

Aplicação de Redes Neurais ao Estudo da Capacidade de Carga de Fundações à Tração

Aureo Pinheiro Ruffier e Erico Fagundes Anicet Lisboa
CEPEL, Rio de Janeiro, RJ

Fernando Artur Brasil Danziger
COPPE/UFRJ, Rio de Janeiro, RJ

RESUMO: Neste trabalho é apresentada uma aplicação de Inteligência Artificial, empregando-se a técnica das Redes Neurais ao estudo de fundações sujeitas a esforços de tração, assentes em terrenos inclinados. Valores de capacidade de carga obtidos a partir desta técnica forneceram excelentes resultados quando comparados a resultados experimentais de fundações em solos argilosos em condição não drenada. O Método de Grenoble foi também empregado na comparação, tendo fornecido resultados muito bons no caso de terrenos horizontais. Fatores corretivos são sugeridos para casos da prática da engenharia e inclinações do terreno de 15° e 30° para a utilização do método em fundações com profundidade de assentamento acima da profundidade crítica.

PALAVRAS-CHAVES: Fundações, Capacidade de Carga, Tração, Taludes, Redes Neurais.

1 INTRODUÇÃO

Fundações submetidas à tração podem ser encontradas em diversos campos da engenharia, tais como estruturas off-shore, estruturas estaiadas, torres de transmissão de energia elétrica, etc. Aborda-se neste trabalho o caso particular de fundações assentes em terrenos inclinados (taludes), caso freqüente em torres de transmissão de energia.

Atualmente existem diversas formulações desenvolvidas para estimar a capacidade de carga à tração de fundações (ver Danziger 1983 e Ruffier 1985, por exemplo). Tais formulações, entretanto, são restritas ao caso de terrenos horizontais.

A técnica das Redes Neurais, que vem tendo larga utilização nos mais diversos ramos da engenharia, inclusive na geotecnia (e.g. Goh 1994) permite que, fornecido um determinado conjunto de dados ou padrões de comportamento, sejam feitas previsões para conjuntos similares. Ao se utilizar Redes Neurais, não se tem a pretensão de determinar leis físicas que regem o fenômeno, mas sim obter uma relação que satisfaça ao conjunto de dados apresentado.

A seguir é feita uma breve conceituação da técnica das Redes Neurais e, nos itens subsequentes, a partir de um conjunto de dados de ensaios à tração de placas em taludes, é feita uma aplicação de Redes Neurais a estes ensaios. Um dos métodos de estimativa de capacidade de carga à tração em terrenos horizontais é empregado também na comparação.

2 REDES NEURAIIS

Os comentários a seguir foram extraídos fundamentalmente de Silva (1994).

2.1 Aspectos Biológicos

O cérebro humano possui dezenas de bilhões de neurônios, densamente interconectados (Redes Neurais), que demonstram grande capacidade para armazenar e processar informações.

Os neurônios (Figura 1) são constituídos de uma estrutura básica, formada por um corpo celular (soma), um axônio e diversos dendritos. O axônio liga o corpo celular de sua célula a outros neurônios e os dendritos recebem as terminações dos axônios de outros neurônios.




Figura 1. Modelo de um Neurônio Biológico

Deste modo, a conexão entre os neurônios, denominada sinapse (Figura 2), é formada pelo encontro da terminação axônica de um neurônio com o corpo celular ou dendrito de outro neurônio. As sinapses, além de permitirem a união de vários neurônios, funcionam como válvulas controladoras do fluxo de informação em uma Rede Neuronal.




Figura 2. Conexões entre neurônios - Sinapses

Existem dois tipos de sinapse: as excitatórias e as inibitórias. As sinapses excitatórias fornecem um sentido de cooperação entre os neurônios, permitindo a passagem de informações entre eles. Já as sinapses inibitórias dificultam ou coíbem a passagem de informações, sugerindo uma idéia de competição entre as sinapses.

