

7 RESULTADOS E ANÁLISE

7.1. Introdução

Na Tabela 4 pode ser observado um resumo das camadas e épocas utilizadas no treinamento da rede neural. Como pode ser visto, para emissões de CO, NO_x e HC e também para o consumo de diesel foram empregadas as funções de ativação Tansig e Logsig, respectivamente para as camadas de entrada e escondida. Para a temperatura de escapamento e rendimento térmico, as funções de ativação Tansig e Purelin, respectivamente para a camada de entrada e escondida. É possível observar que o consumo de diesel foi a variável que teve menor quantidade de neurônios na camada escondida: 14 neurônios no caso A e 10 neurônios no caso B. As variáveis que tiveram maior número de neurônios tiveram 24 neurônios no caso A e 28 neurônios no caso B, porém em diferentes variáveis. No caso A foi a temperatura de escapamento e no B as emissões de NO_x, respectivamente. Analisando a quantidade de épocas, a menor foi de 13 e a maior de 443 épocas, para as variáveis de consumo de diesel (caso B) e temperatura de Escape (caso A) respectivamente. Portanto, pode-se dizer que são necessários menos neurônios e menos épocas para o caso A, quando comparado com o caso B.

Tabela 4. Camadas e Épocas utilizadas na rede neural.

Variáveis	CAMADA ENTRADA - ESCONDIDA	CAMADA SAÍDA - ESCONDIDA	CAMADA ESCONDIDA		ÉPOCAS	
			Caso A	Caso B	Caso A	Caso B
Emissões de CO	Tansig	Logsig	22	26	51	254
Emissões de No _x	Tansig	Logsig	18	28	196	31
Emissões de HC	Tansig	Logsig	14	20	84	135
Temp. de Gases de Escapamento	Tansig	Purelin	24	20	443	358
Consumo de diesel	Tansig	Logsig	14	10	13	177
Rendimento Térmico	Tansig	Purelin	22	24	68	296

Caso A: incluindo dados de consumo de combustível 100% de diesel

Caso B: sem incluir dados de consumo de combustível 100% de diesel

Na Tabela 5 podem ser observados os resultados segundo as métricas de avaliação dos erros RMSE, MAPE e COEFICIENTE DE CORRELAÇÃO.

Analisando o MAPE do treinamento para o caso A, pode-se observar que os erros variam entre 1,24% e 12,19%, onde o maior MAPE (12,19%) é para o caso de emissões de CO e o menor (1,24%) é para a variável de temperatura de gases de escapamento.

Analisando o MAPE de treinamento para o caso B: os erros variam entre 0,79% (temperatura de gases de escapamento) até 9,47% (emissões de HC).

Analisando o MAPE de validação para o caso A: que os erros variam de 1,79% até 14,56%, onde o maior MAPE encontrado no treinamento foi de 14,56% para o caso de emissões de CO e o menor, de 1,79%, para a variável de Rendimento Térmico.

Analisando o MAPE de validação para o Caso B verifica-se que os erros variam de 1,28% a 9,92%, onde o maior MAPE encontrado no treinamento foi para o caso de Emissões de HC e o menor para a variável de Rendimento Térmico.

Esta análise do MAPE é muito importante, pois avalia o treinamento com valores nunca usados para treinamento ou validação.

Analisando o MAPE do teste para o caso A tem-se: os erros variam de 1,94% até 20,15%, onde o maior valor encontrado no treinamento foi para o caso de Emissões de CO e o menor, para a variável de rendimento térmico.

Por fim, analisando o MAPE do teste, para o caso B verifica-se que os mesmos variam de 1,28% até 10,26%, onde o maior valor também está relacionado às emissões de CO e o, neste caso, está associado à temperatura dos gases de escapamento.

As correlações não foram analisadas porque todas estão muito perto de um, ou seja, todas apresentam uma forte relação entre as variáveis experimentais e as variáveis geradas pela rede neuronal.

A maior porcentagem de erro acontece sempre nas emissões de CO, enquanto a menor varia entre o rendimento térmico e a temperatura de gases de escapamento. Note que esta variáveis estão fortemente correlacionadas na prática. Quanto maior o rendimento térmico, menores as temperaturas de saída dos gases, pelo maior aproveitamento do calor para a realização de trabalho.

Tabela 5. Coeficientes RMSE, MAPE e correlação.

Variáveis	RMSE		MAPE		CORRELAÇÃO	
	Caso A	Caso B	Caso A	Caso B	Caso A	Caso B
TREINAMENTO						
Emissões de CO	73,69	56,90	12,19	4,03	0,99	0,99
Emissões de NO _x	36,95	50,24	4,40	4,19	0,99	0,98
Emissões de HC	273,99	296,30	3,10	9,47	1,00	0,99
Temp. Gases de esc.	5,92	3,99	1,24	0,79	1,00	0,99
Consumo de diesel	0,24	0,20	8,06	6,81	1,00	0,99
Rendimento Térmico	0,36	0,33	1,33	1,10	1,00	0,99
VALIDAÇÃO						
Emissões de CO	147,14	132,05	14,56	9,24	0,98	0,97
Emissões de NO _x	50,67	31,43	5,99	4,25	0,98	0,99
Emissões de HC	526,78	396,05	4,63	9,92	0,99	1,00
Temp. Gases de esc.	10,51	6,17	2,43	1,43	0,99	1,00
Consumo de diesel	0,27	0,16	9,97	5,45	1,00	1,00
Rendimento Térmico	0,61	0,38	1,79	1,28	1,00	1,00
TESTE						
Emissões de CO	174,74	160,60	20,15	10,26	0,97	0,97
Emissões de NO _x	118,55	116,75	10,89	5,17	0,88	0,96
Emissões de HC	785,99	533,59	5,41	8,96	0,99	0,99
Temp. Gases de esc.	10,01	6,09	2,06	1,28	0,99	1,00
Consumo de diesel	0,25	0,17	7,60	4,63	1,00	1,00
Rendimento Térmico	0,62	0,41	1,94	1,42	1,00	1,00

Caso A: incluindo dados de consumo de combustível 100% de diesel

Caso B: sem incluir dados de consumo de combustível 100% de diesel

A Tabela 6 apresenta os resultados dos cálculos gerais segundo as métricas dos coeficientes de determinação, coeficiente de correlação, U-THEIL, MSE, NRMSE e MAD. Uma análise sobre o U-THEIL será realizada, já que este fornece um valor mais claro quanto ao ajuste da série prevista à série original.

Para o caso A, segundo U-Theil, têm-se valores muito pequenos (menores que um), portanto verifica-se um melhor ajuste da série prevista em relação à série original. Os valores de U-Theil variam entre 0,06 e 0,19, para o consumo de diesel e temperatura de escapamento respectivamente.

Também para o caso B, segundo U-Theil, têm-se valores muito pequenos (menores que um), significando um bom ajuste da série prevista em relação à série original. Similar ao caso anterior, os valores variam de 0,05 a 0,21. Neste caso o menor valor também é referente ao consumo de diesel, enquanto o maior fica para as emissões de NO_x.

Por intermédio da métrica de U-Theil pode-se determinar qual é a rede melhor treinada para cada uma das variáveis ao longo de muitos treinamentos.

Tabela 6. Cálculos gerais (treinamento, validação e teste), para todas as rotações

VARIÁVEIS	CORREL.	R	R ²	U-THEIL	MSE	NRMSE	MAD
CASO A							
Emissões de CO	0,97	0,99	0,98	0,13	10383,40	0,15	69,48
Emissões de NOx	0,88	0,99	0,97	0,16	2817,13	0,16	31,98
Emissões de HC	0,99	1,00	0,99	0,08	159867,13	0,09	240,84
Temperatura de Escape	0,99	1,00	0,99	0,19	52,91	0,08	4,96
Consumo de diesel	1,00	1,00	1,00	0,06	0,06	0,06	0,19
Rendimento Térmico	1,00	1,00	1,00	0,10	0,19	0,05	0,32
CASO B							
Emissões de CO	0,97	0,99	0,97	0,17	7629,33	0,16	57,51
Emissões de NOx	0,96	0,98	0,97	0,21	3400,64	0,19	28,60
Emissões de HC	0,99	1,00	0,99	0,07	117854,88	0,07	221,01
Temperatura de Escape	1,00	1,00	1,00	0,10	21,35	0,05	3,40
Consumo de diesel	1,00	1,00	1,00	0,05	0,04	0,06	0,14
Rendimento Térmico	1,00	1,00	1,00	0,08	0,12	0,04	0,26

Caso A: incluindo dados de consumo de combustível 100% de diesel

Caso B: sem incluir dados de consumo de combustível 100% de diesel

Na Tabela 7, se resume, finalmente, por meio da métrica do erro porcentual (MAPE) os três subconjuntos (Treinamento, Validação e Teste). Como já constatado anteriormente, pode-se afirmar que maiores erros (segundo métrica MAPE) referem-se às emissões de CO e os menores às variáveis de temperatura de escapamento e rendimento térmico, tanto para o Caso A quanto para o B.

Tabela 7. Variáveis de treinamento, validação e teste.

VARIÁVEIS	TREINAMENTO		VALIDAÇÃO		TESTE*	
	MAPE		MAPE		MAPE	
	Caso A	Caso B	Caso A	Caso B	Caso A	Caso B
Emissões de CO	12,19	4,03	14,56	9,24	20,15	10,26
Emissões de NOx	4,40	4,19	5,99	4,25	10,89	5,17
Emissões de HC	3,10	9,47	4,63	9,92	5,41	8,96
Temperatura de Escape	1,24	0,79	2,43	1,43	2,06	1,28
Consumo de diesel	8,06	6,81	9,97	5,45	7,60	4,63
Rendimento Térmico	1,33	1,10	1,79	1,28	1,94	1,42

* Com dados não treinados

Caso A: incluindo dados de consumo de combustível 100% de diesel

Caso B: sem incluir dados de consumo de combustível 100% de diesel

7.2. Aprendizagem e Predição de Parâmetros

Pode-se entender como Conceito de Aprendizagem a resposta da rede neural com os dados experimentais. Uma parte dos dados foi utilizada para treinar a rede neural, outra parte para validar os dados e o resto para testar (com dados desconhecidos para a rede).

Pode-se observar nas Figura 25 até a Figura 30, respectivamente, a predição de dados para consumo do combustível diesel, rendimento térmico, temperatura dos gases de escapamento, emissão de CO, emissão de HC e emissão de NOx. Para todos os casos, no eixo das ordenadas está localizada a variável a ser predita e no eixo das abscissas, os dados utilizados para a aprendizagem da rede neural. Nesta etapa de aprendizagem, a rede neural utilizada apresenta uma boa concordância com os dados experimentais utilizados.

Na mesma relação de figuras (Figura 25 até a Figura 30), pode-se observar que os pontos de aprendizagem utilizados são apresentados em forma seqüencial (ordenados por rotação), tendo como consequência que estas curvas representam como foi que a rede neural respondeu ante os dados experimentais, mas não dá uma interpretação do fenômeno estudado.

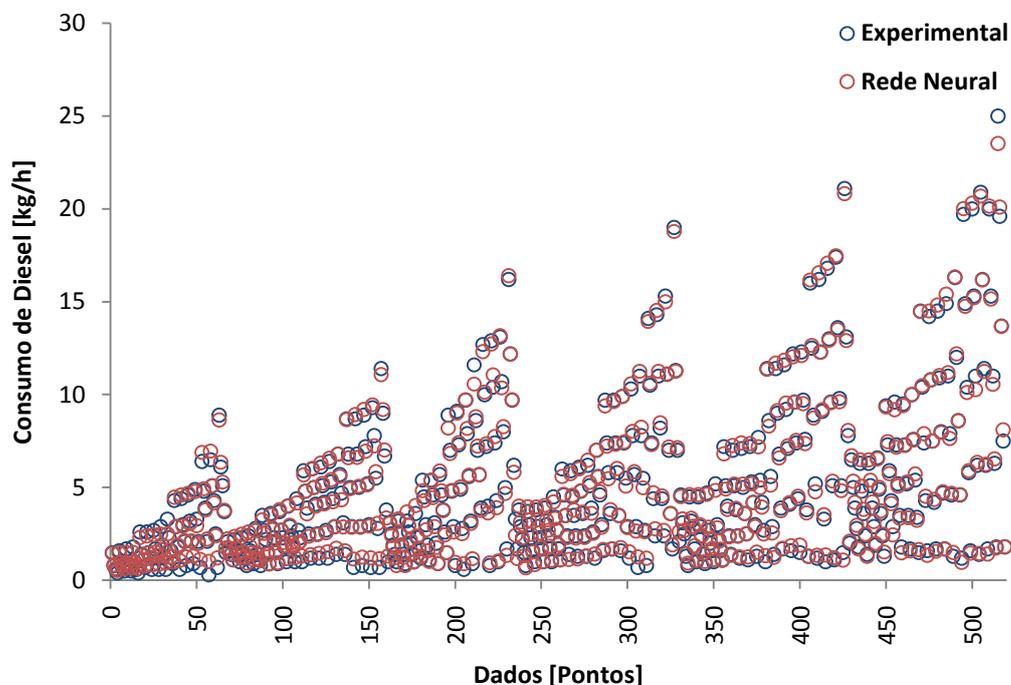


Figura 25. Aprendizagem de dados para consumo de diesel.

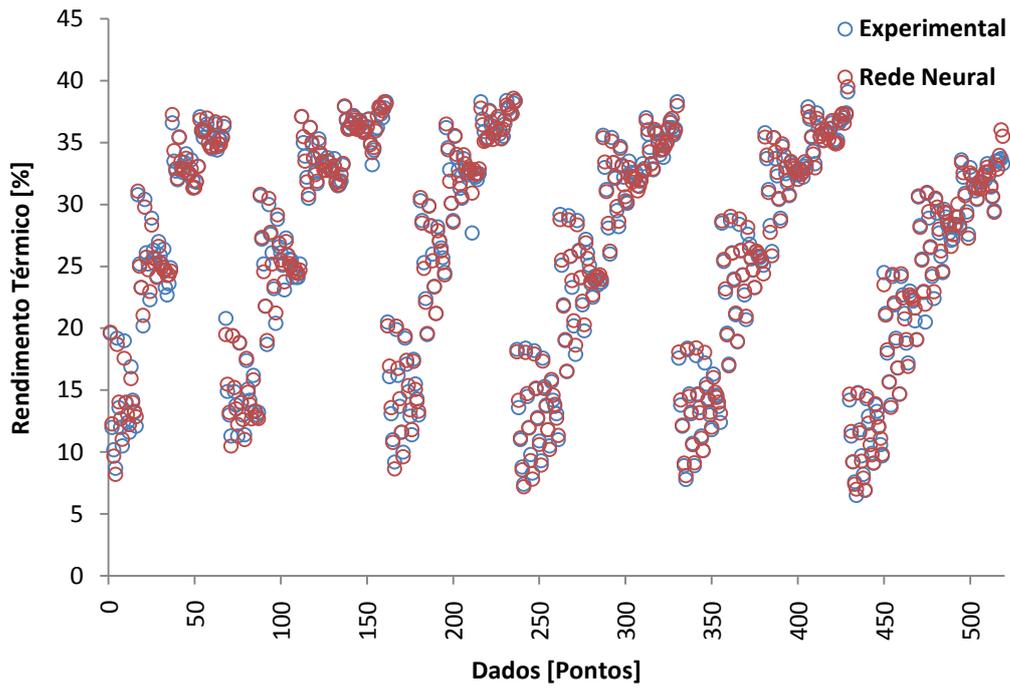


Figura 26. Aprendizagem de dados para rendimento térmico.

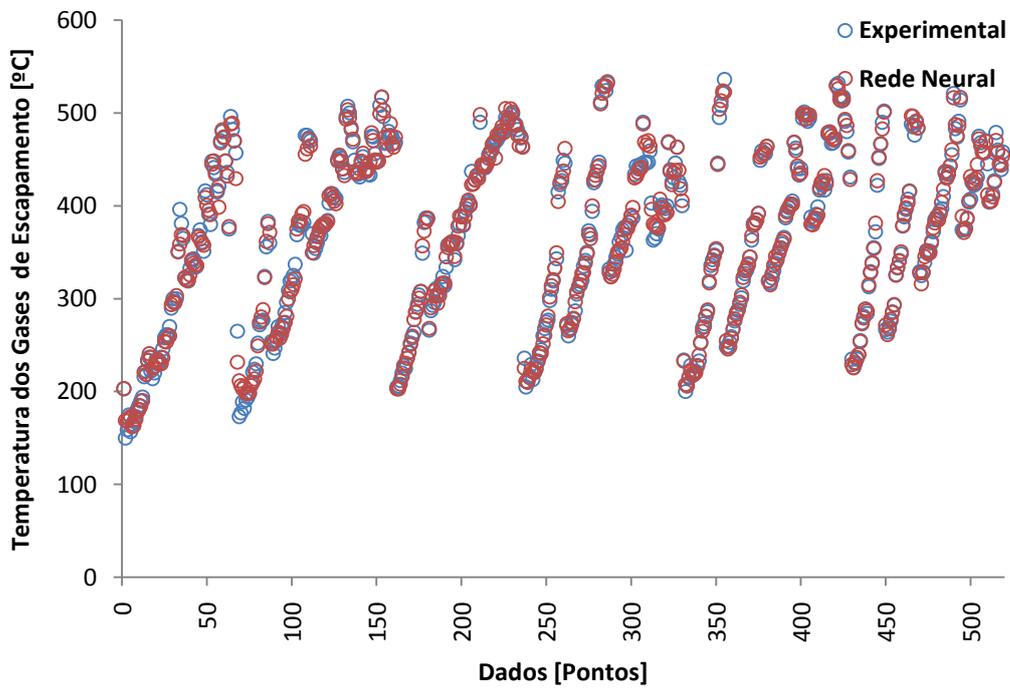


Figura 27. Aprendizagem de dados para temperatura dos gases de escapamento.

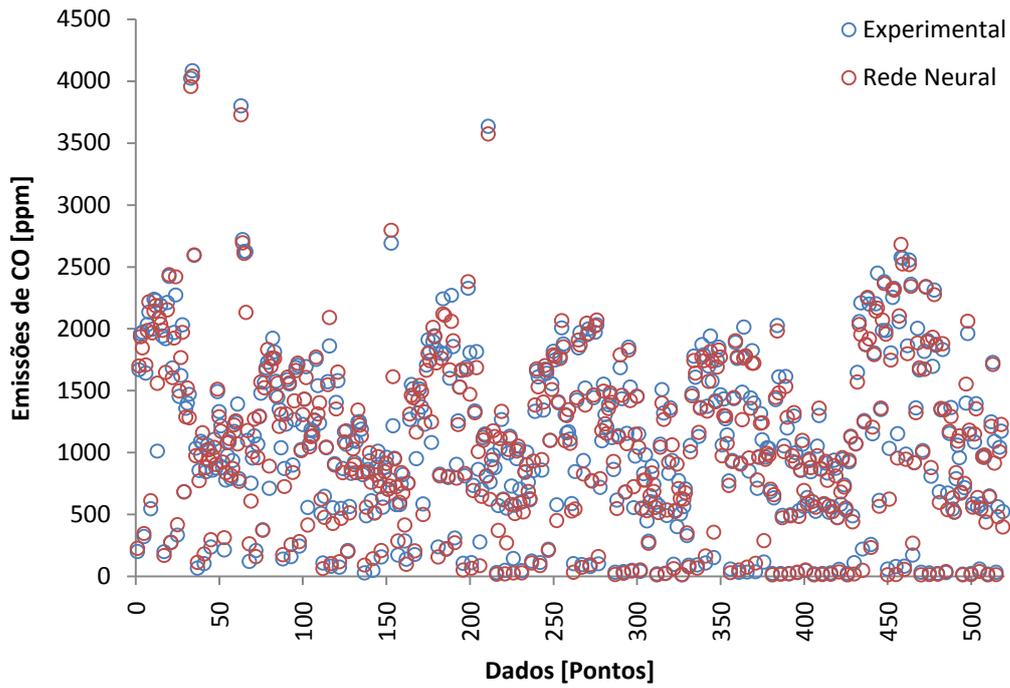


Figura 28. Aprendizagem de dados para emissão de CO.

