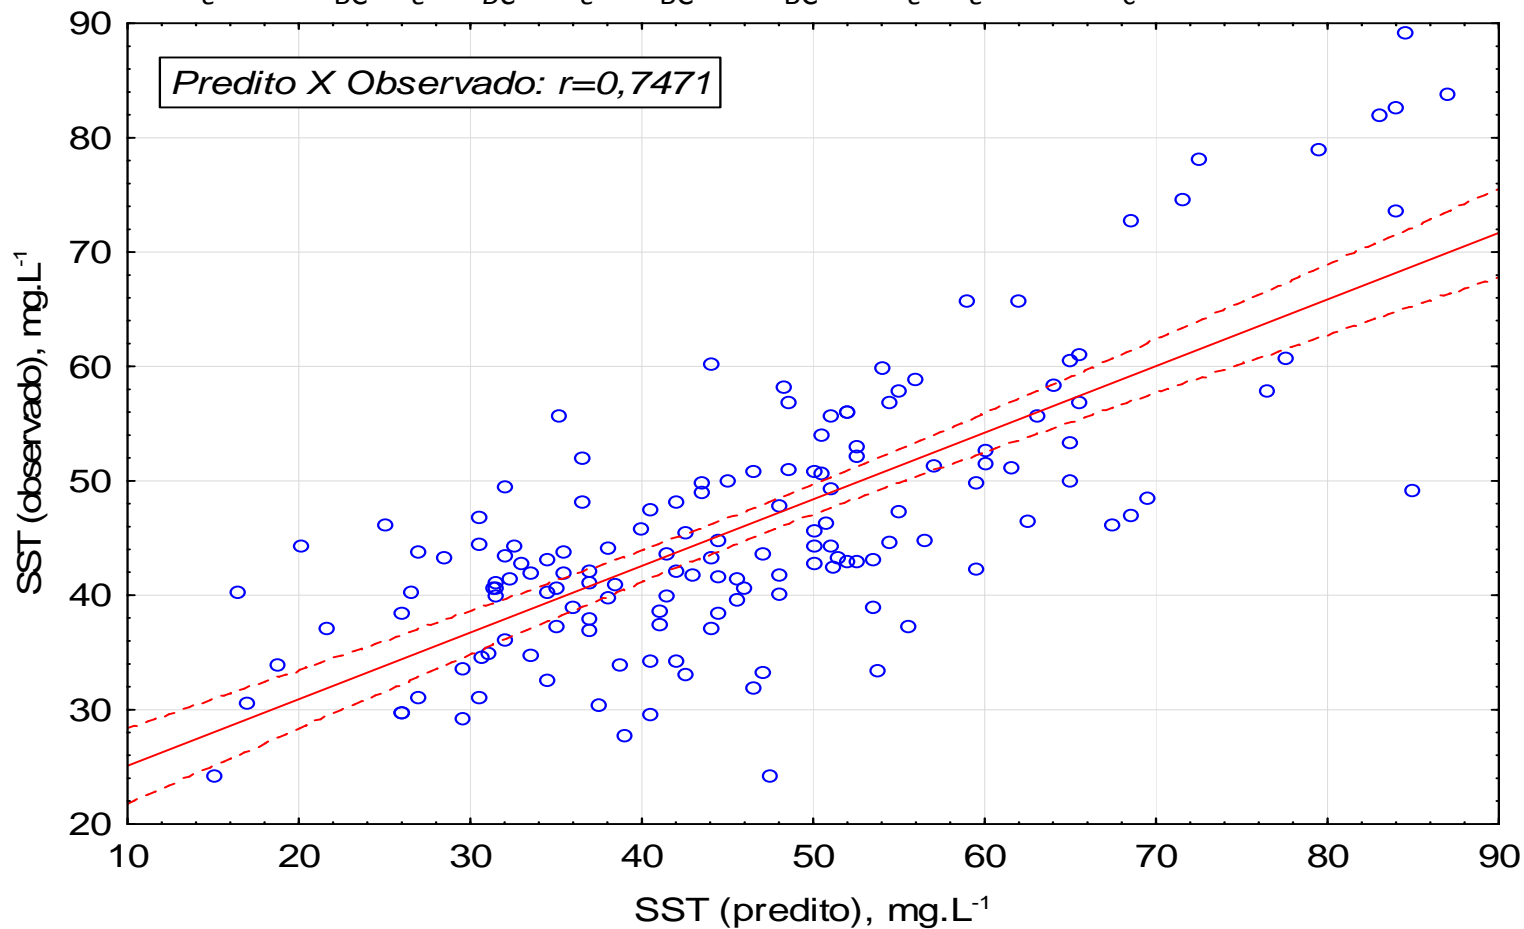


Resultados

Predição SST


DQO_e , DQO_{BC} , Q_e , Q_{BC} , SS_e , SS_{BC} , SST_{BC} , SST_e , T_e , OD , Θ_c , tr e P

MLP 13-11-1





Resultados Predição SST





- Os parâmetros selecionados são típicos da legislação ambiental vigente e foram cristalizados nos programas de automonitoramento das empresas de Minas Gerais;
- É importante destacar a dificuldade de predição, e a significância ambiental, de dois deles: DQO e SST;
 - O primeiro por não serem conhecidos todos os mecanismos envolvidos em sua remoção;
 - O segundo por haver hipóteses de ser claramente influenciado por variáveis essencialmente biológicas, sendo a toxicidade a mais obscura delas;



Conclusão

- Os modelos apresentaram excelente desempenho no treinamento e validação externa;
- A produção de celulose (P) foi utilizada em todos os modelos como variável de, demonstrando a relação direta do processo com a qualidade do efluente;



Conclusão

- Os algoritmos obtidos podem ser implementados para predição dos resultados de DQO e SST do efluente final com elevado grau de confiança e aproximadamente 20 horas de antecedência;
- A temperatura do efluente final também pode ser predita com a mesma antecedência se a temperatura do efluente de baixa carga for considerada como uma variável categórica;



Realização
Arranged by

Correalização
Co-sponsor



Obrigado