Cada sinapse tem ainda uma eficiência diferente (peso sináptico). Assim, uma única saída (axônio) de um neurônio pode sensibilizar diferentemente os outros neurônios aos quais está conectado.

A capacidade do ser humano de entender, lembrar, memorizar, generalizar, entre outras tarefas, parece estar intrinsecamente relacionada com o tipo e o peso das sinapses existentes nas Redes Neurais.

O conhecimento sobre o funcionamento das Redes Neurais, infelizmente, ainda não é o

bastante para explicar as tarefas extremamente complexas que o cérebro é capaz de realizar.

Entretanto, o que deve ser destacado é que o cérebro realiza todas as suas tarefas de forma eficaz, apesar dos neurônios serem sensivelmente mais lentos que os processadores usados nos computadores atualmente. Possivelmente, toda essa eficiência não está na capacidade individual de um neurônio e sim no conjunto formado pela quantidade muito grande deles (dezenas de bilhões) e pela forma como eles estão conectados.

Estes são os principais motivos do homem tentar imitar o modo de funcionamento do cérebro, procurando reproduzir artificialmente as Redes Neurais biológicas e usá-las como ferramenta de computação em diversas áreas.

2.2 Redes Neurais Artificiais

Ao contrário dos sistemas especialistas utilizados na Inteligência Artificial convencional, onde o conhecimento está representado na forma de regras e algoritmos, as Redes Neurais Artificiais (Rumelhart et al. 1986) aprendem através de exemplos, ou seja, o problema é modelado através da apresentação exhaustiva de casos típicos.

A partir desta apresentação, as redes tendem a generalizar o seu conhecimento e passam a responder corretamente a casos novos, desde que parecidos com os exemplos aprendidos. Assim, mesmo diante de entradas incompletas ou inesperadas, a rede tende a fornecer uma saída razoavelmente correta.

Esta generalização advém não só da capacidade de aprendizado das redes mas também da memória da rede estar distribuída, ou seja, o conhecimento estar espalhado pelos diversos neurônios na forma de pesos.

A distribuição de sua memória torna as Redes Neurais Artificiais tolerantes a falhas, ou seja, a perda de alguns neurônios não trará como consequência a destruição de uma quantidade considerável de informação.

Outra característica bastante interessante é a sua capacidade de processamento paralelo (originada da densa rede de conexões entre os neurônios), o que a torna bastante útil para aplicações em tempo real devido à alta

velocidade que o processamento paralelo proporciona.

Uma Rede Neural Artificial é composta por vários neurônios (também denominados elementos de processamento) organizados em grupos chamados de camadas. As camadas podem ser classificadas em três tipos:

- Camada de Entrada → é aquela em que as informações são apresentadas à rede;
- Camada de Saída → é a camada em que se visualizam os resultados, ou seja, a que mostra a resposta da rede a uma entrada apresentada;
- Camadas Escondidas ou Intermediárias → são todas as camadas existentes entre a camada de saída e a camada de entrada.

Tipicamente, a topologia de uma Rede Neural (Figura 3) consiste em uma seqüência de camadas interligadas completamente ou aleatoriamente com as camadas adjacentes.




Figura 3. Organização em camadas de uma Rede Neural qualquer

Cada ligação possui ainda um peso, podendo assumir qualquer valor. O Padrão de Conexão (Eficiência Sináptica) é a base do conhecimento da rede e é caracterizado pelos tipos de ligações entre os neurônios e seus respectivos pesos.

2.3 Considerações Finais

Quando se utiliza Redes Neurais determina-se uma arquitetura (número de neurônios, tipos de conexões, etc.) e, uma vez que esta esteja estabelecida, otimiza-se um conjunto de pesos para que a rede simule o conjunto de entrada. Espera-se que a rede generalize estes resultados (apresente resultados satisfatórios para dados com os quais ela não tenha sido treinada). Isto

depende basicamente do conjunto de treino escolhido.