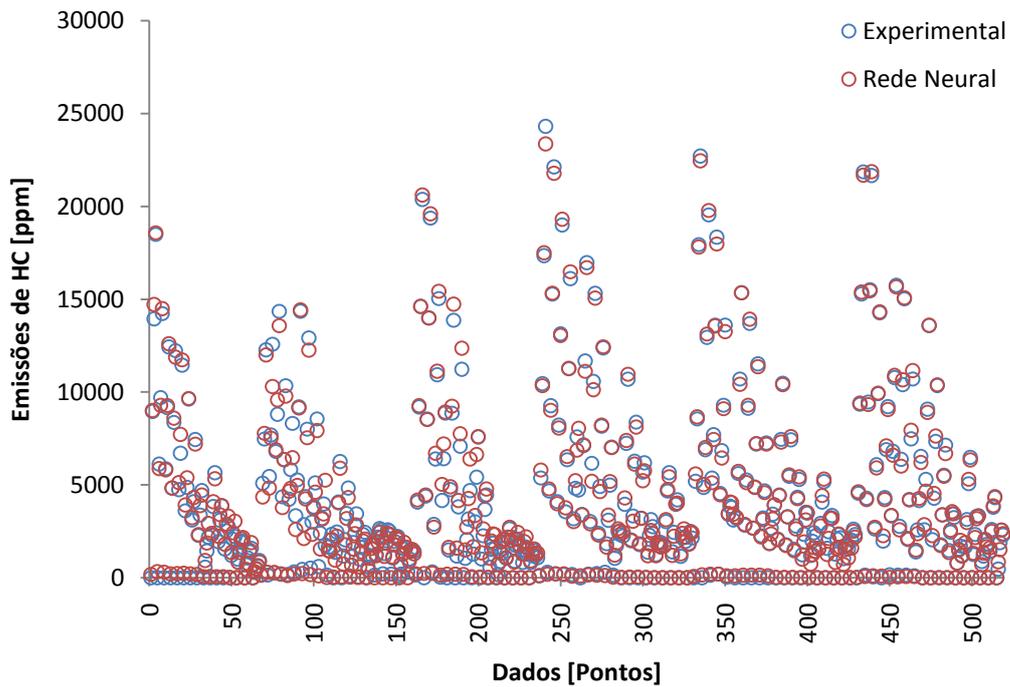


Figura 29. Aprendizagem de dados para emissão de HC.

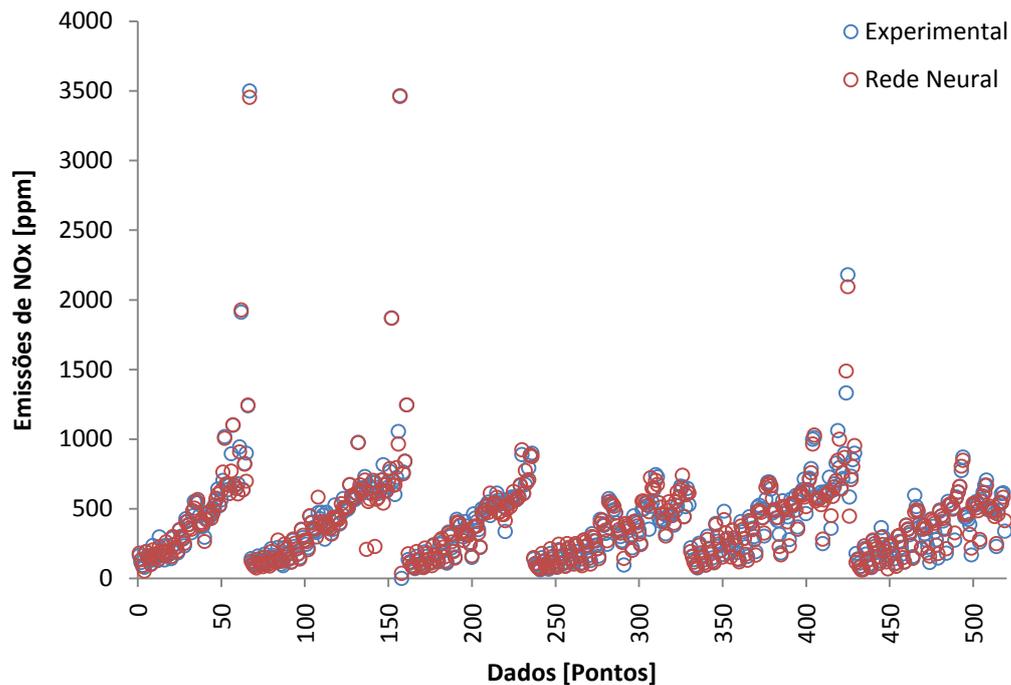


Figura 30. Aprendizagem de dados para emissão de NOx.

7.2.1. Coeficientes de Correlação

Podemos observar nas Figura 31 até a Figura 36 a correlação entre os dados experimentais e os dados obtidos do processo de aprendizagem da rede neural, isto para o consumo do combustível diesel, rendimento térmico, temperatura dos gases de escapamento, emissão de CO, emissão de HC e emissão de NOx, respectivamente.

Os coeficientes de correlação (R^2) são apresentados nas mesmas figuras, podendo-se observar que, para os casos de consumo de combustível diesel, rendimento térmico, temperatura dos gases de escapamento, emissão de HC, $R^2=0,99$. Este valor indica que os dados apresentados pela rede neural, na média, se aproximam 99% dos valores experimentais.

No caso de emissão de CO e emissão de NOx, o coeficiente de correlação R^2 foi de 0,96. Ainda que este valor seja menor que os casos anteriores, a aproximação entre os dados apresentados pela rede neural e os experimentais é considerada bastante satisfatória.

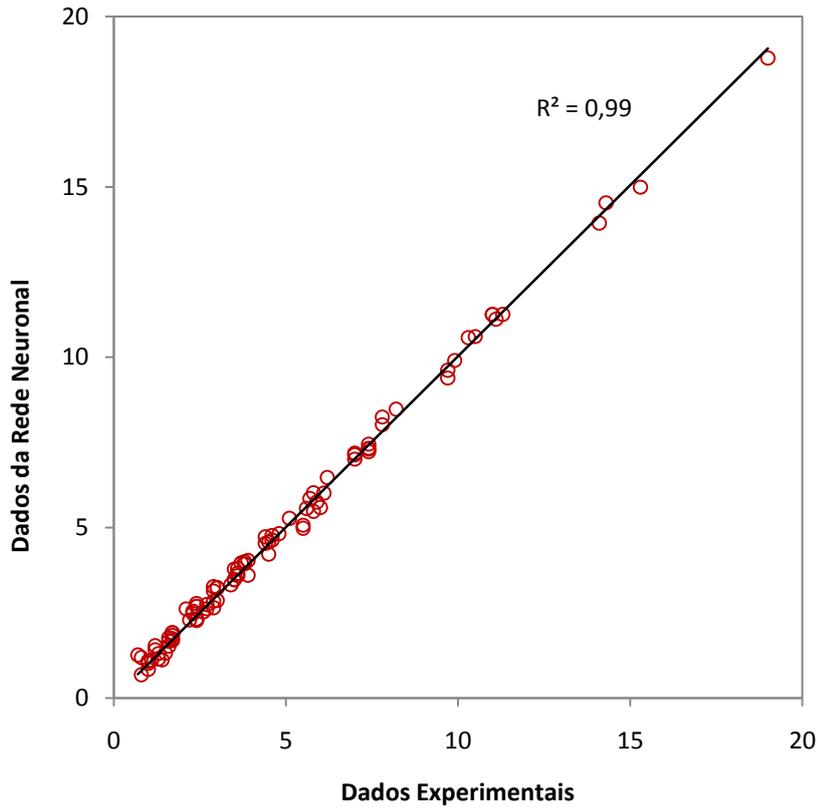


Figura 31. Correlação para consumo de diesel, $n = 1850$ RPM.

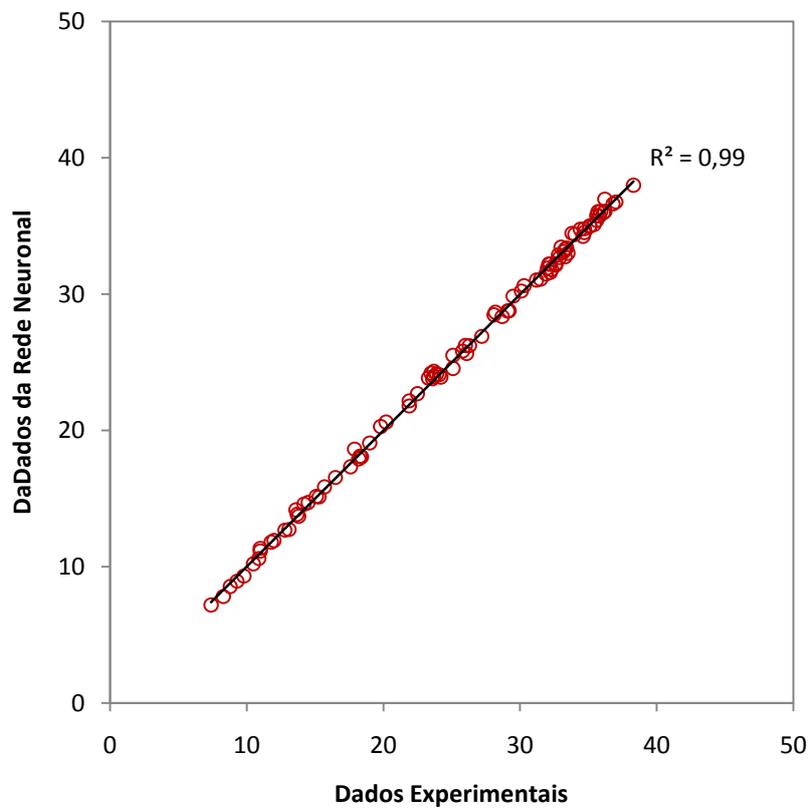


Figura 32. Correlação para rendimento térmico, $n = 1850$ RPM.

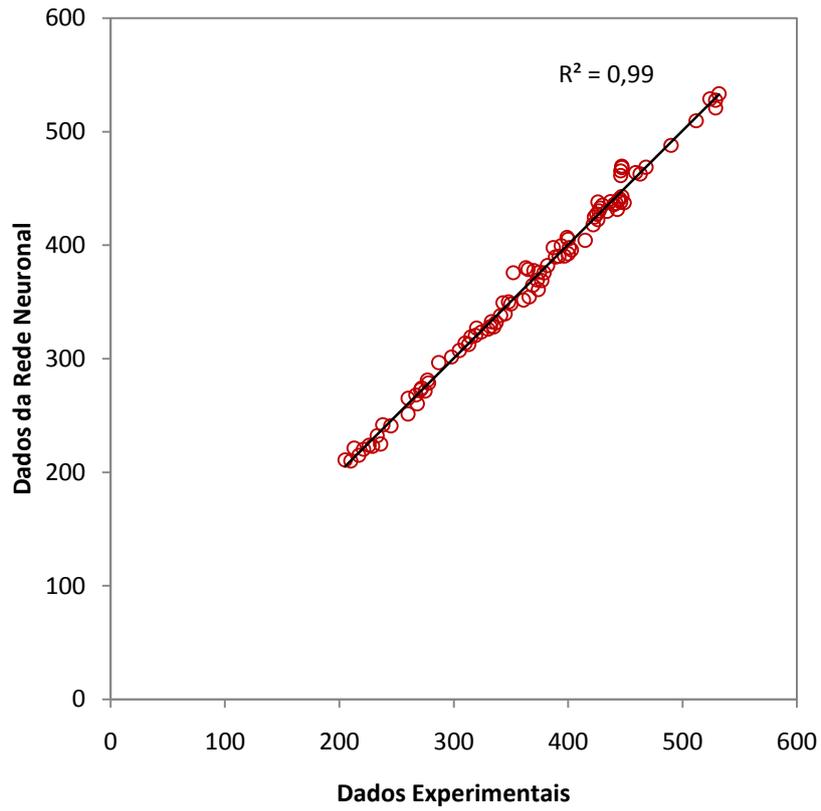


Figura 33. Correlação para temp. gases de escape, $n = 1850$ RPM.

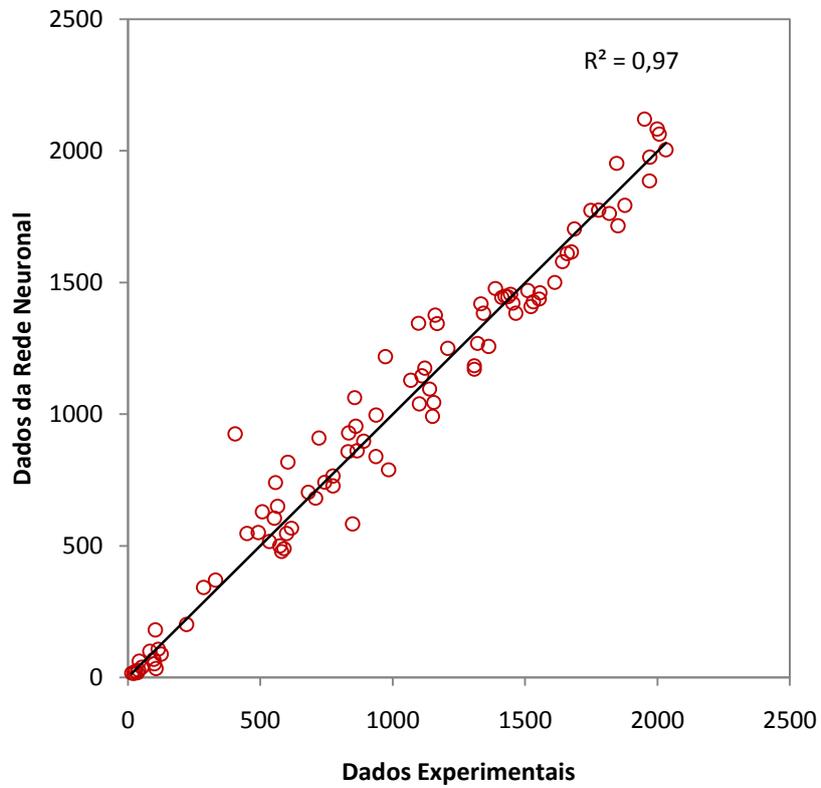


Figura 34. Correlação para emissão de CO, $n = 1850$ RPM.

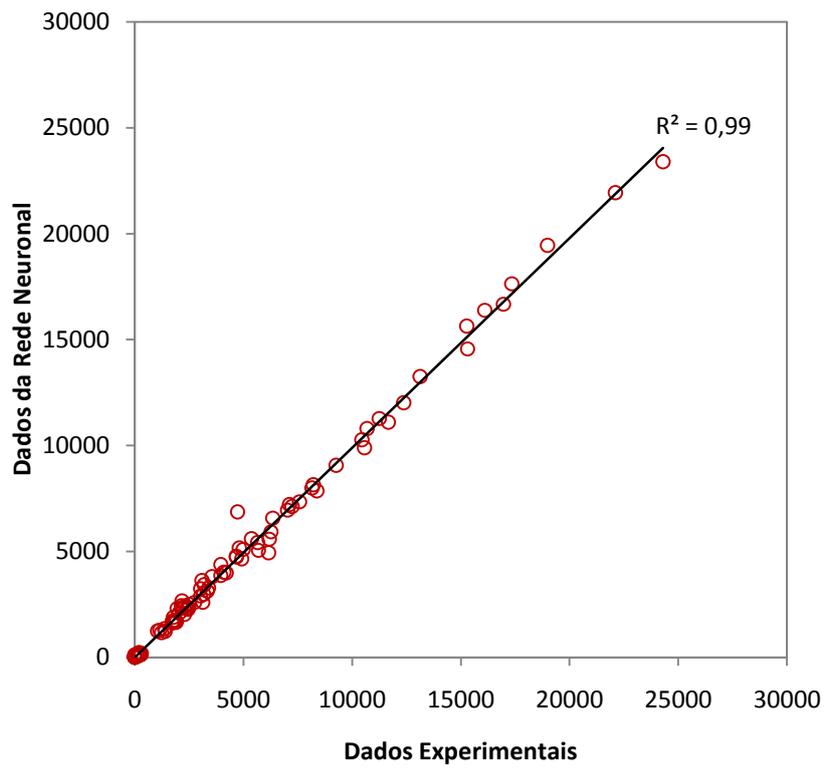


Figura 35. Correlação para emissão de HC, $n = 1850$ RPM.

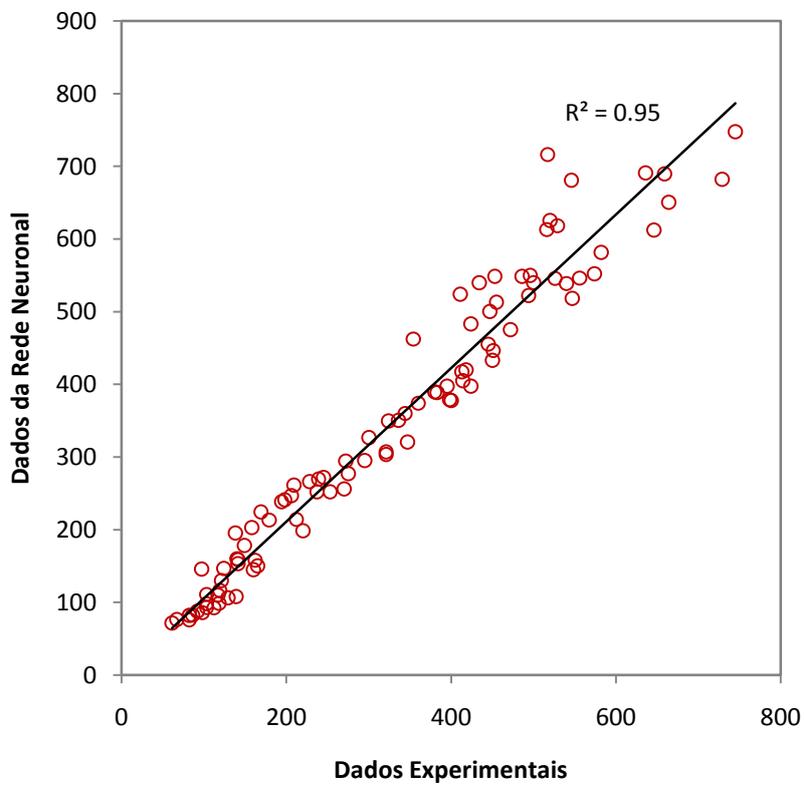


Figura 36. Correlação para emissão de NO_x, $n = 1850$ RPM.