Matematicamente falando, a rede achará, para o universo em que foi treinada, uma função ou conjunto de funções, de comportamento linear ou não linear, que melhor se ajusta ao fenômeno. Sua aplicabilidade poderá ser avaliada utilizando-se um conjunto de testes significativo.

3 CAPACIDADE DE CARGA DE FUNDAÇÕES À TRAÇÃO

Conforme comentado anteriormente, existem diversos métodos desenvolvidos para a estimativa da capacidade de carga de fundações à tração. Dentre estes métodos, o mais abrangente - aquele que apresenta o maior número de tipos de fundação e características de solos - é, na opinião dos autores do presente trabalho, o desenvolvido na Universidade de Grenoble (e.g. Martin 1966, Batmanabane 1973). O mesmo é, ainda, um método que tem fornecido resultados muito bons quando comparado a resultados de provas de carga (e.g. Barata et al 1978, Danziger 1983, Pereira Pinto 1985). Porém, mesmo este método, bem como outros estudados recentemente (Ruffier 1996), não apresentam o caso de fundações em terrenos inclinados, muito importante para a prática de projeto de fundações de torres de linhas de transmissão, as quais freqüentemente são posicionadas em taludes.

De modo a contornar o problema na prática de projeto, a única possibilidade consiste em se lançar mão dos métodos empregados para terrenos horizontais, considerando-se algum artifício para compensar a inclinação do terreno.

4 CASO ESTUDADO

A base experimental deste trabalho consiste de um conjunto de ensaios à tração, apresentados em Rao e Prasad (1992), de placas em terrenos com inclinação variável.

Estes ensaios consistiram de testes em modelos reduzidos, realizados em centrífuga, de placas de ancoragem circulares com diâmetro de 50 mm. Os testes foram executados em argila

remoldada, preparada em quatro diferentes condições. Para cada condição foram realizados testes a diferentes profundidades relativas D/B (sendo D a profundidade da placa medida no eixo central e B o diâmetro da mesma) e inclinações do terreno i (ver Figura 4).




Figura 4. Parâmetros geométricos de uma placa assente em talude (Rao e Prasad 1992)

Nos ensaios foi usada uma argila marinha de um depósito na costa leste da Índia, com 10% de areia e 90% de silte e argila, limite de liquidez de 82% e de plasticidade 32%. Todos os ensaios foram realizados em condições não drenadas. Um resumo das características dos ensaios pode ser visto na Tabela 1.

Tabela 1. Resumo do programa de ensaios à tração de Rao e Prasad (1992)

w (%)	γ_{sat} (kN/m ³)	C_u (kPa)	Inclinação do terreno, i (graus)	Profundidade relativa (D/B)
75	15,4	1,4	0;15;30;45	1;1,5;2;2,5;3
50	16,9	10,0	0;15;30;45	1;1,5;2;2,5;3;3,5
45	17,3	17,5	0;15;30;45	1;2;3;4
42	17,7	25,0	0;15;30;45	1;2;3;4

Obs.: w=teor de umidade, γ_{sat} =peso específico saturado, C_u =resistência não drenada

A técnica das Redes Neurais foi aplicada a todo o conjunto de dados experimentais, adotando-se um procedimento usual, que é dividir aleatoriamente o conjunto de dados em dois subconjuntos: o de treino, com cerca de 80% dos dados, e o de teste, com os demais 20%.

A Rede Neural é gerada através do conjunto de treino, e aferida através do conjunto de teste, sendo o processo repetido iterativamente até a obtenção do erro mínimo. Tal prática assegura que a rede não ficará especializada em um determinado conjunto de dados, perdendo com isto a capacidade de generalização, que é um

dos principais atributos das Redes Neurais.

Foram feitas também previsões com o Método de Grenoble, o qual pôde ser diretamente aplicado às fundações em terreno horizontal (inclinação de 0°), pois esta situação representa uma das premissas do método. Já para as fundações em terrenos inclinados estimou-se apenas a resistência que seria obtida para uma fundação de profundidade média equivalente, porém em terreno horizontal.

Nas Tabelas 2 a 5 são apresentadas comparações entre os resultados previstos pelo Método de Grenoble e pelas Redes Neurais com os resultados experimentais para os ensaios em terrenos horizontais. Nestas tabelas, bem como nas subseqüentes, $Q_{rup\ exp.}$ =carga de ruptura obtida experimentalmente, $Q_{rup\ Gr.}$ =previsões pelo Método de Grenoble e $Q_{rup\ RN}$ =previsões por Redes Neurais. Nas Tabelas 6 a 9 são apresentados os resultados para terrenos com inclinação i de 15° a 45°.

Nas Figuras 5 a 8 são apresentados gráficos de carga de ruptura experimental e prevista, em função da profundidade relativa, para terrenos com inclinação de 30°. Nas Figuras 9 e 10 são apresentados gráficos, para dois dos solos analisados, nos quais pode-se ver a variação da carga de ruptura em função da inclinação do terreno.

Tabela 2. Resultados para terrenos horizontais com $C_u=1,4$ kPa

D/B	$Q_{rup\ exp.}$ (N)	$Q_{rup\ Gr.}$ (N)	Erro (%)	$Q_{rup\ RN}$ (N)	Erro (%)
1	15,26	11,00	-27,9	11,20	-26,6
1,5	22,06	16,49	-25,2	22,37	1,4
2	25,56	21,99	-14,0	27,70	8,4
2,5	28,52	27,49	-3,6	28,38	-0,5
3	29,28	32,99	12,7	26,35	-10,0
Erro absoluto médio:			16,7		9,4

Tabela 3. Resultados para terrenos horizontais com $C_u=10,0$ kPa

D/B	$Q_{rup\ exp.}$ (N)	$Q_{rup\ Gr.}$ (N)	Erro (%)	$Q_{rup\ RN}$ (N)	Erro (%)
1	64,49	65,44	1,5	74,88	16,1
1,5	100,66	98,17	-2,5	106,34	5,6
2	132,91	130,89	-1,5	133,51	0,5
2,5	153,37	163,62	6,7	156,22	1,9
3	173,84	196,34	12,9	175,28	0,8
3,5	182,52	229,07	25,5	192,18	5,3
Erro absoluto médio:			8,4		5,0

Tabela 4. Resultados para terrenos horizontais com $C_u=17,9$ kPa

D/B	Q_{rup} exp. (N)	Q_{rup} Gr. (N)	Erro (%)	Q_{rup} RN (N)	Erro (%)
1	104,78	103,08	-1,6	100,53	-4,1
2	209,56	206,15	-1,6	189,72	-9,5
3	279,98	309,23	10,4	265,40	-5,2
4	309,17	412,31	33,4	324,27	4,9
Erro absoluto médio:			11,8		5,9

Tabela 5. Resultados para terrenos horizontais com $C_u=25,0$ kPa

D/B	Q_{rup} exp. (N)	Q_{rup} Gr. (N)	Erro (%)	Q_{rup} RN (N)	Erro (%)
1	129,36	130,89	1,2	139,31	7,7
2	248,91	261,78	5,2	256,62	3,1
3	368,46	392,67	6,6	363,22	-1,4
4	438,92	523,57	19,3	442,64	0,8
Erro absoluto médio:			8,1		3,3