7.3. Predição de dados

Entende-se por predição de dados ao processo de interpolação e extrapolação a partir dos valores preditos pela rede neural para determinar pontos que não foram determinados experimentalmente. É dizer, os testes experimentais foram realizados para intervalos de porcentagem de carga (por exemplo) de 10%, 25%, 75%, e 100%; o processo de predição de dados determinara os pontos intermediários, isto é, porcentagens de carga de 10%, 12%, 14%, 16%..., 96%,98%, e 100%. Desta maneira, tem-se uma seqüência de pontos praticamente contínua para ser otimizada.

Nesta parte do trabalho o processo de predição de dados foi realizado para rotações entre 1000 e 2600 RPM (com intervalos de 250 RPM). Neste capítulo somente serão apresentadas as curvas de predição de dados para a rotação de 1850 RPM. Os outros casos, 1000 RPM e 2600 RPM, podem ser avaliados nos anexo 0 e 0, respectivamente.

Nas Figura 37 até Figura 42, são apresentados casos de predição de dados com a rotação de 1850 RPM, para consumo do combustível diesel, rendimento térmico, temperatura dos gases de escapamento, CO, HC e NOx, respectivamente. Em cada Figura, as linhas representam as previsões e os pontos indicam os dados experimentais. Pode-se observar que cada caso apresenta coerência com os dados experimentais obtidos. Para os casos de consumo de diesel, rendimento térmico e temperatura dos gases de escapamento e HC, os resultados de predição são mais aproximados do que no caso de CO e de NOx.

Em todas as Figuras, no caso de 100% de carga, pode-se observar uma maior dispersão entre os dados experimentais e os dados da rede neural. Isto se deve ao fato de que nos experimentos, foi feito somente um teste, sendo, portanto, considerado um número de pontos menor para análise de predição. Contudo, em termos gerais, a aproximação dos experimentos com os dados da rede neural é considerada aceitável e suficiente para realizar a seguinte etapa de otimização de parâmetros.

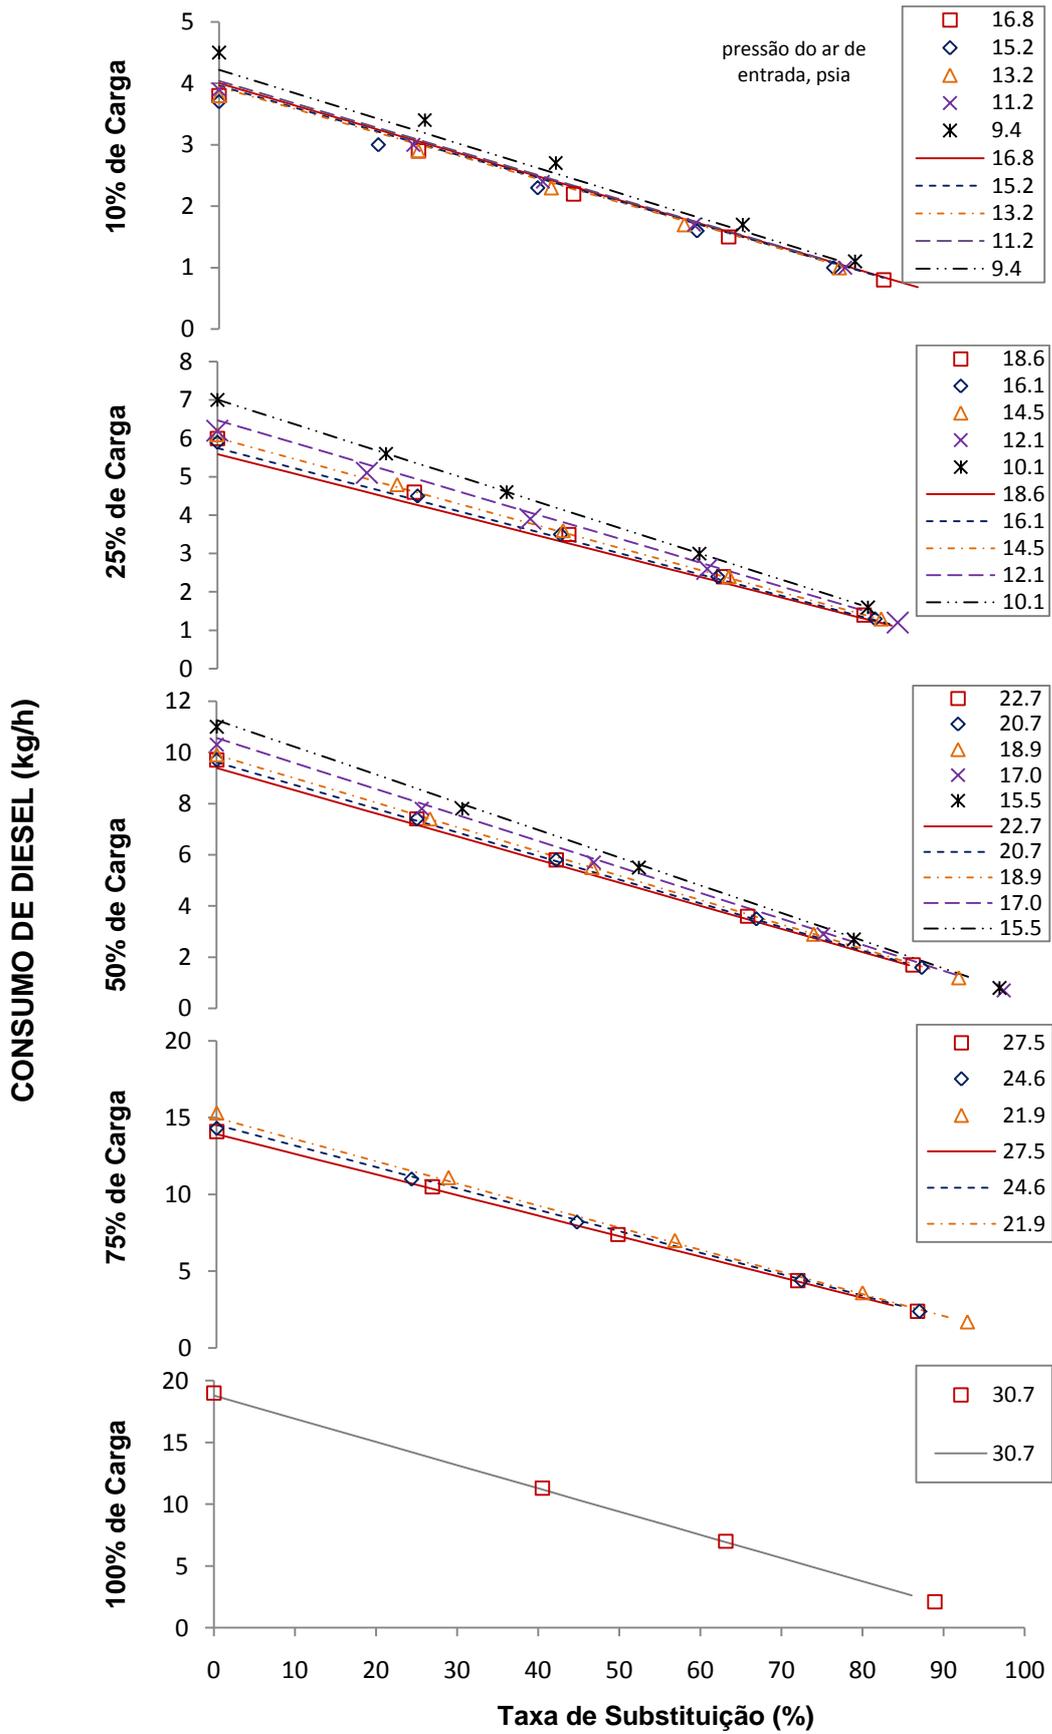


Figura 37. Predição para consumo de diesel, 1850 RPM.

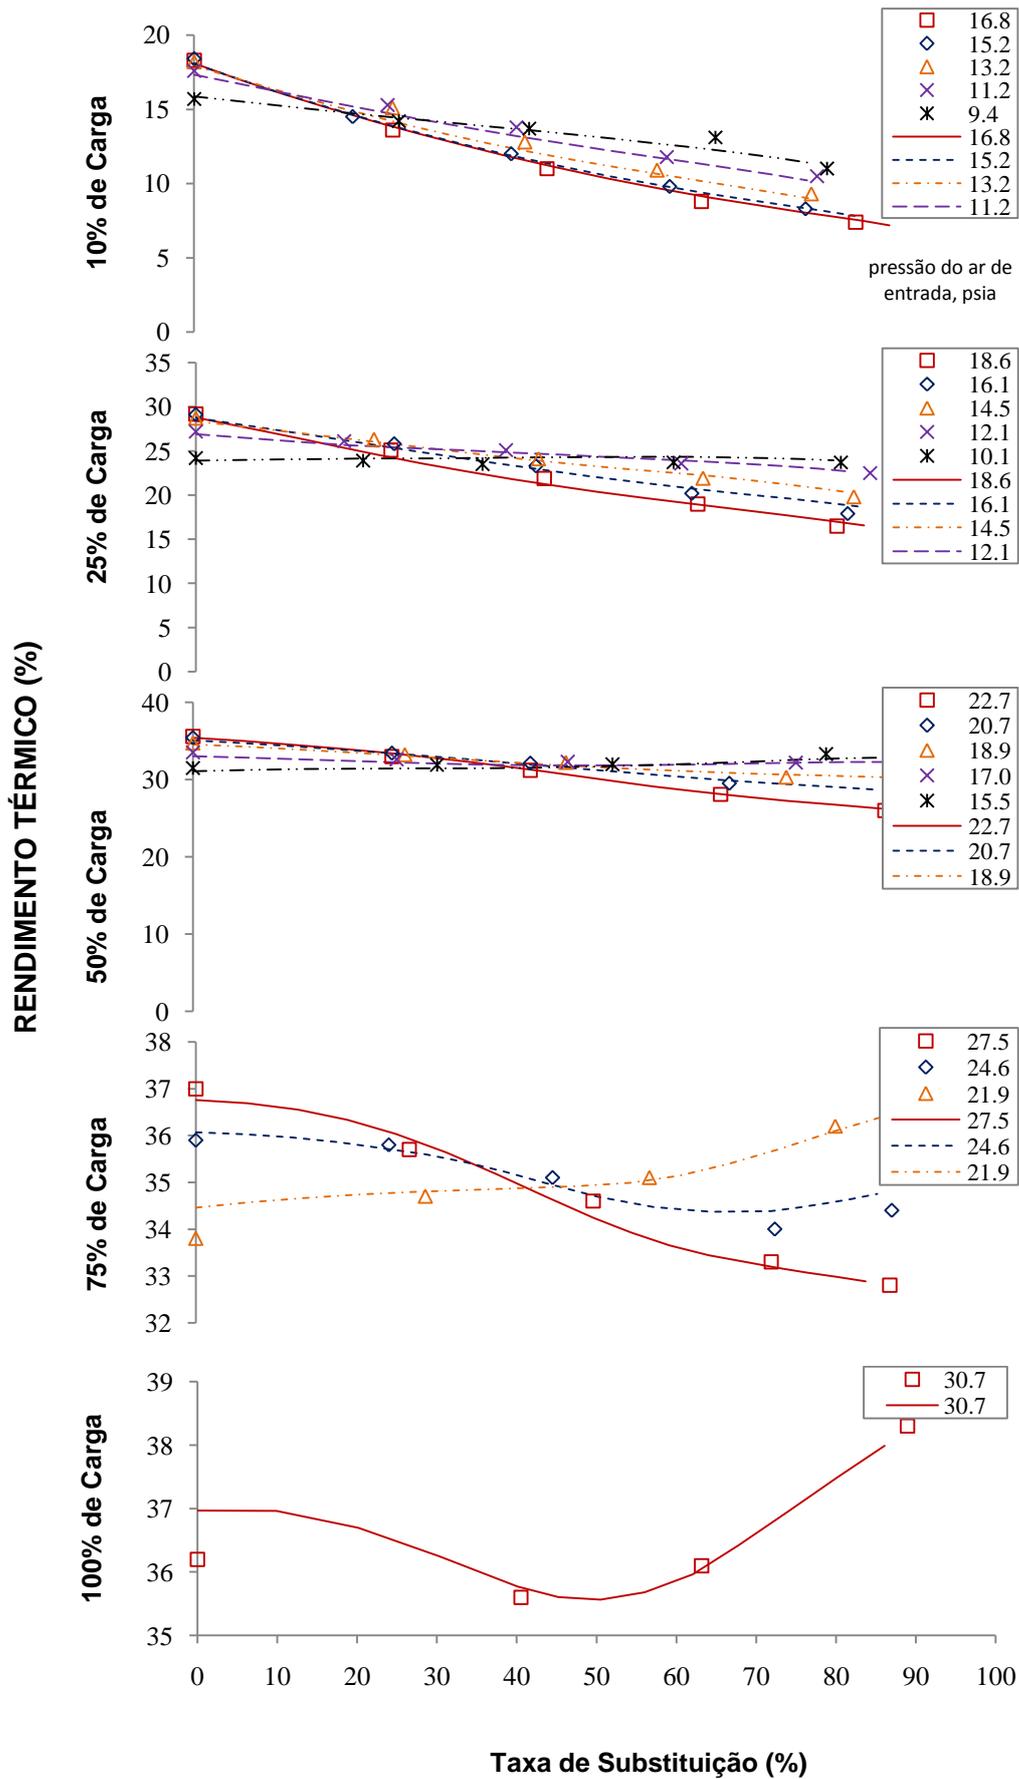


Figura 38. Predição para rendimento térmico, 1850 RPM.

TEMPERATURA DOS GASES DE ESCAPAMENTO (°C)

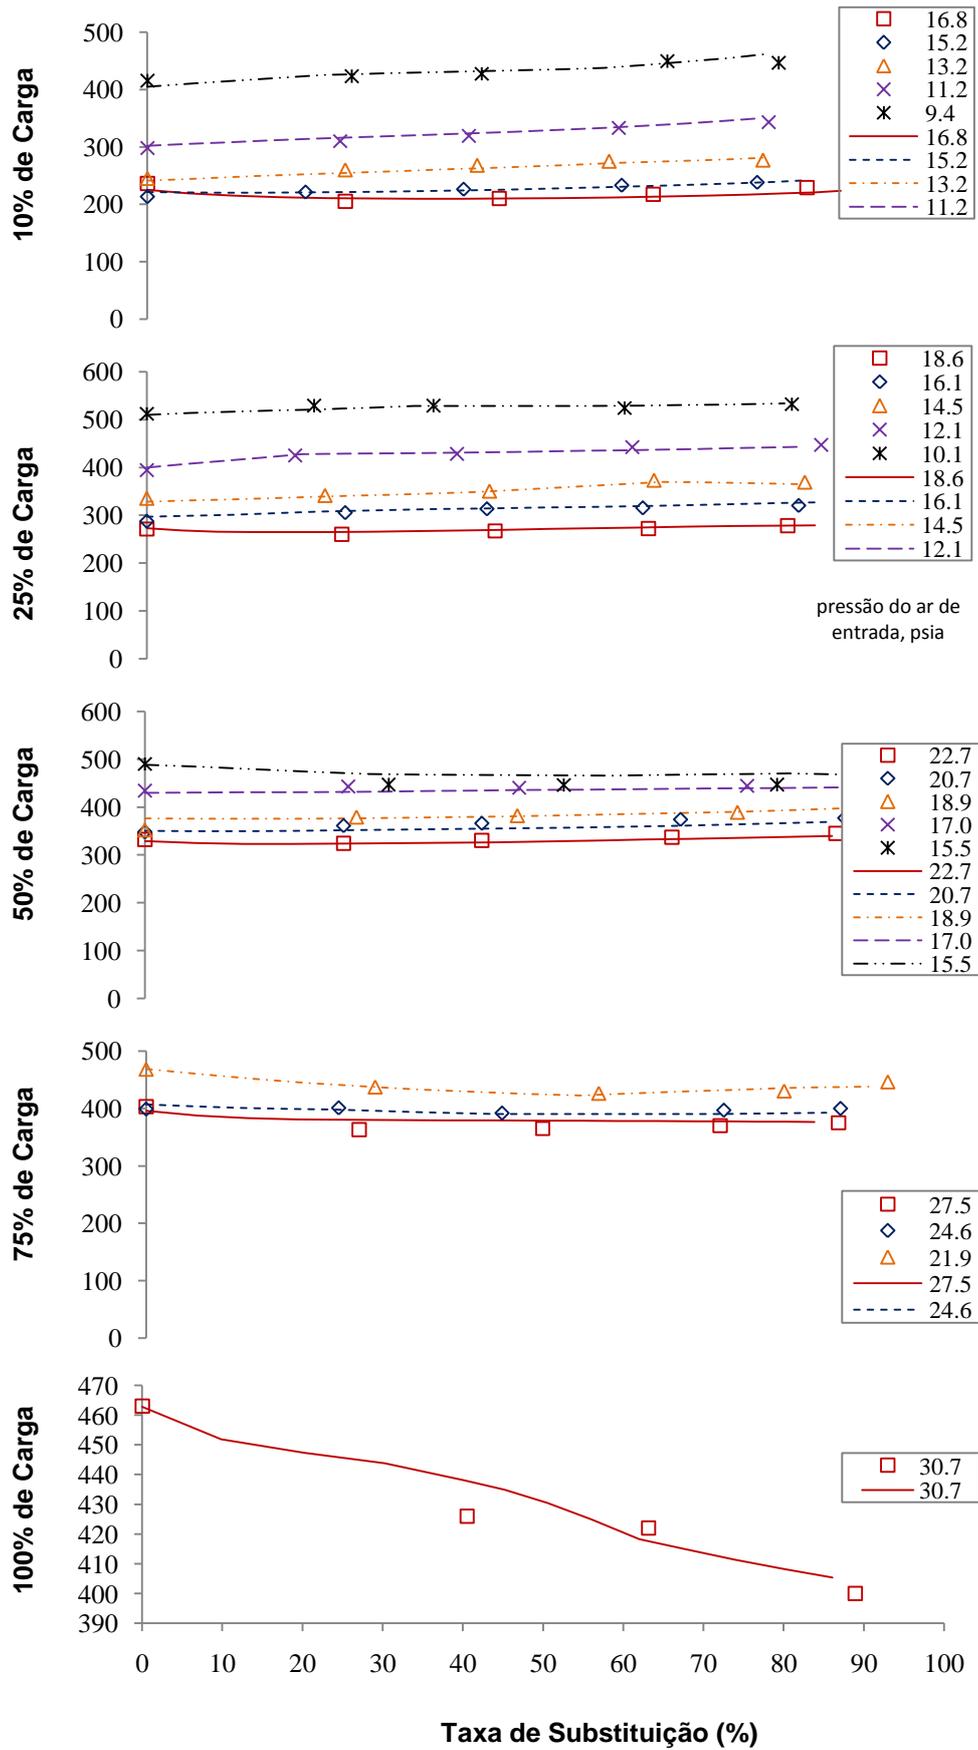


Figura 39. Predição para temp. dos gases de escapamento, 1850 RPM.