Tabela 6. Resultados para terrenos inclinados com $C_u=1,4$ kPa

D/B	i (graus)	Q_{rup} exp. (N)	Q_{rup} Gr. (N)	Erro (%)	Q_{rup} RN (N)	Erro (%)
1	15	14,16	11,00	-22,3	9,4	-33,6
1	30	13,88	11,00	-20,7	7,5	-45,9
1	45	11,41	11,00	-3,6	5,4	-52,5
1,5	15	21,51	16,49	-23,3	21,5	0,1
1,5	30	20,96	16,49	-21,3	20,6	-1,7
1,5	45	17,66	16,49	-6,6	19,5	10,3
2	15	25,56	21,99	-14,0	27,7	8,6
2	30	25,56	21,99	-14,0	27,7	8,6
2	45	23,92	21,99	-8,1	27,6	15,5
2,5	15	28,52	27,49	-3,6	29,0	1,7
2,5	30	27,97	27,49	-1,7	29,7	6,1
2,5	45	27,42	27,49	0,3	30,3	10,6
3	15	29,28	32,99	12,7	27,1	-7,3
3	30	29,28	32,99	12,7	28,1	-4,0
3	45	28,73	32,99	14,8	29,1	1,4
Erro absoluto médio:				12,0		13,9

5 ANÁLISE DOS RESULTADOS

5.1 Terrenos Horizontais

Observa-se das tabelas e gráficos que, mesmo para terrenos horizontais, a técnica das Redes Neurais forneceu erros médios menores que o Método de Grenoble em todos os solos. Esta técnica forneceu erros absolutos menores ou iguais a 10% em todos os casos, exceto para valores de $D/B=1$ nos solos com $C_u=1,4$ kPa (maior erro) e $C_u=10,0$ kPa.

Tabela 7. Resultados para terrenos inclinados com $C_u=10,0$ kPa

D/B	i (graus)	Q_{rup} exp. (N)	Q_{rup} Gr. (N)	Erro (%)	Q_{rup} RN (N)	Erro (%)
1	15	60,56	65,44	8,1	68,7	13,4
1	30	60,56	65,44	8,1	62,5	3,1
1	45	52,71	65,44	24,2	56,2	6,6
1,5	15	96,74	98,17	1,5	100,4	3,8
1,5	30	88,88	98,17	10,5	94,4	6,3
1,5	45	77,10	98,17	27,3	88,4	14,6
2	15	128,98	130,89	1,5	128,0	-0,8
2	30	121,13	130,89	8,1	122,5	1,1
2	45	109,35	130,89	19,7	116,8	6,8
2,5	15	153,37	163,62	6,7	151,1	-1,5
2,5	30	149,45	163,62	9,5	145,9	-2,4
2,5	45	137,67	163,62	18,8	140,7	2,2
3	15	173,84	196,34	12,9	170,2	-2,1
3	30	169,91	196,34	15,6	165,3	-2,7
3	45	162,06	196,34	21,2	160,3	-1,1
3,5	15	182,52	229,07	25,5	186,9	2,4
3,5	30	178,59	229,07	28,3	181,9	1,8
3,5	45	170,74	229,07	34,2	176,9	3,6
Erro absoluto médio:				15,6		4,2

Tabela 8. Resultados para terrenos inclinados com $C_u=17,9$ kPa

D/B	i (graus)	Q_{rup} exp. (N)	Q_{rup} Gr. (N)	Erro (%)	Q_{rup} RN (N)	Erro (%)
1	15	97,91	103,08	5,3	91,1	-6,9
1	30	91,04	103,08	13,2	81,8	-10,1
1	45	84,17	103,08	22,5	72,6	-13,8
2	15	202,69	206,15	1,7	179,9	-11,3
2	30	195,82	206,15	5,3	170,0	-13,2
2	45	161,46	206,15	27,7	160,1	-0,9
3	15	279,98	309,23	10,4	256,2	-8,5
3	30	266,24	309,23	16,1	246,9	-7,3
3	45	259,37	309,23	19,2	237,5	-8,4
4	15	309,17	412,31	33,4	315,9	2,2
4	30	302,30	412,31	36,4	307,4	1,7
4	45	295,43	412,31	39,6	298,7	1,1
Erro absoluto médio:				19,2		7,1

Mesmo o Método de Grenoble forneceu previsões excelentes para D/B até 3, com erros quase sempre inferiores a 10%, exceto no caso do solo com $C_u=1,4$ kPa, a ser comentado a parte. No caso de $D/B=3,5$ e 4, o erro situou-se na faixa de 19 a 33%, com o método fornecendo previsões contrárias à segurança. Vale lembrar que estes casos correspondem a um diferente modelo de comportamento, no qual a fundação se encontra abaixo da profundidade denominada crítica por Martin (1966), de $D/B=2,5$. No caso do solo com $C_u=1,4$ kPa, o Método de Grenoble

Tabela 9. Resultados para terrenos inclinados com $C_u=25,0$ kPa

D/B	i (graus)	Q_{rup} exp. (N)	Q_{rup} Gr. (N)	Erro (%)	Q_{rup} RN (N)	Erro (%)
1	15	119,55	130,89	9,5	126,6	5,9
1	30	109,73	130,89	19,3	114,2	4,0
1	45	80,28	130,89	63,0	101,9	26,9
2	15	239,09	261,78	9,5	242,6	1,5
2	30	219,46	261,78	19,3	228,6	4,1
2	45	199,82	261,78	31,0	214,4	7,3
3	15	358,64	392,67	9,5	350,5	-2,3
3	30	348,82	392,67	12,6	337,4	-3,3
3	45	329,19	392,67	19,3	324,0	-1,6
4	15	438,92	523,57	19,3	432,8	-1,4
4	30	419,28	523,57	24,9	422,5	0,8
4	45	409,47	523,57	27,9	411,6	0,5
Erro absoluto médio:				22,1		5,0

forneceu valores conservativos para $D/B=1$ e 1,5. Entretanto, vale lembrar que este caso corresponde a um solo com valor de C_u dificilmente encontrado na natureza.

5.2 Terrenos Inclinados

Como era esperado, a técnica das Redes Neurais forneceu previsões melhores que o Método de Grenoble quando se considera o conjunto de todas as inclinações e todos os solos. Os erros médios para cada tipo de solo foram inferiores a 15%, e os erros absolutos foram superiores a este valor (aproximadamente) em apenas 4 casos: solo com $C_u=1,4$ kPa, $D/B=1$ e $i=15^\circ$, 30° e 45° , onde a técnica foi conservativa em 34% a 53%, e solo com $C_u=25,0$ kPa, $D/B=1$ e $i=45^\circ$, com erro de 27% a favor da segurança. É importante aqui ressaltar que os maiores erros relativos às Redes Neurais ocorreram em situações extremas. Este fato é ilustrado na Figura 5, para o solo com $C_u=1,4$ kPa, $i=30^\circ$, onde se observa que a técnica produz uma função que se afasta mais dos resultados experimentais para $D/B=1$. O mesmo se observa nas Figuras 9 e 10, onde pode-se verificar que, embora as previsões tenham acompanhado a tendência dos resultados experimentais, em alguns casos de extremos os erros crescem.

No caso do Método de Grenoble, novamente há que distinguir entre o solo extremamente mole e os demais. Para o valor de $C_u=1,4$ kPa, os resultados em média foram muito bons,




Figura 5. Curvas carga de ruptura vs D/B para terreno inclinado a 30° com $C_u=1,4$ kPa




Figura 6. Curvas carga de ruptura vs D/B para terreno inclinado a 30° com $C_u=10,0$ kPa

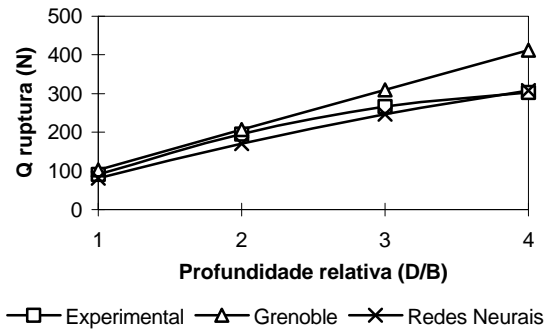


Figura 7. Curvas carga de ruptura vs D/B para terreno inclinado a 30° com $C_u=17,9$ kPa




Figura 8. Curvas carga de ruptura vs D/B para terreno inclinado a 30° com $C_u=25,0$ kPa