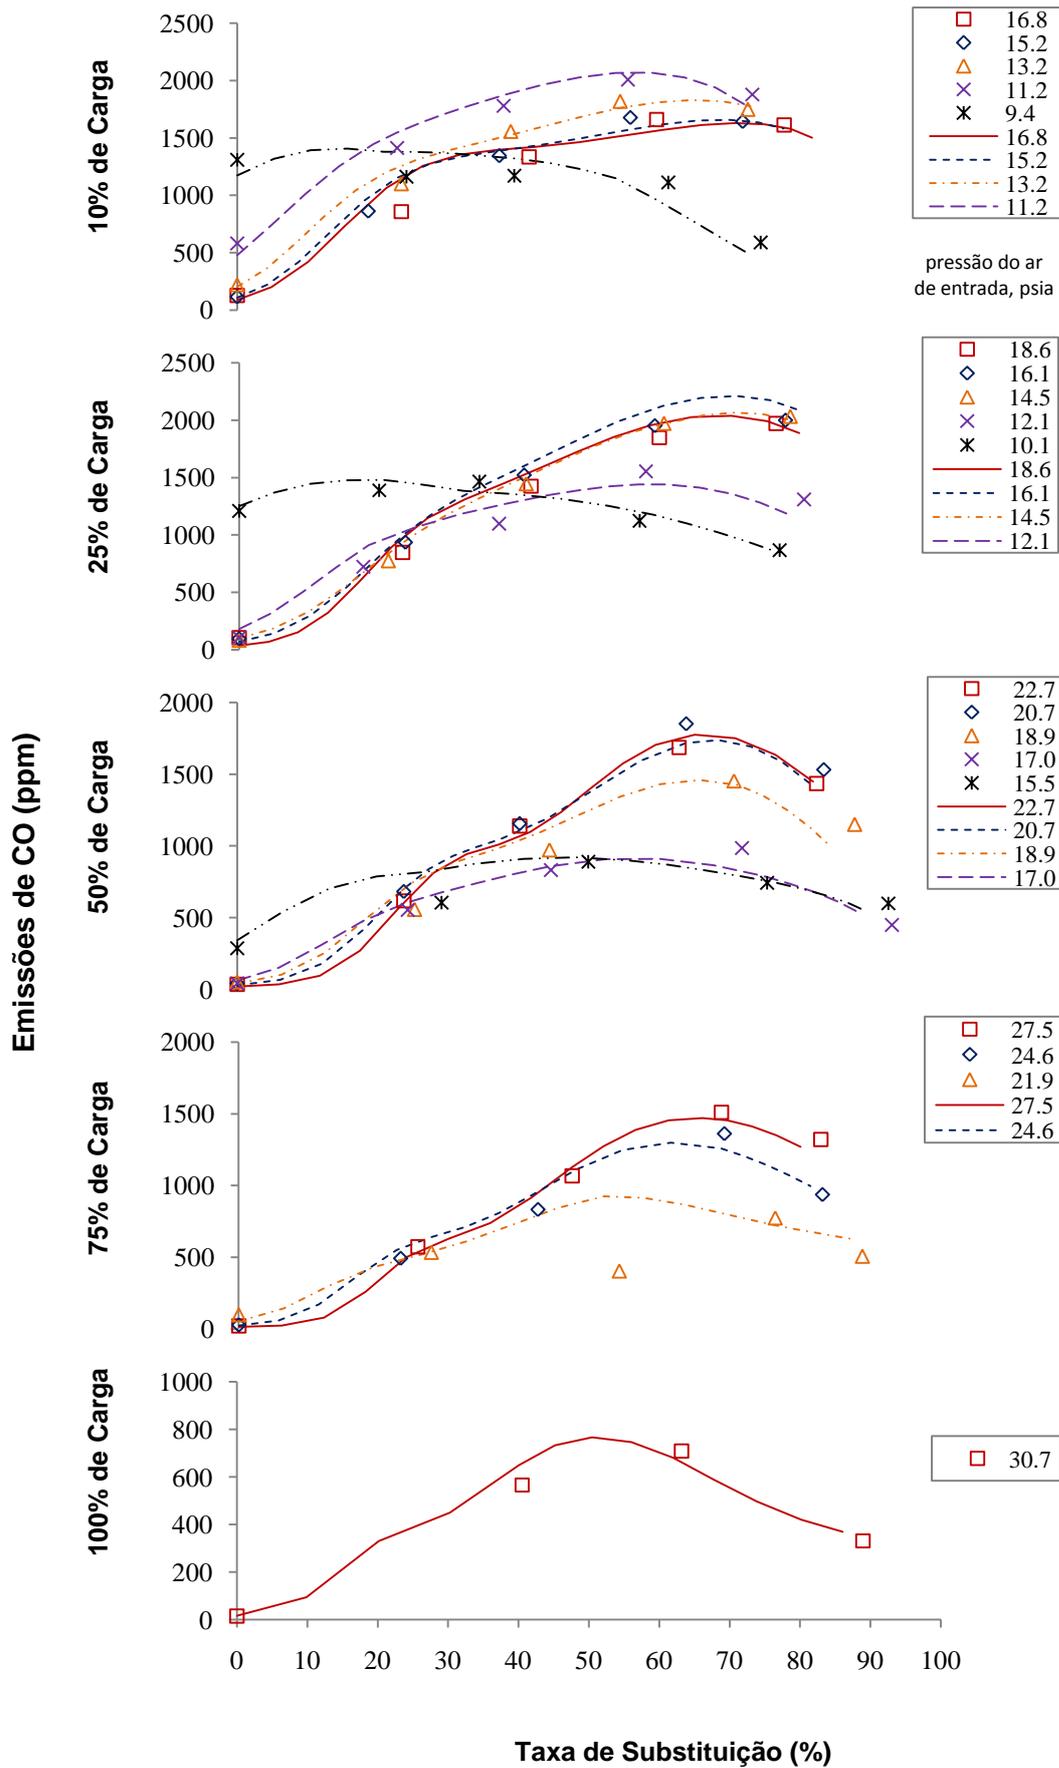


Figura 40. Predição para CO, 1850 RPM.

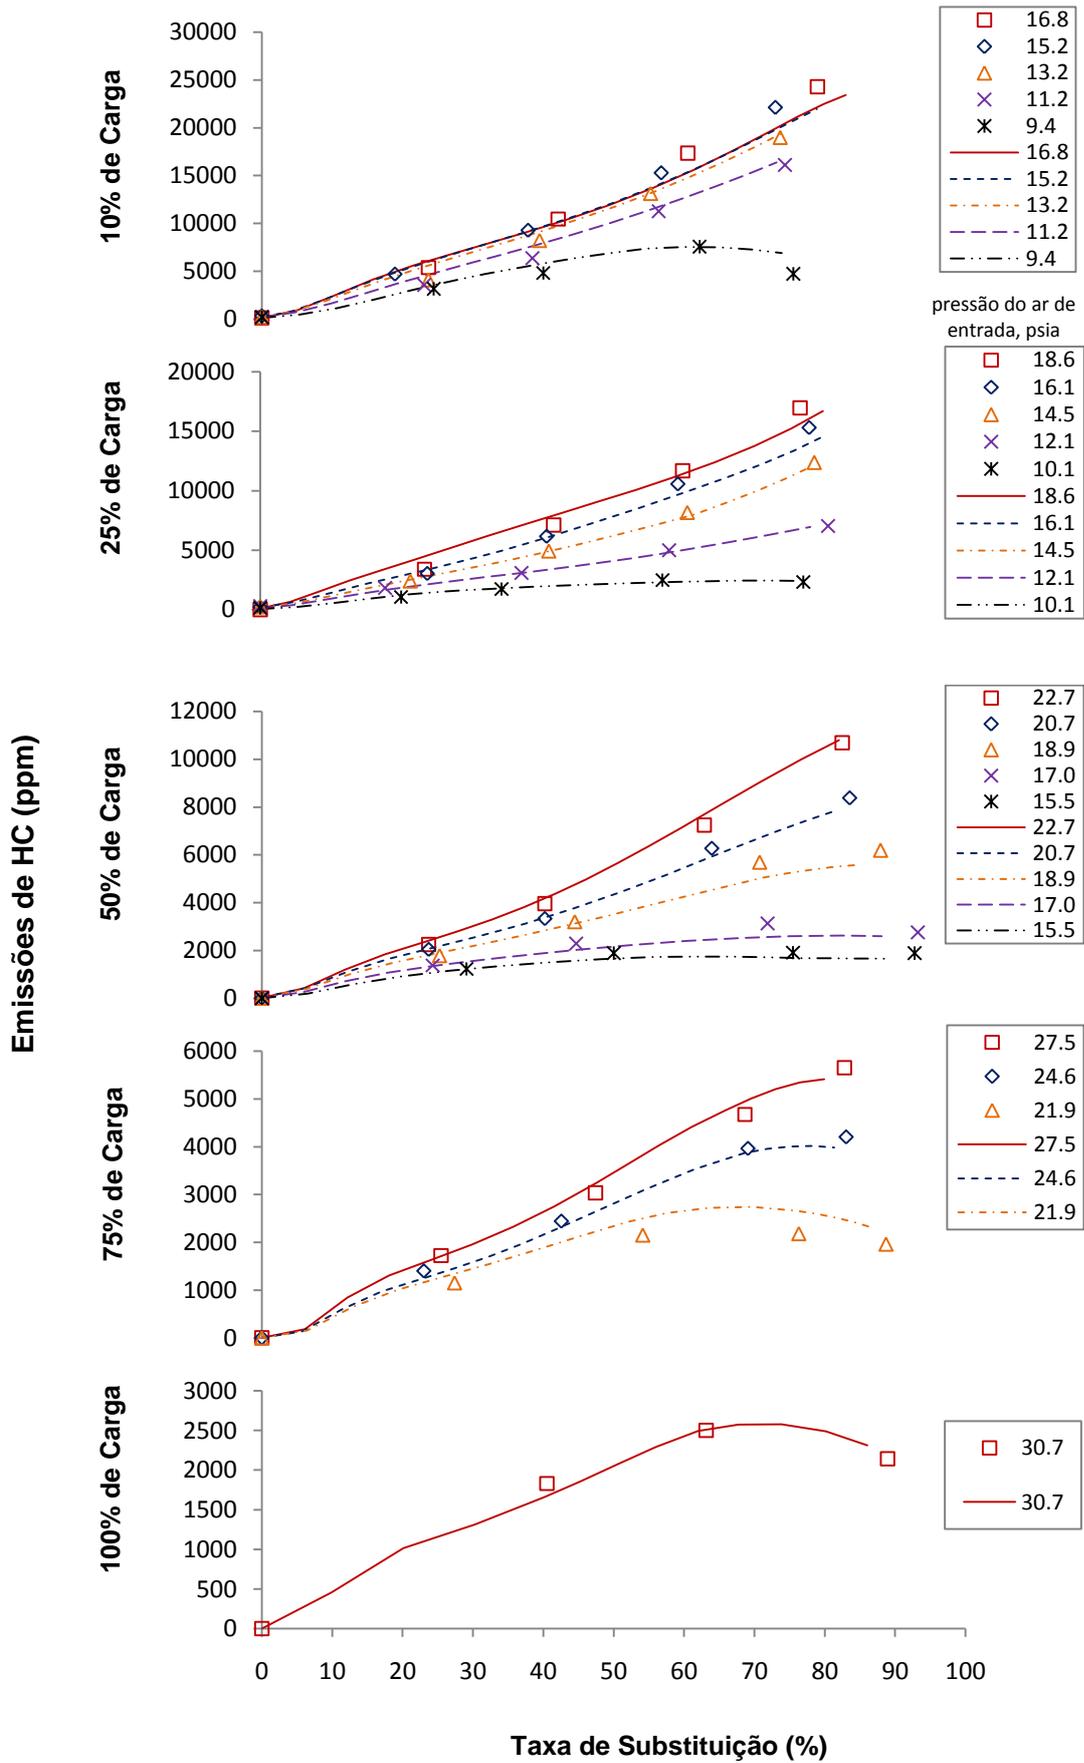


Figura 41. Predição para HC, 1850 RPM.

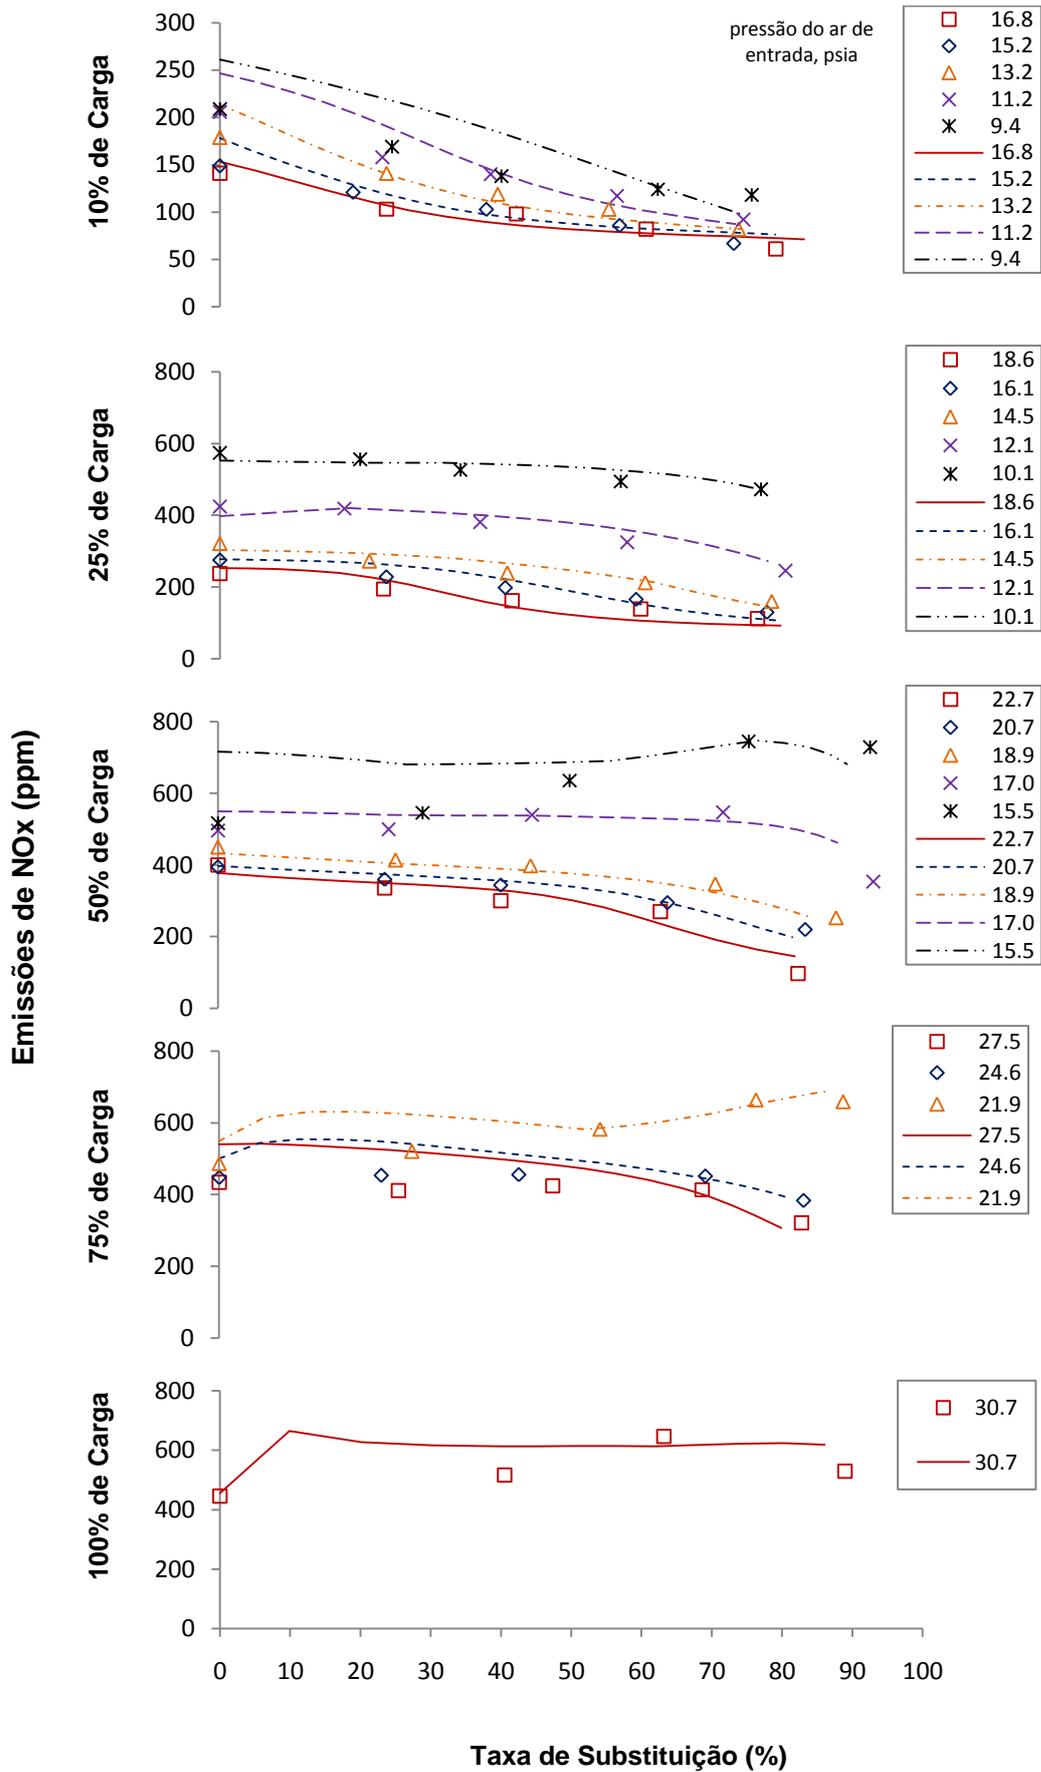


Figura 42. Predição para NOx, 1850 RPM.

7.4. Otimização de Parâmetros

O processo de otimização consiste em determinar uma boa combinação de entre as quantidades de ar seco e de gás natural que reduzam as emissões ao mesmo tempo em que maximizem o rendimento térmico do motor e a taxa de substituição. Mais, o processo de otimização também está baseado segundo a determinação dos pesos para cada uma das variáveis que compõem a função de otimização ou fitness. Ao final são obtidos os valores para esse determinado ponto (otimizado), tais como suas emissões (CO, HC e NOx), rendimento térmico e quantidade de diesel.

Muitos critérios podem ser avaliados, criando inúmeros mapas de otimização. No presente trabalho serão apresentados alguns casos específicos de otimização.

7.4.1. Otimização da Taxa de Substituição

Nos resultados a seguir são apresentados diferentes mapeamentos. Diferentes “pesos” são atribuídos a cada variável para determinar um ponto de desempenho ótimo, determinado pela tendência de otimização (ver Equação 11).

Para otimizar a taxa de substituição, foi utilizada a seguinte configuração de “pesos”.