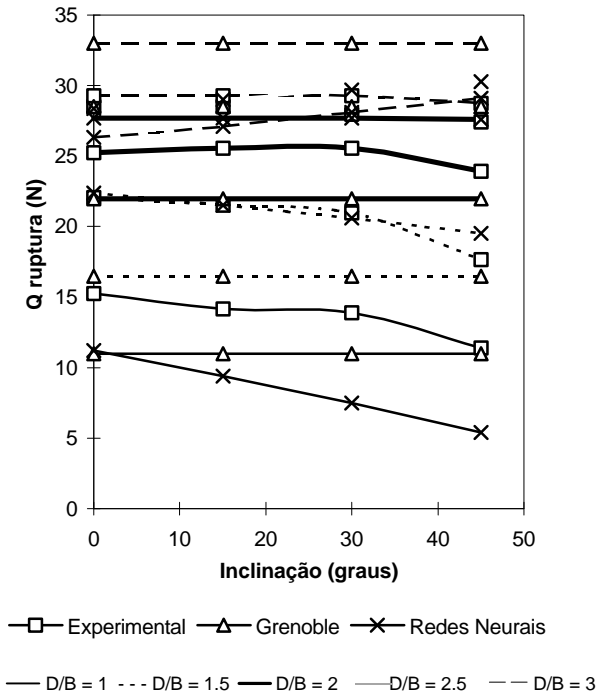


Figura 9. Curvas carga de ruptura vs inclinação do terreno para argila com $C_u=1,4$ kPa

melhores mesmo que a técnica das Redes Neurais. Isso ocorreu em função da tendência, anteriormente mencionada para esse solo, de o Método de Grenoble fornecer valores contrários à segurança para inclinação $i=0^\circ$ ser compensada com a tendência contrária para valores crescentes de i . Para os outros solos, os erros foram sempre contrários à segurança, como seria de se esperar em função da simplificação adotada. Entretanto, erros inferiores a 10% foram sempre obtidos para $i=15^\circ$ e $D/B=1$ a 2,5 (profundidade acima da crítica). Para $D/B=3$, o erro situou-se na faixa de 9,5 a 12,4, tendo crescido para maiores valores de D/B (erro na faixa de 19 a 33% para D/B de 3,5 a 4). Mesmo para $i=30^\circ$, os erros para $D/B=1$ a 2,5 foram sempre inferiores a 20%.

6 CONSIDERAÇÕES ADICIONAIS

Cabem aqui algumas observações quanto à utilização de Redes Neurais a este problema. A primeira é que foi gerada apenas uma Rede Neural para todo o conjunto de ensaios, tendo




Figura 10. Curvas carga de ruptura vs inclinação do terreno para argila com $C_u=25,0$ kPa

como dados de entrada a profundidade relativa da fundação, a inclinação do terreno, a resistência não drenada e o peso específico do solo. O fato dos resultados obtidos terem sido equivalentes para terrenos horizontais e inclinados evidencia a boa aplicabilidade da técnica a este problema específico.

Vale salientar que as Redes Neurais não obtêm uma solução com base em uma análise geotécnica do problema, logo uma rede encontrada para um determinado conjunto de dados só poderia ser aplicada a outro conjunto com muitas ressalvas. Há técnicas que permitem que a cada nova entrada de dados a rede seja “retreinada” (auto-aprendizado), porém não houve necessidade de aplicação destas técnicas ao presente estudo, em função da base de dados disponível. Para algum outro problema pode ser adotada tal abordagem, com a rede sendo melhorada continuamente, na medida em que forem sendo obtidos novos dados. Acredita-se ter sido demonstrado a boa aplicabilidade das Redes Neurais ao problema geotécnico objeto deste estudo.