Tabela 8. Configuração de pesos para otimização da taxa de substituição.

Parâmetro	Peso 1	Peso 2	Peso 3	Peso 4
CO	5	5	5	5
HC	5	5	5	5
NOx	5	5	5	5
Eficiência térmica	10	10	10	10
Taxa de substituição	5	10	15	20

Pode-se observar na Tabela 8 que foi mantido um peso constante para as emissões de gases de escapamento (5 para todos). Para o caso da eficiência térmica o seu peso também é mantido constante, mas com um valor superior (o dobro das emissões). Então, fica claro que o objetivo é manter um peso maior na

eficiência térmica e avaliar o mapeamento produzido com diferentes pesos da taxa de substituição.

Para simplificar esta descrição, os pesos são apresentados como sobrescritos dos símbolos das variáveis analisadas.

Na Figura 43, pode-se observar o mapeamento da taxa de substituição com pesos: $CO^5-HC^5-NOx^5-ET^{10}-TS^5$. Pode-se observar superfícies de valores experimentais máximos e mínimos e, entre estes, a superfície “otimizada” gerada pelo algoritmo genético com esses pesos. Os pesos atribuídos a cada variável, determinam valores da taxa de substituição baixa para cargas baixas e valores altos para cargas altas. Neste caso, os pontos foram “otimizados” pelas emissões e pela eficiência térmica.

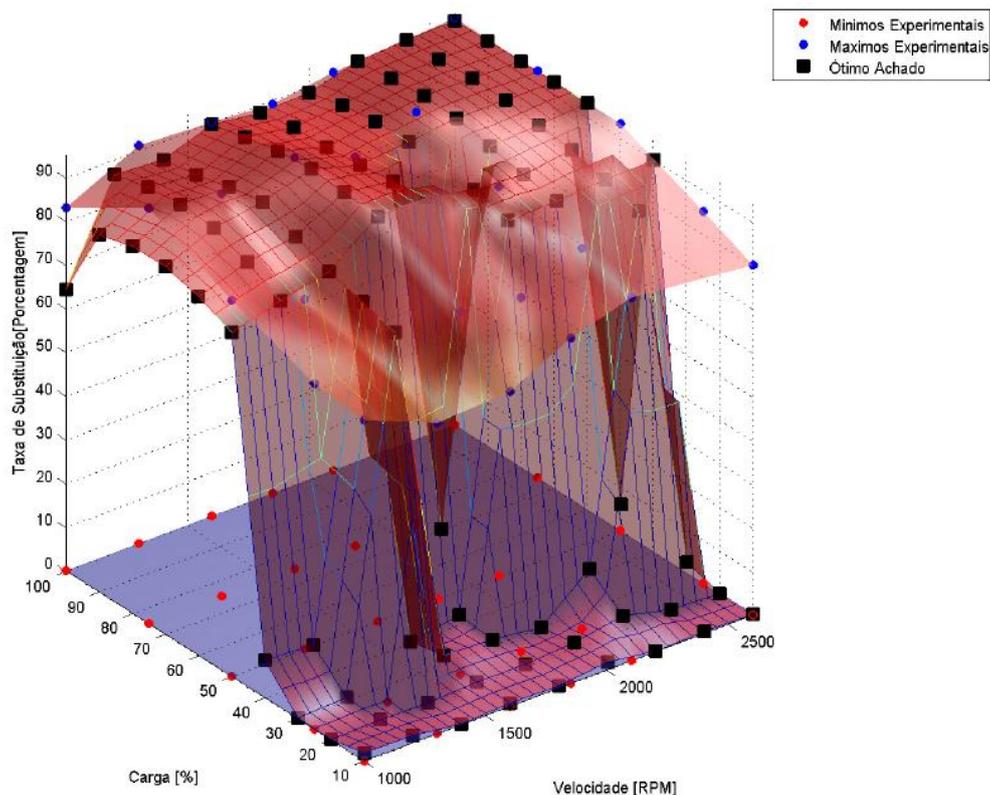


Figura 43. Desempenho da TS, pesos: $CO^5-HC^5-NOx^5-ET^{10}-TS^5$.

Na Figura 44, pode-se observar a configuração de pesos: $CO^5-HC^5-NOx^5-ET^{10}-TS^{10}$. A diferença entre este caso e o anterior está no peso da taxa de substituição, que foi aumentado de 5 para 10. Como resultado, muda a superfície ótima gerada pelo algoritmo genético, aumentando os valores das

taxas de substituição ótimas. Quase todos os valores ficaram próximos aos máximos experimentais.

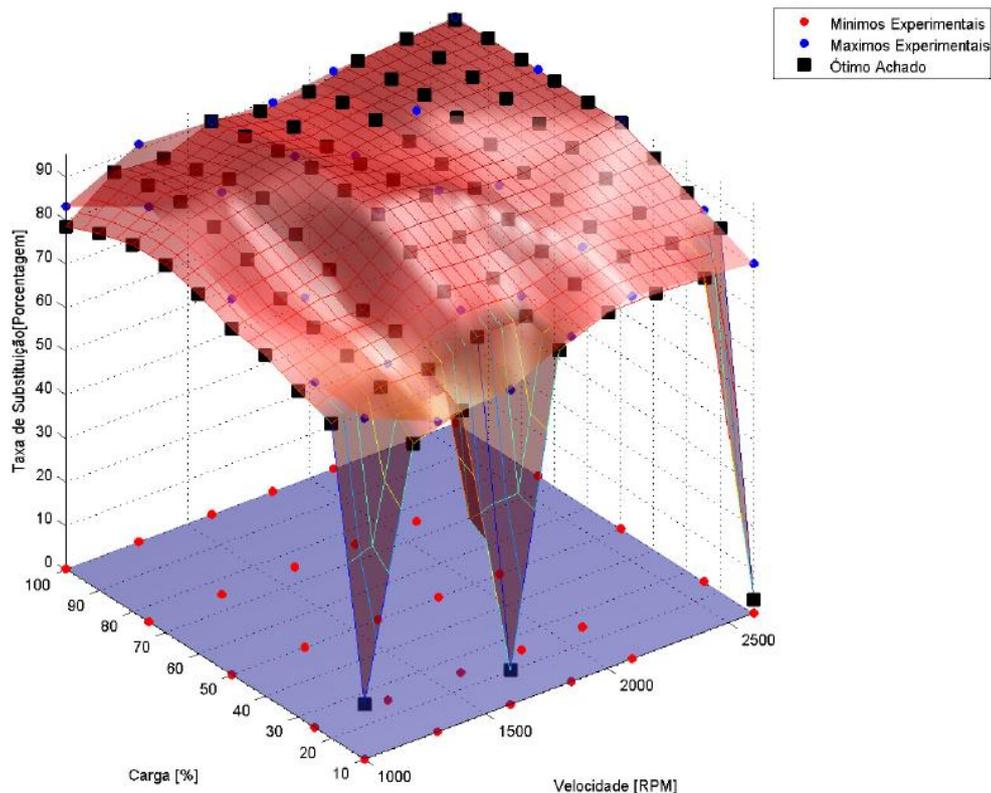


Figura 44. Desempenho da TS, pesos: $CO^5-HC^5-NOx^5-ET^{10}-TS^{10}$.

Na Figura 45, pode-se observar a configuração de pesos: $CO^5-HC^5-NOx^5-ET^{10}-TS^{15}$. Mais uma vez o valor do peso para a taxa de substituição foi aumentado e os valores ótimos ficaram todos muito próximos dos máximos experimentais. Na Figura 46 é apresentado um caso similar, com o peso 20 para a taxa de substituição. Para este último caso, não se percebe uma diferença substancial com o caso do peso 15 (Figura 45). A partir deste valor de peso para a taxa de substituição (acima de 15), a superfície gerada pelo algoritmo genético não mais se altera.

Analisando novamente as Figura 43 até a Figura 46, conclui-se que a combinação com pesos $CO^5-HC^5-NOx^5-ET^{10}-TS^5$ (Figura 43) e $CO^5-HC^5-NOx^5-ET^{10}-TS^{15}$ (Figura 45), exibem os casos mais representativos na combinação de pesos apresentada.

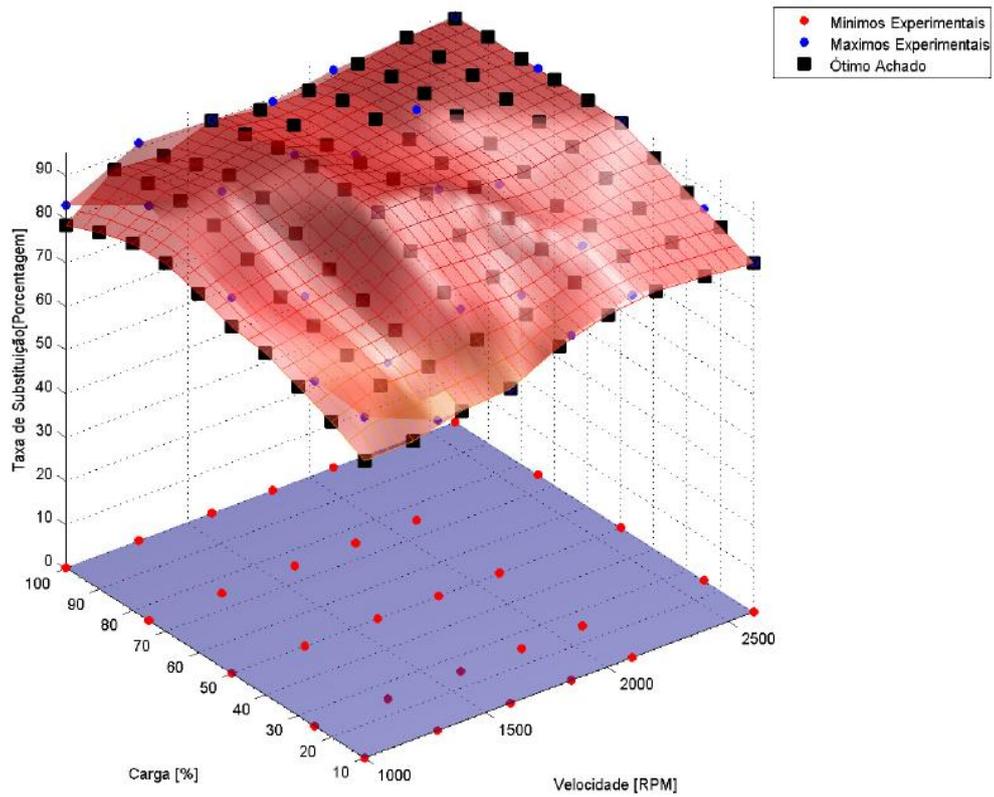


Figura 45. Desempenho da TS, pesos: $CO^5-HC^5-NOx^5-ET^{10}-TS^{15}$.

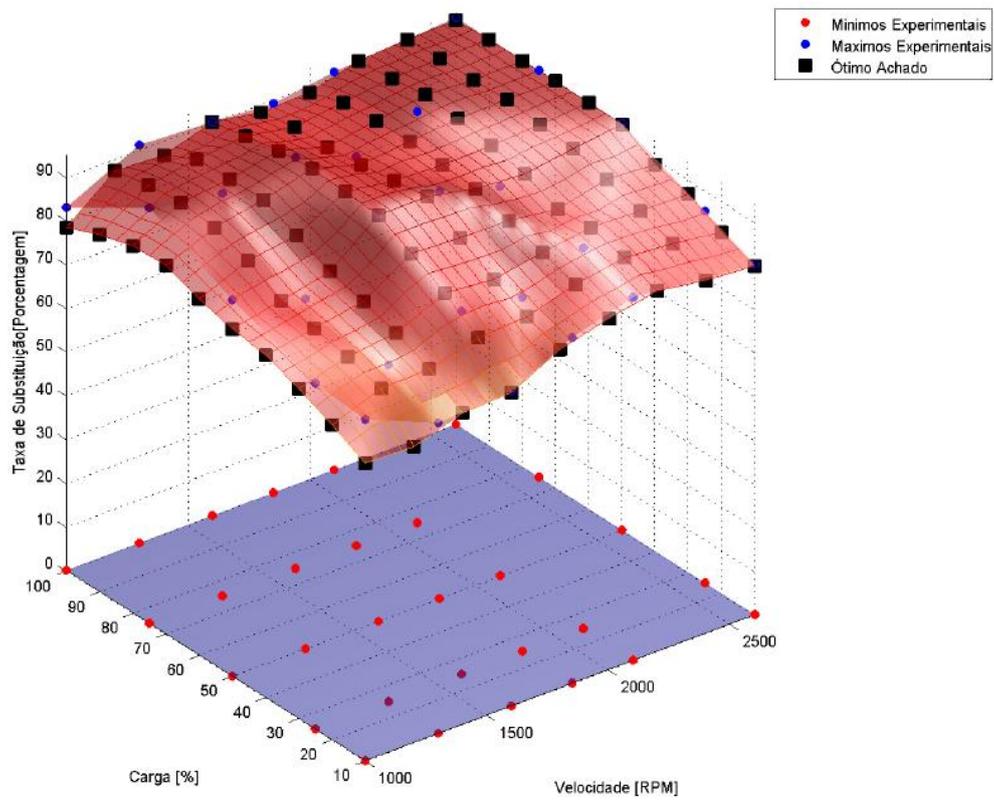


Figura 46. Desempenho da TS, pesos: $CO^5-HC^5-NOx^5-ET^{10}-TS^{20}$.

Nas Figura 47, Figura 48, Figura 49 e Figura 50, são apresentadas as gerações de CO, HC, NOx, e o rendimento térmico, respectivamente, com a atribuição dos seguintes pesos: $CO^5-HC^5-NOx^5-ET^{10}-TS^5$.

Pode-se observar nestas mesmas figuras que o fato de se ter atribuído um peso menor à taxa de substituição, conduz a um resultado onde os valores das emissões (CO, HC, NOx), apresentem valores mais próximos dos mínimos experimentais. Isto traz como consequência uma redução na taxa de substituição, que beira o zero nas baixas cargas e o máximo experimental (em cargas altas) onde as emissões são menores, segundo a Figura 43.

Contrário às emissões de CO e HC, o NOx apresenta valores experimentais menores com cargas baixas e elevadas rotações. Caso seja este um parâmetro importante para ser avaliado no desempenho do motor, seu peso deverá ser elevado, simultaneamente à sua relevância.

Referente ao rendimento térmico, RT (Figura 50) pode-se afirmar que nesta formulação de pesos ($CO^5-HC^5-NOx^5-ET^{10}-TS^5$), onde a taxa de substituição tem um peso menor, o RT vai apresentar valores (otimizados) perto dos máximos experimentais.

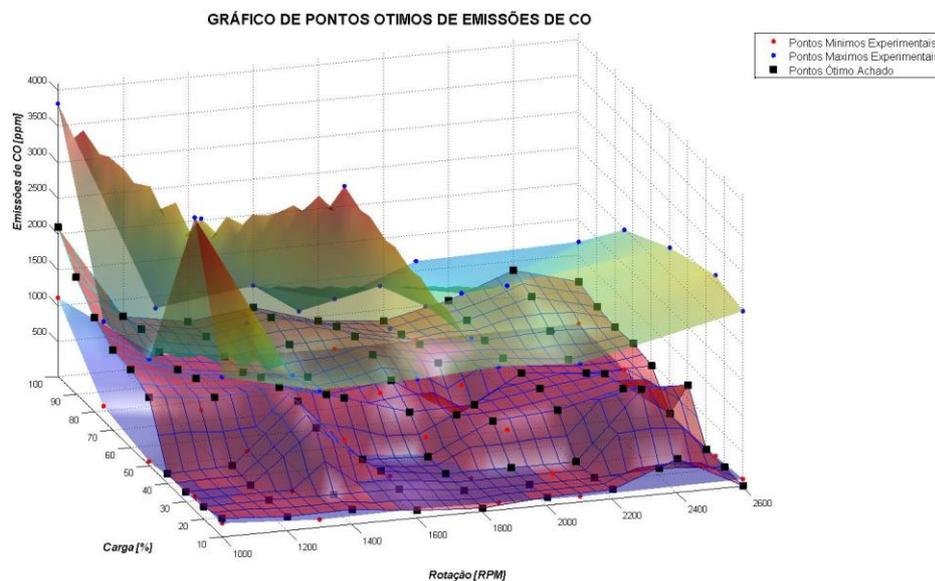


Figura 47. Desempenho do CO, pesos: $CO^5-HC^5-NOx^5-ET^{10}-TS^5$.

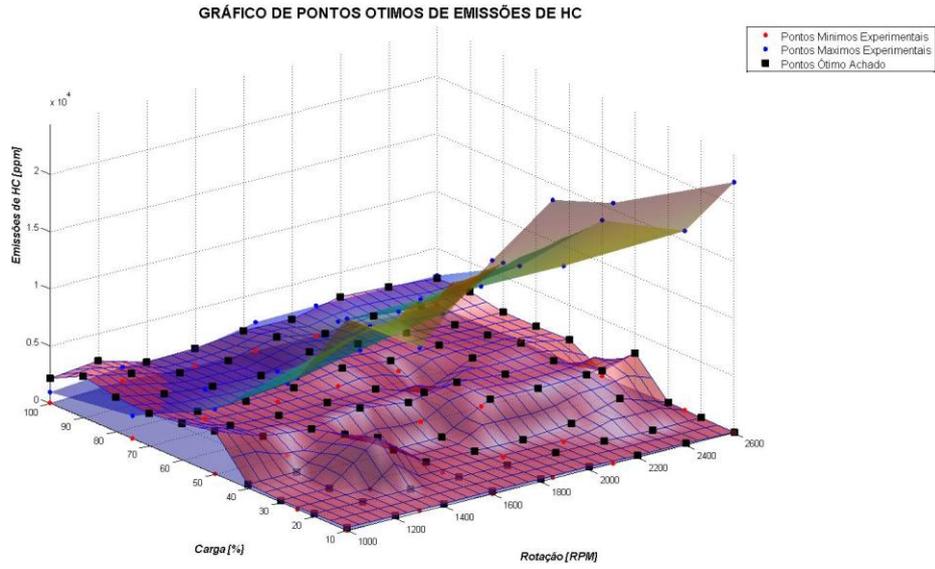


Figura 48. Desempenho do HC, pesos: $CO^5-HC^5-NOx^5-ET^{10}-TS^5$.