A técnica de Redes Neurais mostrou-se excelente para a aplicação ao caso estudado, relativo à capacidade de carga de fundações à tração em terrenos inclinados, solos argilosos, com carregamento em condição não drenada. Note-se que foi gerada apenas uma Rede Neural, com somente 80% dos dados disponíveis, e que a mesma foi capaz de fornecer previsões adequadas para todos os dados, quaisquer que fossem a inclinação do terreno, a profundidade relativa ou os parâmetros geotécnicos da argila.

O Método de Grenoble forneceu excelentes previsões para terrenos horizontais, exceção feita ao caso do solo extremamente mole, muito dificilmente encontrado na natureza. Mesmo no caso de terrenos inclinados e profundidade da fundação acima da profundidade crítica, que ocorre para a profundidade relativa $D/B=2,5$ (Martin 1966), as previsões supondo-se terreno horizontal tiveram erro (contra a segurança) de no máximo 10% para inclinação até 15° e 20% para inclinação até 30° . Assim, para a aplicação na prática da engenharia, na falta de um método de análise que leve em conta de forma mais acurada a inclinação do terreno, sugere-se os fatores de correção acima para o emprego do Método de Grenoble, nas mesmas condições para as quais a análise foi efetuada.

A técnica utilizada presta-se apenas a previsões quando se dispõe de uma sólida base experimental representativa do problema estudado. A intenção do presente trabalho foi apresentar uma técnica com grande potencial de aplicação em problemas geotécnicos, e o seu excelente desempenho para um caso específico, de difícil avaliação teórica pelas técnicas atualmente disponíveis.

REFERÊNCIAS

- Barata, F.E., Pacheco, M.P. e Danziger, F.A.B. (1978) Uplift Tests on Drilled Piers and Footing Built in Residual Soils, VI COBRAMSEF, Rio de Janeiro, Brasil, Vol. 3, p. 1-37.
- Batmanabane, L. (1973) *Résistance Maximale a l'Arrachement des Ancrages en Milieu Coherent*, Thèse de Docteur-Ingénieur, Faculté des Sciences de Grenoble, Grenoble, França.
- Danziger, F.A.B. (1983) *Capacidade de Carga de Fundações Submetidas a Esforços Verticais de Tração*, Tese M.Sc., COPPE/UFRJ, Rio de Janeiro, Brasil.
- Goh, A.T.C. (1994) Seismic Liquefaction Potential Assessed by Neural Networks, *Journal of Geotechnical Engineering*, ASCE, Vol. 120, n° 9, p. 1467-1480.
- Martin, D. (1966) *Étude à la Rupture de Différents Ancrages Sollicitées Verticalement*, Thèse de Docteur-Ingénieur, Faculté des Sciences de Grenoble, Grenoble, França.
- Pereira Pinto, C. (1985) *Comportamento de Ancoragens para Torres Estaiadas em Solo Residual*, Tese M.Sc., COPPE/UFRJ, Rio de Janeiro, Brasil.
- Rao, S.N. e Prasad, Y.V.S.N. (1992), Uplift Capacity of Plate Anchors in Sloped Clayed Ground, *Soils and Foundations*, Vol. 32, n°. 4, p. 164-170.
- Ruffier, A.P. (1985) *Análise de Fundações Submetidas a Esforços de Arrancamento, pelo Método dos Elementos Finitos*, Tese M.Sc., COPPE/UFRJ, Rio de Janeiro, Brasil.
- Ruffier, A.P. (1996) *Análise de Fundações Submetidas a Esforços de Arrancamento em Taludes*, Seminário de Qualificação Acadêmica para Doutorado, COPPE/UFRJ, Rio de Janeiro, Brasil.
- Rumelhart, D., McClelland, J. e The PDP Research Group (1986) *Parallel Distributed Processing: Exploration in the Microstructure of Cognition*, MIT Press, Boston, EEUU.
- Silva, V.N.A.L. (1994) *Diagnose em Sistemas de Potência Utilizando Lógica Não-Monotônica e Redes Neurais*, Tese M.Sc., COPPE/UFRJ, Rio de Janeiro, Brasil.