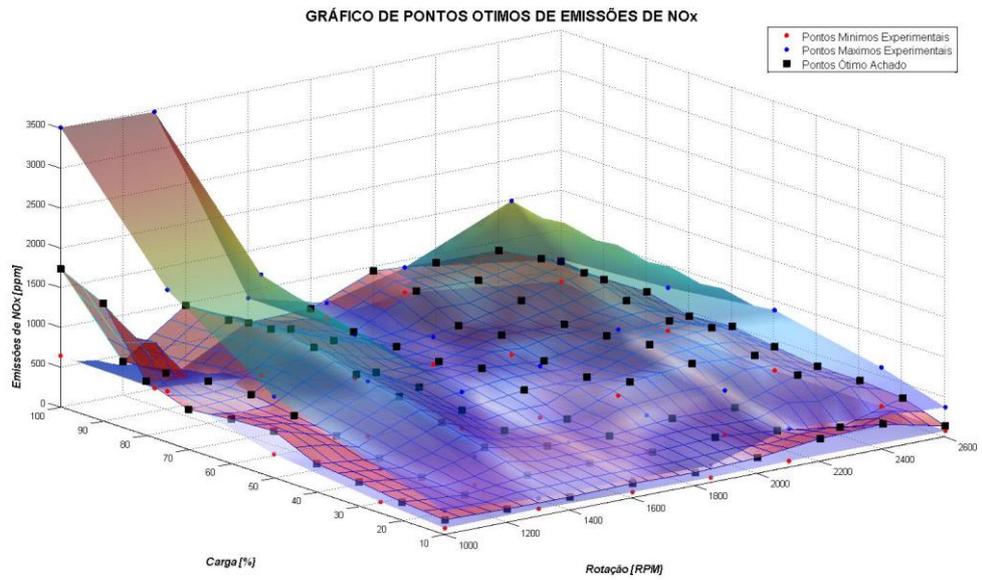


Figura 49. Desempenho do NOx, pesos: $CO^5-HC^5-NOx^5-ET^{10}-TS^5$.

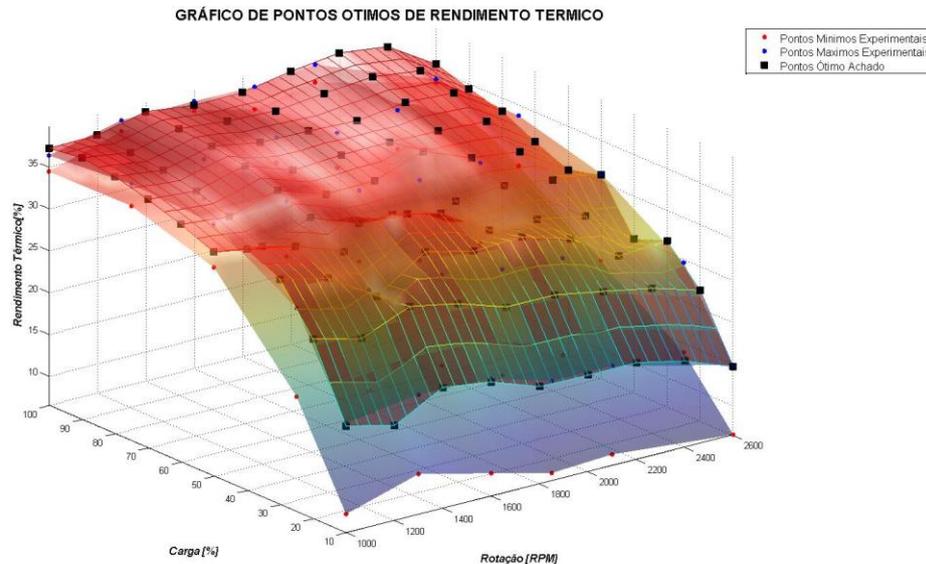


Figura 50. Desempenho do RT, pesos: $CO^5-HC^5-NOx^5-ET^{10}-TS^5$.

Nas Figura 51, Figura 52, Figura 53 e Figura 54, são apresentadas as emissões de CO, HC e NOx e o rendimento térmico, respectivamente; com a formulação de pesos $CO^5-HC^5-NOx^5-ET^{10}-TS^{15}$,

Pode-se observar que para o caso de CO e NOx, na Figura 51 e Figura 52, respectivamente, os valores ótimos (com pesos: $CO^5-HC^5-NOx^5-ET^{10}-TS^{15}$) ficam acima dos valores quando comparados com o caso de $CO^5-HC^5-NOx^5-ET^{10}-TS^5$. O fato de dar maior peso à taxa de substituição tem como consequência o aumento dos níveis de CO e HC. Isto é mais evidente em baixas cargas. Para cargas elevadas os níveis de CO e HC são praticamente os mesmos, isto devido a que a taxa de substituição ótima é a mesma para ambos os pesos.

Para o caso de NOx com peso $CO^5-HC^5-NOx^5-ET^{10}-TS^{15}$ (Figura 53), quando comparado com o NOx com peso $CO^5-HC^5-NOx^5-ET^{10}-TS^5$ (Figura 49), a diferença não é grande, mantendo, em ambos os casos, para baixas cargas, um nível de emissões de NOx perto dos limites inferiores experimentais. Para cargas elevadas os níveis de NOx, para ambos os pesos, mantém-se iguais. Isto devido à taxa de substituição ótima ser a mesma.

A eficiência térmica com os pesos $CO^5-HC^5-NOx^5-ET^{10}-TS^{15}$ (Figura 54), apresenta valores inferiores (cargas baixas), quando comparado com o caso

$CO^5-HC^5-NOx^5-ET^{10}-TS^5$ (Figura 50). Isto é explicado pelo fato de que ao se dar maior peso à taxa de substituição, a eficiência térmica diminui. Em cargas elevadas a eficiência térmica mantém-se em valores iguais (para ambos os pesos), isto devido a que a taxa de substituição ótima é a mesma.

Algumas outras possíveis combinações de peso são apresentadas nos anexo 0 ($CO^5-HC^5-NOx^5-ET^{10}-TS^{20}$), anexo 0 ($CO^5-HC^5-NOx^5-ET^{10}-TS^{10}$), anexo 0 ($CO^{10}HC^5-NOx^5-ET^{10}-TS^{10}$), anexo 0 ($CO^{10}-HC^5-NOx^{10}-ET^{10}-TS^5$), anexo 0 ($CO^{10}-HC^{10}-NOx^{10}-ET^{10}-TS^0$), e o anexo 0 ($CO^{10}-HC^{10}-NOx^{10}-ET^{10}-TS^5$).

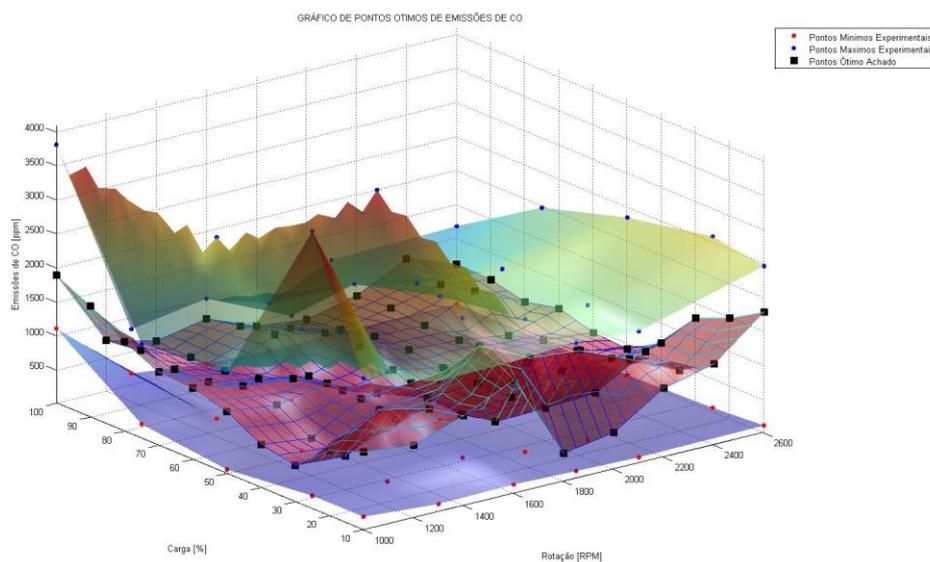


Figura 51. Desempenho do CO, pesos: $CO^5-HC^5-NOx^5-ET^{10}-TS^{15}$.

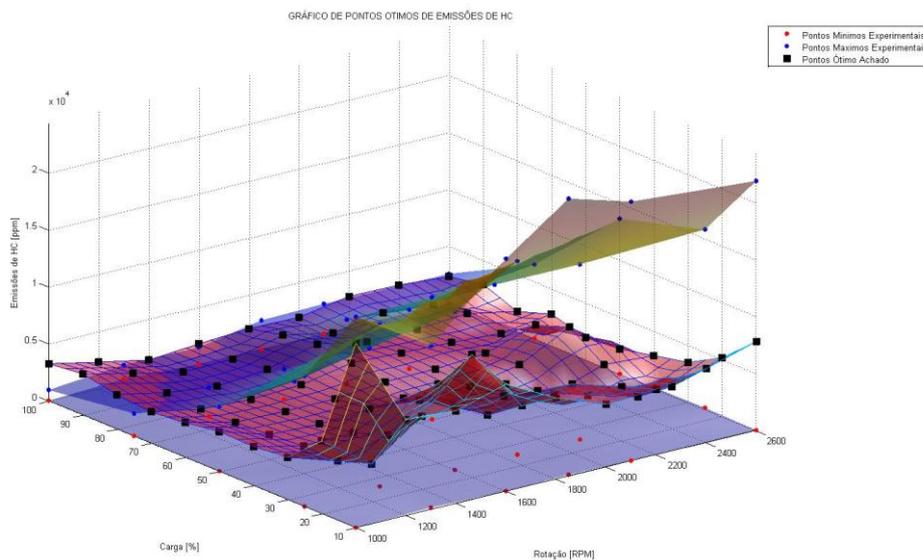


Figura 52. Desempenho HC, pesos: $CO^5-HC^5-NOx^5-ET^{10}-TS^{15}$.

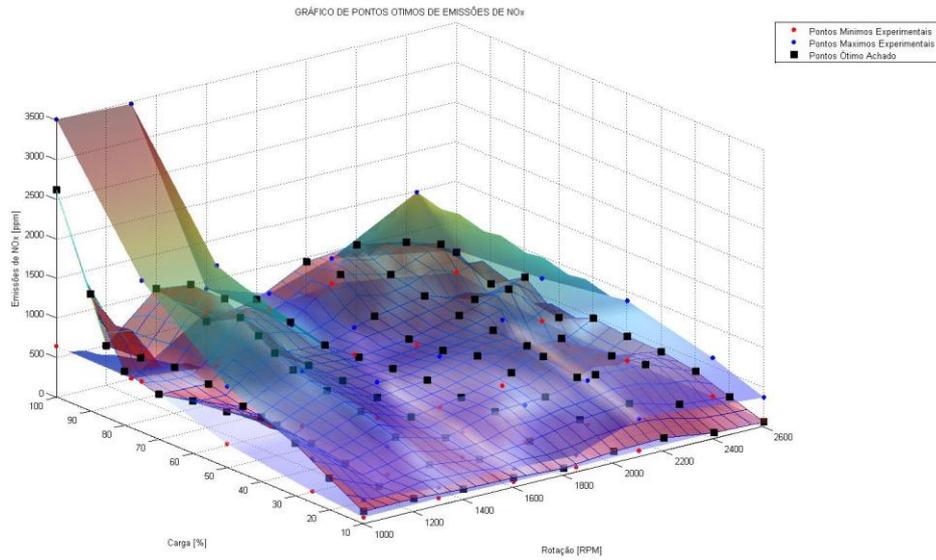


Figura 53. Desempenho NOx, pesos: $CO^5-HC^5-NOx^5-ET^{10}-TS^{15}$.

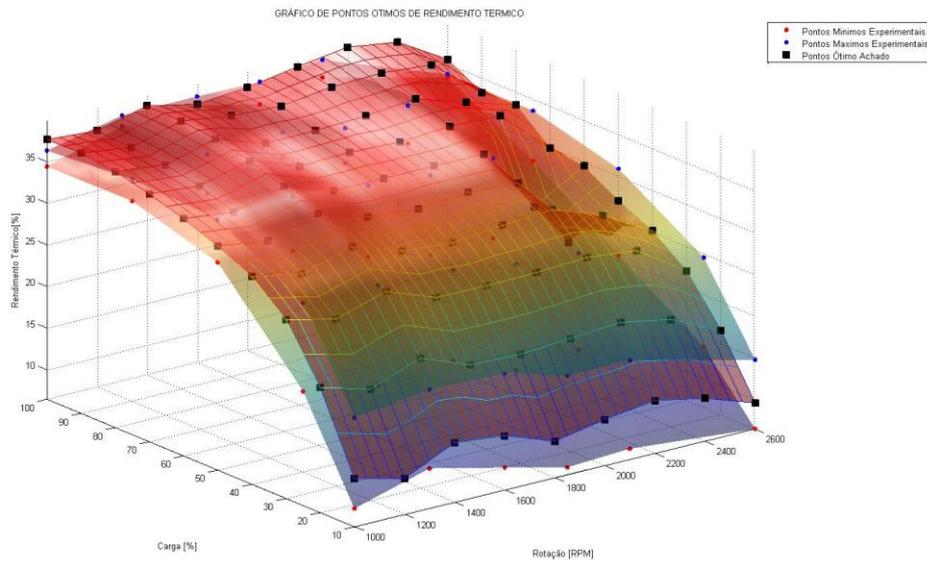


Figura 54. Desempenho do RT, pesos: $CO^5-HC^5-NOx^5-ET^{10}-TS^{15}$.

7.4.2. Validação do Modelo

Foram avaliados alguns casos em particular, para avaliar o desempenho do sistema de otimização (rede neural - algoritmo genético). O processo de

validação simplesmente verifica como é que os dados otimizados se comportam referente aos experimentais. É bem verdade que nos mapas 3D apresentados já é possível verificar isso, mas uma análise em 2D se faz necessária.

Nas Figura 55, Figura 56, Figura 57, Figura 58 e Figura 59, apresenta-se o processo de validação de dados para a rotação de 1850 RPM, para 10 %, 25%, 50%, 75%, e 100% de carga, respectivamente. Para todas as Figuras, pode-se observar que são apresentados os resultados experimentais e os resultados do algoritmo genético (AG). Como anteriormente apresentado, as linhas representam as previsões e os pontos indicam os dados experimentais. Para os resultados de otimização do AG são apresentados dois casos: o primeiro reflete uma formulação de pesos $CO^5-HC^5-NOx^5-ET^{10}-TS^5$, e o segundo é para $CO^5-HC^5-NOx^5-ET^{10}-TS^{10}$. Estes pontos singulares são representados por símbolos apresentados nas próprias figuras.

Para o caso de 10% e 25% de carga (Figura 55 e Figura 56 respectivamente), a configuração do peso $CO^5-HC^5-NOx^5-ET^{10}-TS^5$ indica uma taxa de substituição ótima no ponto mínimo experimental e a configuração do peso $CO^5-HC^5-NOx^5-ET^{10}-TS^{15}$ indica uma taxa de substituição ótima perto do máximo experimental. As emissões ótimas de CO, HC e NOx, para ambas as configurações, estão localizadas perto dos mínimos experimentais. O caso do rendimento térmico indica um maior valor para a taxa de substituição baixa. A temperatura dos gases de escapamento fica elevada para a segunda configuração de pesos ($CO^5-HC^5-NOx^5-ET^{10}-TS^{15}$), mas dentro dos parâmetros experimentais estabelecidos.

Para o caso de 50% e 75% de carga (Figura 57, e Figura 58 respectivamente), ambas as configurações dos pesos indicam uma taxa de substituição ótima perto do máximo experimental. As emissões ótimas de CO, HC, estão localizadas perto dos mínimos experimentais. Já para o caso do NOx, observa-se um valor localizado quase no meio dos valores experimentais máximo e mínimo. O rendimento térmico é considerado aceitável e a temperatura dos gases de escapamento está localizada dentro dos parâmetros experimentais.

Para o caso de 100% de carga (Figura 59), pode-se observar que o ponto de desempenho ótimo fica localizado perto do máximo valor experimental da taxa de substituição. Os valores das emissões são os valores mínimos dessa região, mas não são os mínimos de toda a curva experimental. A eficiência térmica, para ambas as combinações de peso, ficam localizadas no máximo

experimental. Para o caso da temperatura dos gases de escapamento o valor otimizado é o mínimo experimental.

Nas mesmas Figuras (Figura 55 até a Figura 59), pode-se conferir que, em casos de baixa carga, a combinação de pesos, determina uma diferença de pontos ótimos. Isto quer dizer que, quando os pesos são direcionados ao rendimento térmico e as emissões ($\text{CO}^5\text{-HC}^5\text{-NOx}^5\text{-ET}^{10}\text{-TS}^5$), os pontos ótimos vão a para valores de taxa de substituição baixas. Já quando a combinação de pesos privilegie tanto o rendimento térmico quanto a taxa de substituição ($\text{CO}^5\text{-HC}^5\text{-NOx}^5\text{-ET}^{10}\text{-TS}^{15}$), os pontos ótimos vão a para valores mais altos da taxa de substituição. Em cargas elevadas (acima de 50%), pode-se observar que as emissões e o RT têm valores mínimos nos extremos das curvas experimentais. Então, independente da combinação de pesos analisada, o ponto ótimo achado estará sempre na máxima taxa de substituição. Sendo que, no caso de 100% de carga com maior razão, o ponto ótimo está localizado no extremo de máxima taxa de substituição. Isto devido à maior eficiência térmica localizar-se neste ponto.

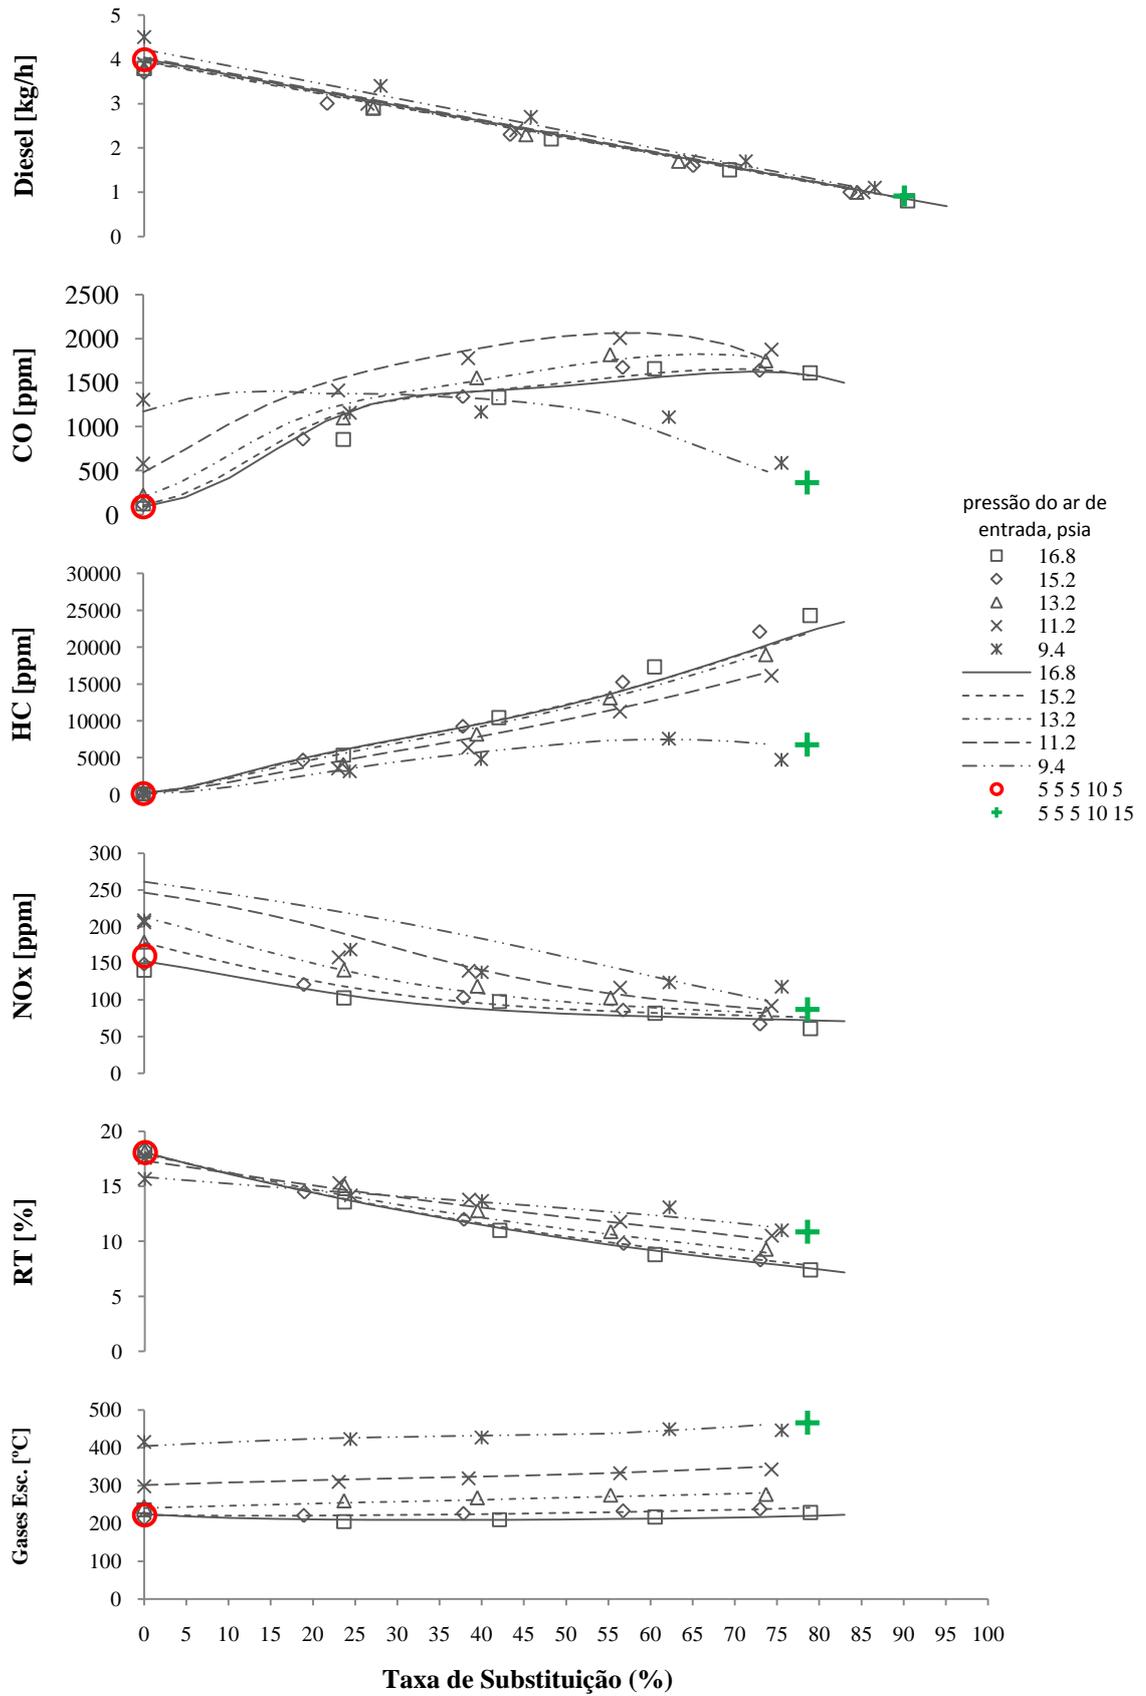


Figura 55. Validação de dados rotação 1850 RPM, 10 % de carga.

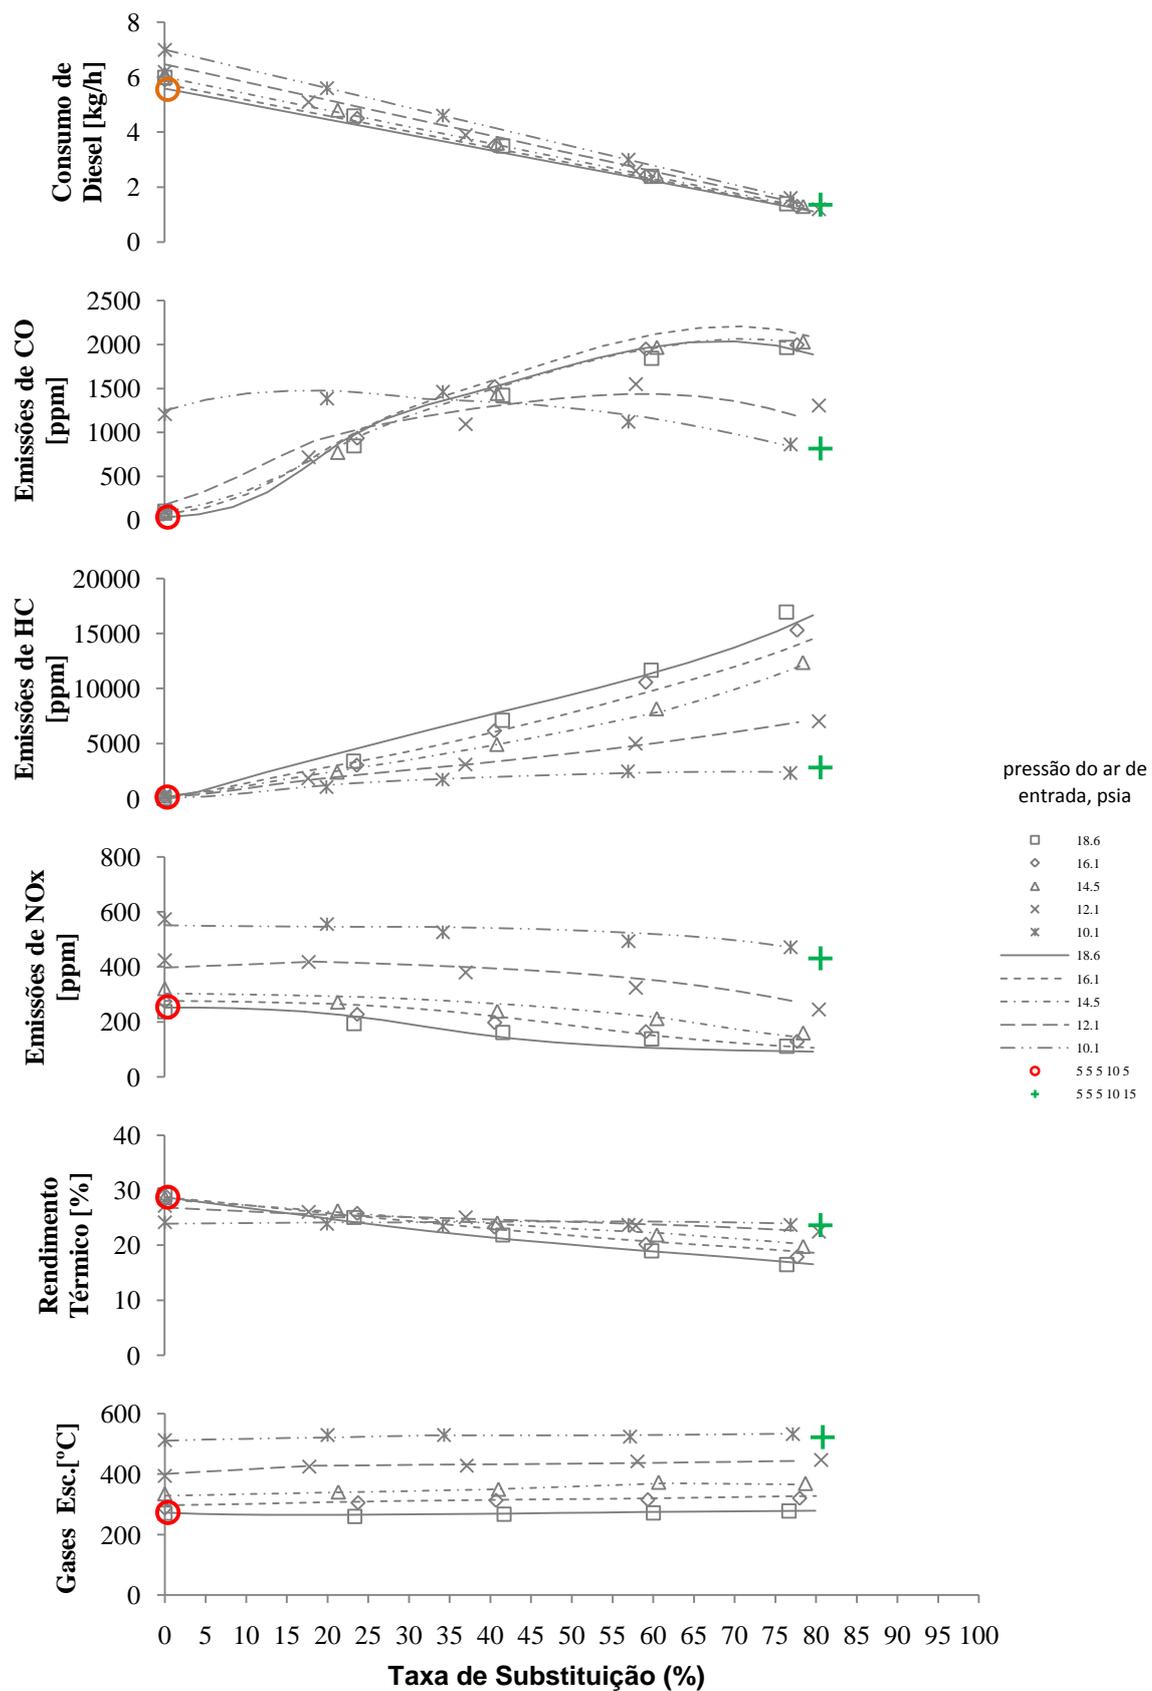


Figura 56. Validação de dados rotação 1850 RPM, 25 % de carga.

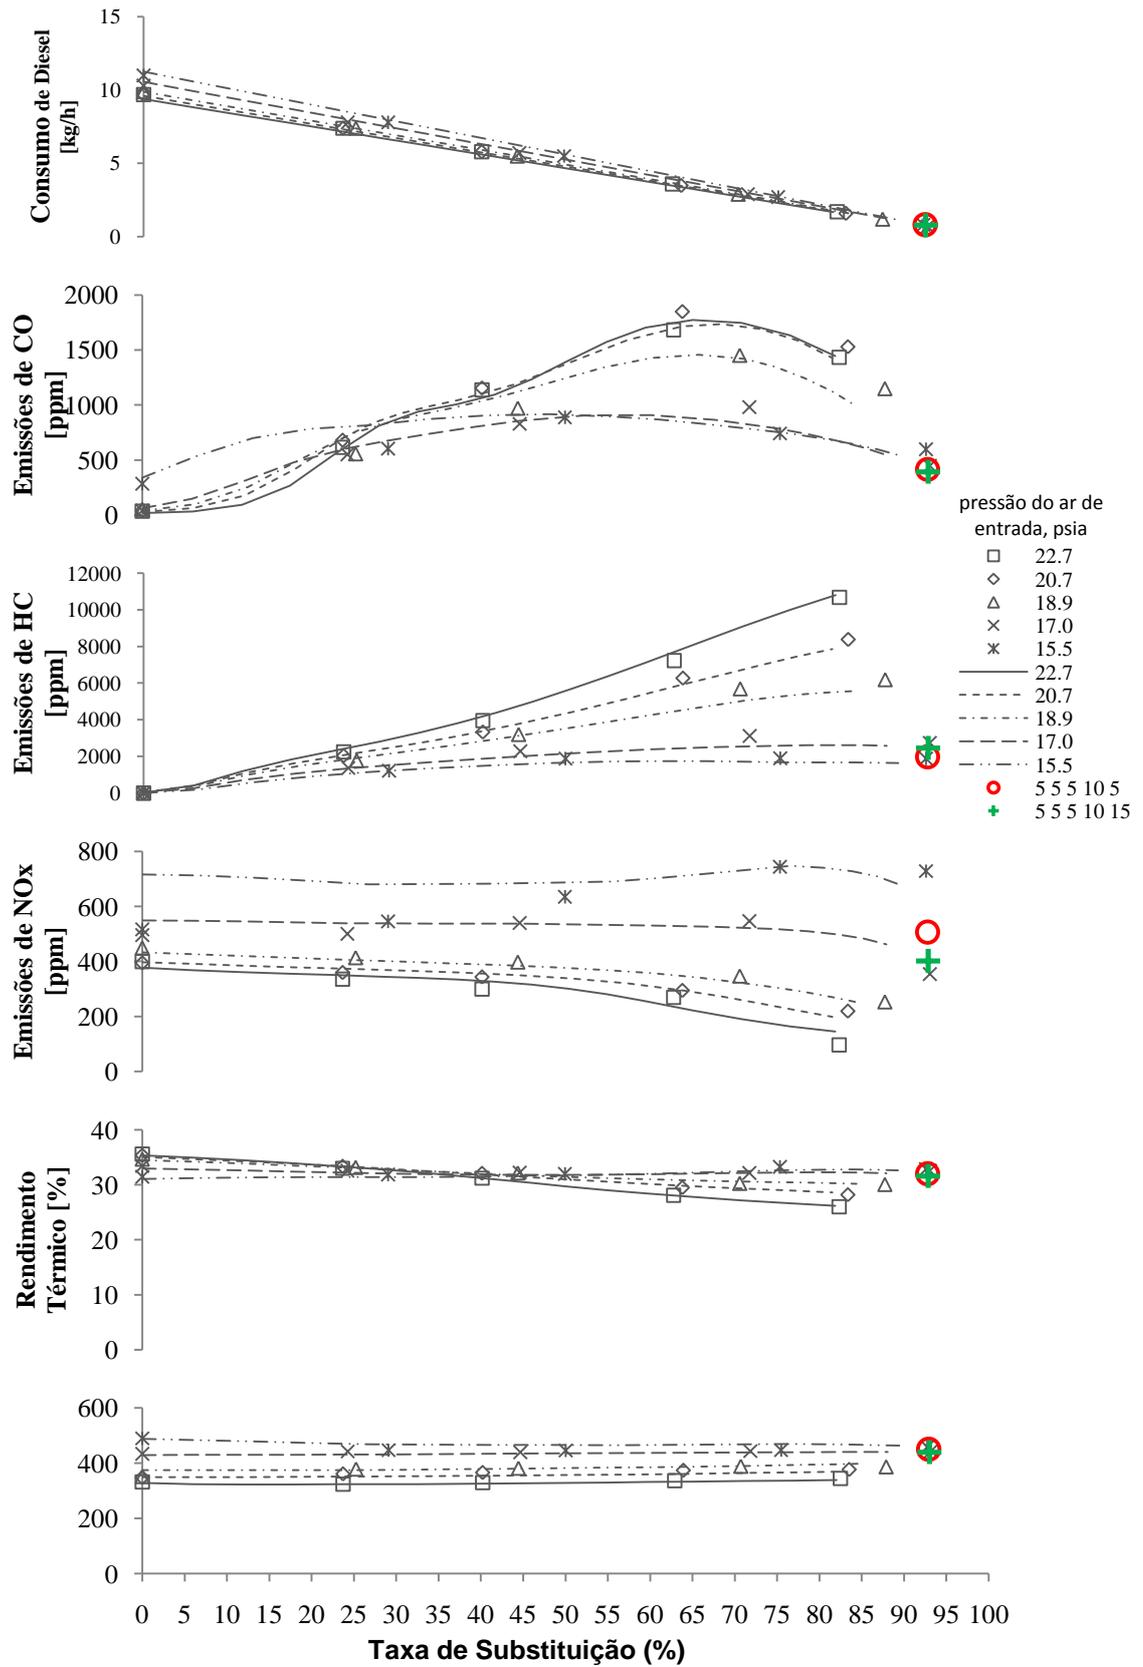


Figura 57. Validação de dados rotação 1850 RPM, 50 % de carga.

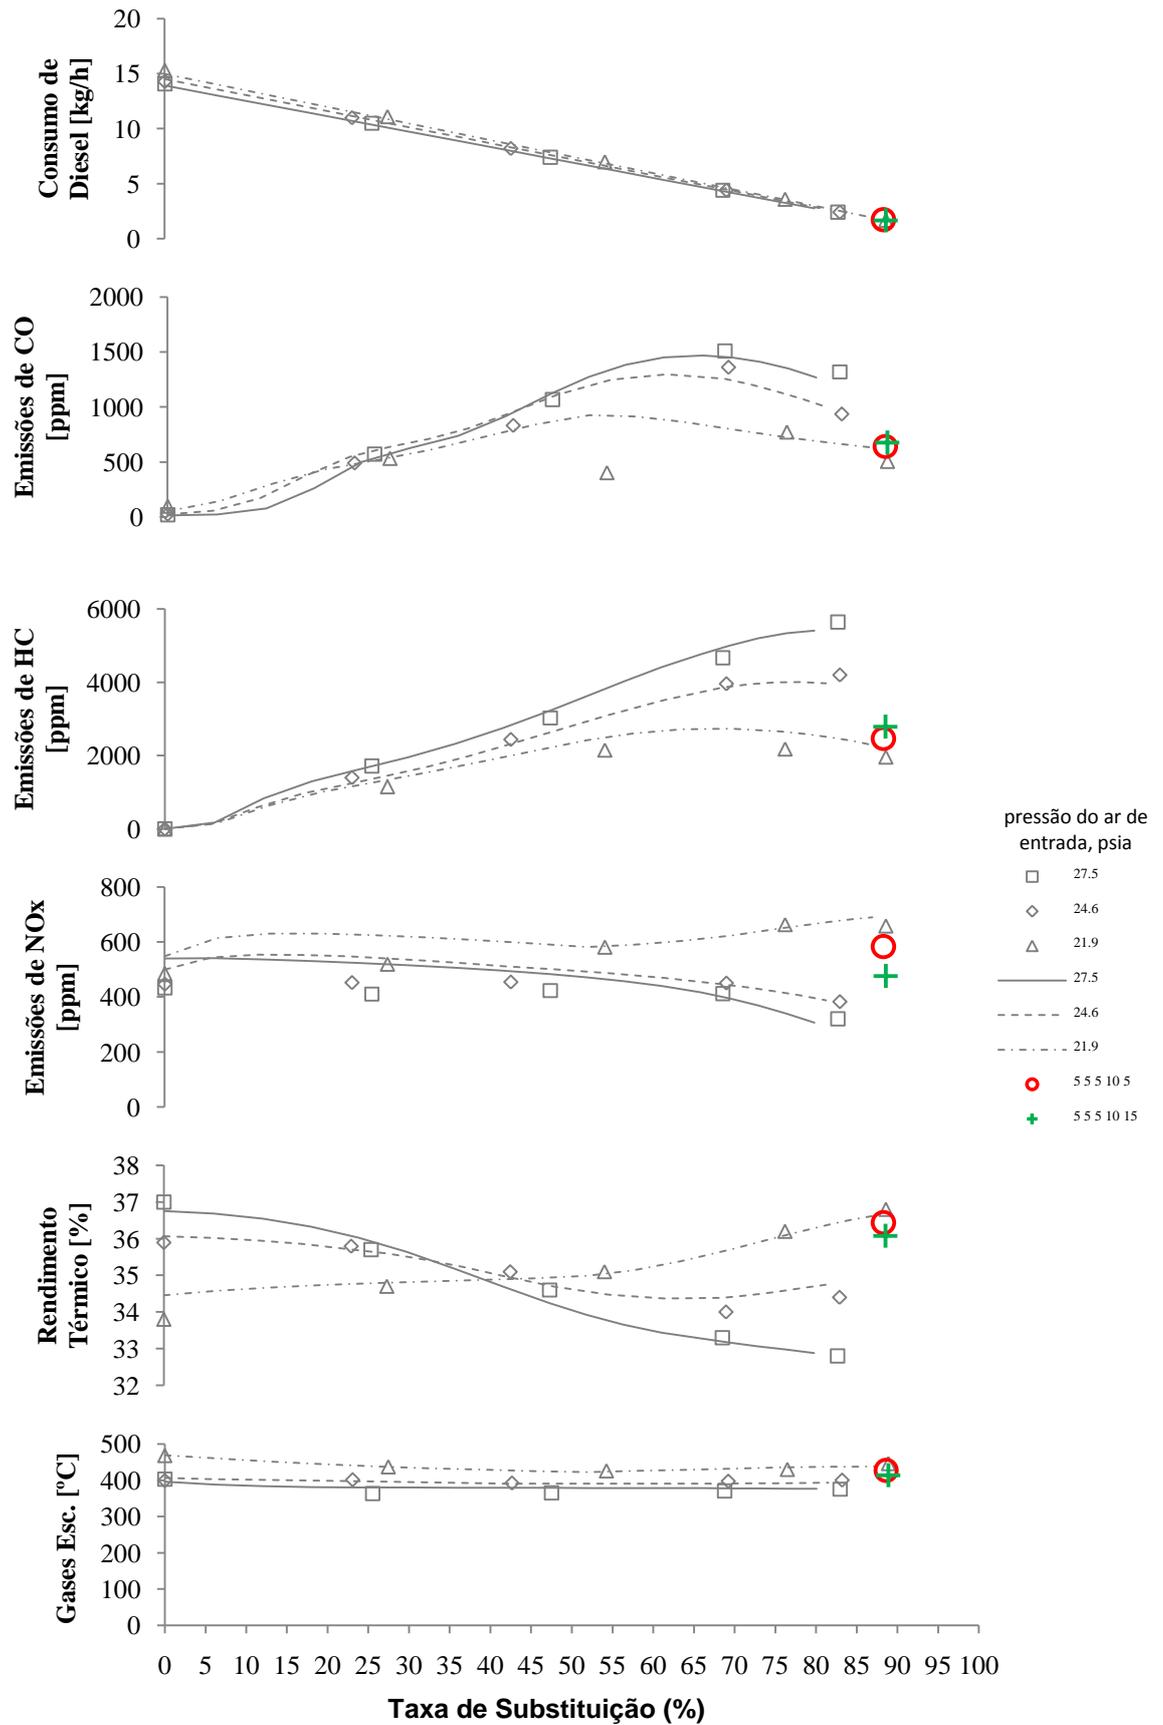


Figura 58. Validação de dados rotação 1850 RPM, 75 % de carga.

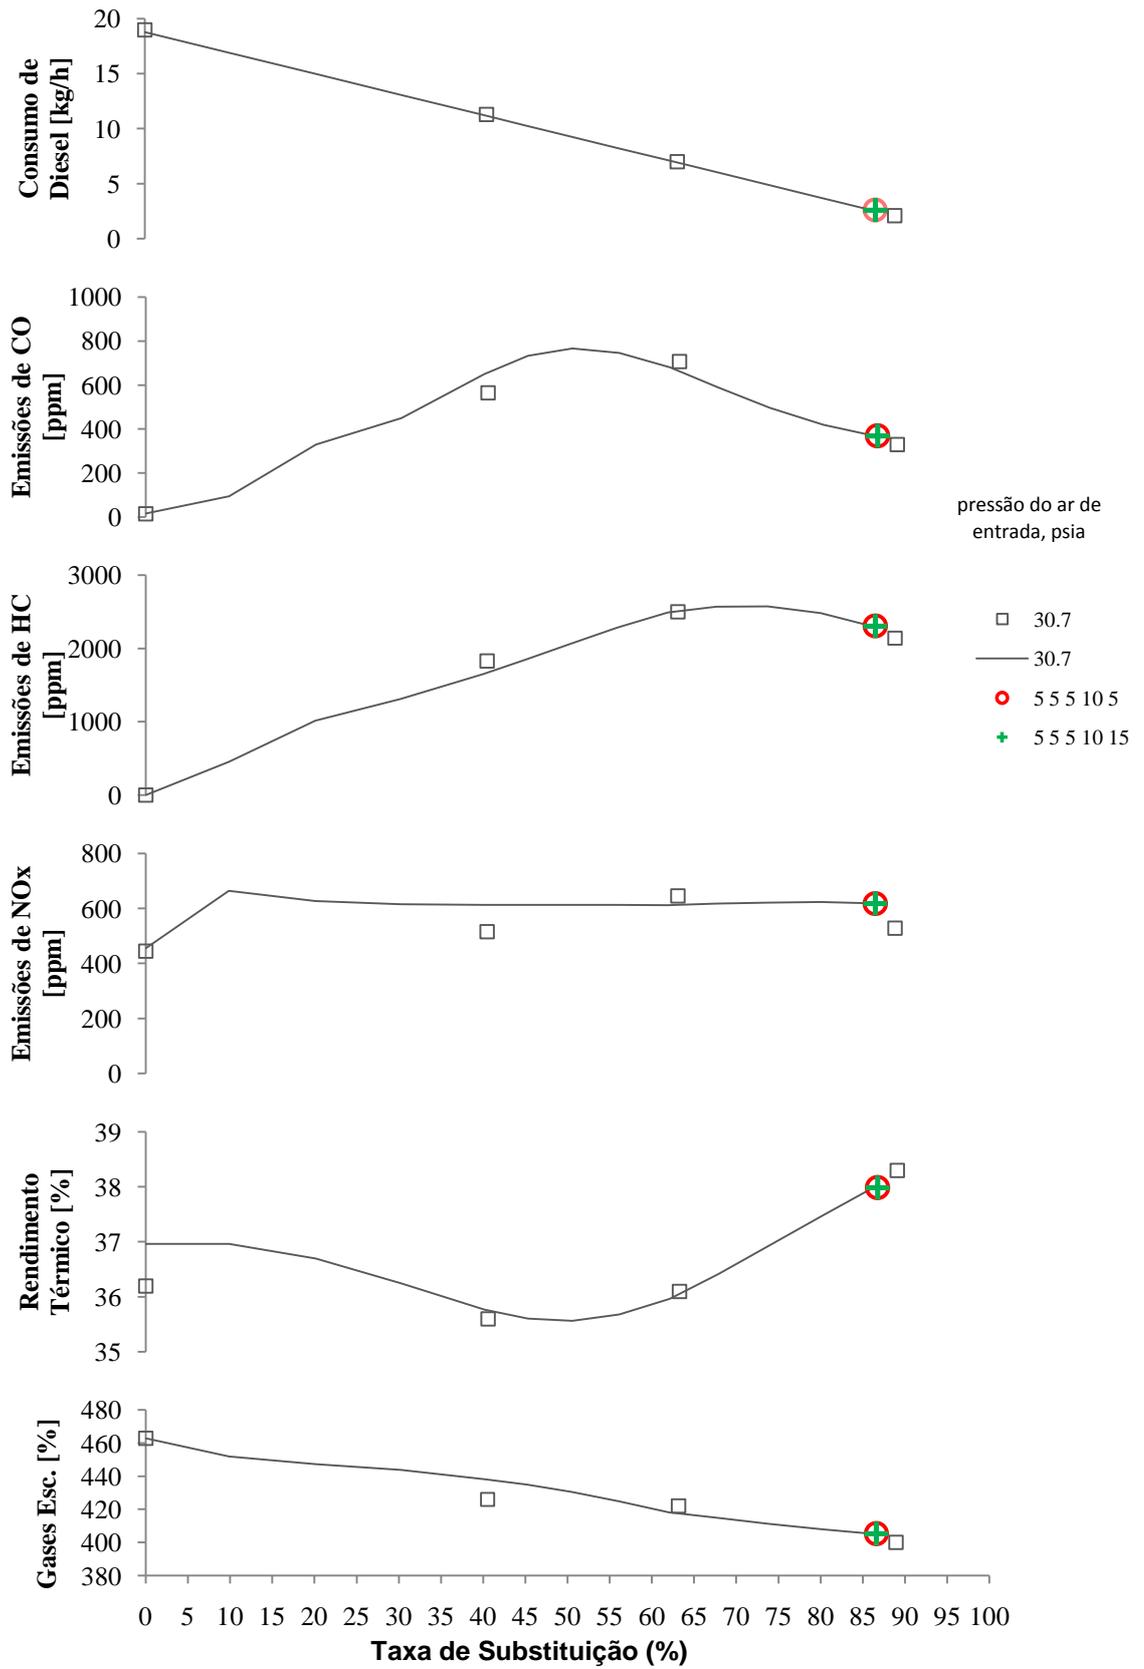


Figura 59. Validação de dados rotação 1850 RPM, 100 % de carga.

A Figura 60 resume os resultados observados para o caso específico da combinação de pesos: $CO^5-HC^5-NOx^5-ET^{10}-TS^{15}$. Os pontos cheios representam os limites experimentais, enquanto os demais os resultados da otimização. Como mencionado anteriormente, espera-se que a taxa de substituição seja a maior possível. Para esta combinação de pesos, os valores das emissões se mantêm perto dos mínimos experimentais à exceção do NOx , que flutua próximo aos máximos experimentais.

A Figura 61 mostra uma análise para a combinação de pesos: $CO^5-HC^5-NOx^5-ET^{10}-TS^{xx}$, com diferentes pesos para a taxa de substituição (TS^5, TS^{10}, TS^{12} e TS^{15}). Como mencionado anteriormente, pesos baixos (TS^5, TS^{10}) apresentam duas tendências para a taxa de substituição: mínima, nas baixas cargas, e máxima, nas cargas elevadas. Já para valores de pesos maiores (TS^{12} , e TS^{15}), os resultados indicam que a taxa de substituição ótima é sempre a máxima, independente da carga.

A tendência do algoritmo genético (AG), no processo de otimização, é localizar pontos com emissões mínimas e eficiências térmicas e taxas de substituição máximas. Dependendo dos pesos assinalados para cada variável, o AG pode indicar pontos localizados nos extremos de taxas de substituição experimentais.

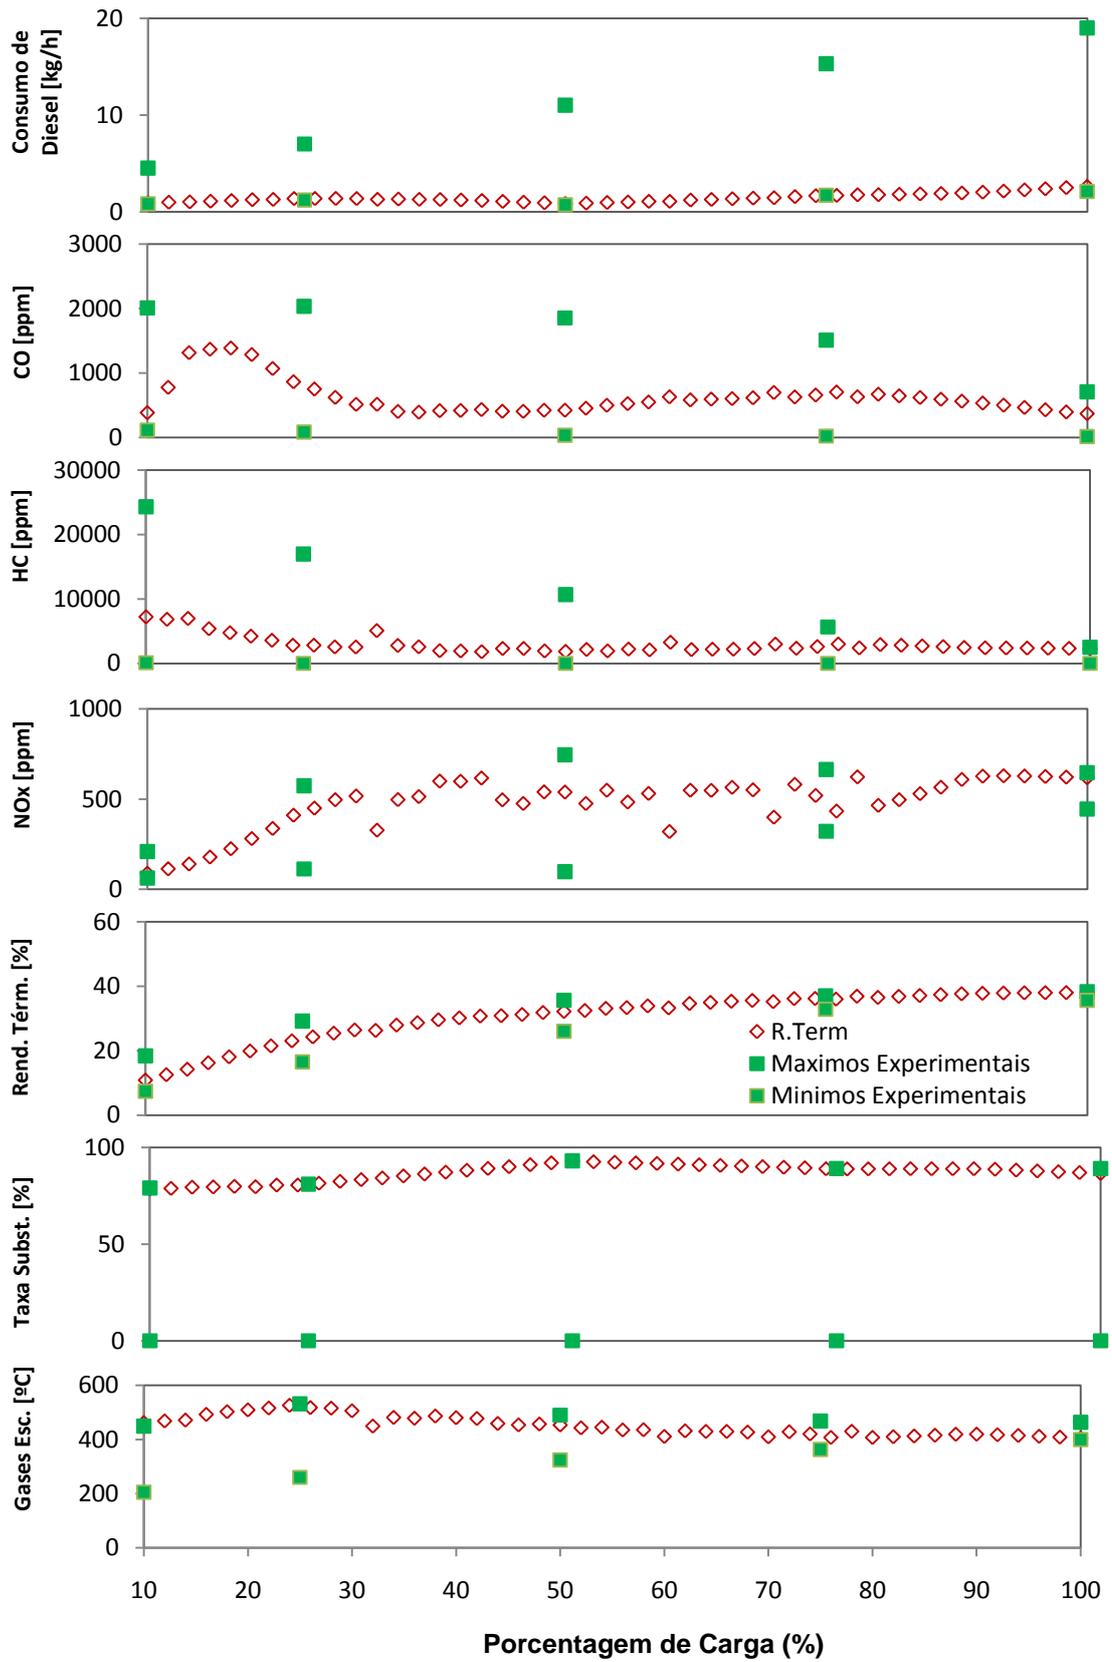


Figura 60. Validação em 1850 RPM, pesos: $CO^5-HC^5-NOx^5-ET^{10}-TS^{15}$.

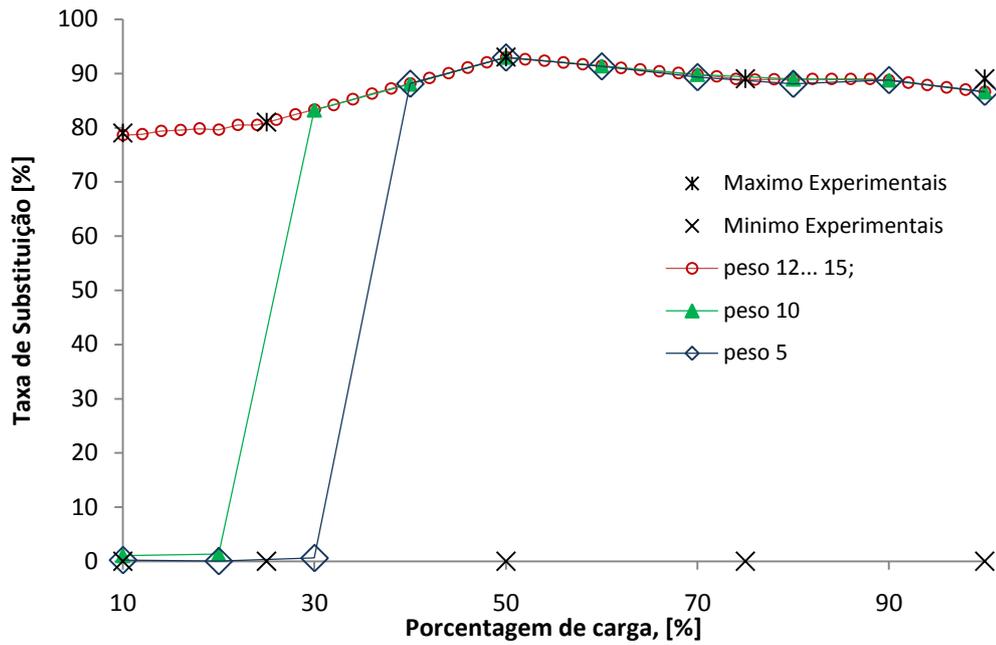


Figura 61. Validação da TS com diferentes pesos e porcentagens de carga.

O processo de otimização vai depender dos objetivos pretendidos para o desempenho do motor. Pode-se assim ter diferentes escolhas para que o AG ache os parâmetros apropriados. Com uma combinação em particular, o AG pode dar preferência a cada parâmetro, como é mostrado nos anexos.