

OVÍDIO JOAQUIM DOS SANTOS JÚNIOR

**ANÁLISE DE DADOS DE INSTRUMENTAÇÃO  
DE TÚNEIS DO METRÔ DE SÃO PAULO –  
UMA ABORDAGEM POR REDES NEURAIS.**

Dissertação apresentada à Escola de Engenharia de São Carlos da Universidade de São Paulo como parte dos requisitos para obtenção do título de Mestre em Geotecnia.

Orientador: Prof. Dr. Tarcísio Barreto Celestino

São Carlos

2006



---

À minha família.

---



---

## AGRADECIMENTOS

A Deus, por ser e existir, nos momentos mais inglórios e nos mais gloriosos, um reduto para a paz e a busca do aperfeiçoamento.

Aos meus pais, Ovídio Joaquim dos Santos e Lourdes da Silva Pereira Santos, pelo apoio ao se mostrarem presentes mesmo à distância e acima de tudo pela compreensão, paciência e dificuldades compartilhadas. Aos meus irmãos, André Pereira Santos e Regina Silva Santos, pelo refúgio de alegria que são, e por comporem a maravilhosa família da qual faço parte.

Ao Prof. Dr. Tarcísio B. Celestino, pelas orientações e condução dos trabalhos, mas principalmente pela compreensão e amizade cultivadas nesse período.

Aos amigos, onde o simples fato de saber que o auxílio seria pronto e imediato, a qualquer momento já seria motivo para agradecer: Eng. Fernando L. Lavoie, um modelo de respeito e consideração; Eng. Rafael R. Plácido e Eng<sup>a</sup>. Thelma S. M. M. Kamiji, sempre presente, do futebol para a vida (amigos... amigos... futebol à parte); Eng. José F. F. Valente e Eng<sup>a</sup>. Débora Valente, ele, a voz da experiência e o apoio, ela sempre alegre e sorridente levando alegria no viver; Geól. José Miguel P. Garcia, no limiar entre amigo e um segundo pai; Roberto H. Remédio, pelas conversas sobre a vida e o viver; Eng<sup>a</sup>. Sílvia D. Levis, uma troca de ajuda sob a mesma tutela; Eng<sup>a</sup>. Karla M. W. Rebelo, pela partilha de experiências; Eng. Cleber D. Assis, pela ajuda nas lembranças por que “um homem que esquece suas origens, esquece a si mesmo”.

À Lini de Pádua Silva que, principalmente nessa reta final, mostrou o poder do amor pra trazer a alegria, a auto-estima e a valorização à vida de um homem.

---

---

Aos colegas de Pós-Graduação do Departamento de Geotecnia. Enumerá-los um a um seria impossível, mas tenham a certeza de que o apoio e a confiança mostrados nunca serão esquecidos.

Aos professores, funcionários e técnicos do Departamento de Geotecnia. Em especial ao Eng. Benedito O. de Souza, um exemplo de calma, tranquilidade e retidão.

Ao Prof. Dr. Glauco Túlio Pessa Fabri pelas importantes colaborações, sugestões e contribuição com a experiência na área de estudo.

À Companhia do Metropolitano de São Paulo - Metrô por disponibilizar os dados utilizados no estudo. Especialmente ao geólogo Hugo Cássio Rocha e aos engenheiros Marcelo Matsui, Marco Aurélio Peixoto da Silva e Francisco Ribeiro Neto, pelo apoio no esclarecimento das informações e pelo auxílio no tratamento dos dados estudados.

À Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) pela concessão da bolsa de mestrado e pelo apoio financeiro para a realização desta pesquisa.

---

---

## **NÃO SEI...**

Não sei... se a vida é curta...

Não sei...

Não sei...

se a vida é curta  
ou longa demais para nós.

Mas sei que nada do que vivemos tem sentido,  
se não tocarmos o coração das pessoas.

Muitas vezes basta ser:  
colo que acolhe,  
braço que envolve,  
palavra que conforta,  
silêncio que respeita,  
alegria que contagia,  
lágrima que corre,  
olhar que sacia,  
amor que promove.

E isso não é coisa de outro mundo:  
é o que dá sentido à vida.

É o que faz com que ela  
não seja nem curta,  
nem longa demais,  
mas que seja intensa,  
verdadeira e pura...  
enquanto durar.

*(Cora Coralina)*

---





---

## RESUMO

SANTOS JR, O.J. (2006) Análise de dados de instrumentação de túneis do metrô de São Paulo: uma abordagem por Redes Neurais, Dissertação (Mestrado), Escola de Engenharia de São Carlos, Universidade de São Paulo, 160p.

Atualmente, a escavação de túneis rasos em regiões densamente ocupadas requer medidas severas para reduzir riscos e possíveis influências em estruturas próximas. Um importante passo é a previsão dos efeitos da escavação, principalmente no que concerne à geração de recalques. As Redes Neurais Artificiais (RNAs) aparecem como uma nova ferramenta para auxiliar o entendimento desses fenômenos. Isso porque a rede neural possui a capacidade de realizar generalizações, isto é, após a rede aprender características de uma categoria geral de dados baseada em uma série de exemplos daquela categoria, a rede pode apresentar respostas idênticas ou similares às respostas treinadas para entradas não treinadas. Nesse trabalho, realiza-se a aplicação de Redes Neurais Artificiais para os dados das Linhas 1 e 2 do Metrô de São Paulo, onde se observa a influência de alguns parâmetros e a melhoria significativa de previsão da rede neural devido à utilização de algumas técnicas no tratamento e manuseio dos dados. Dentre as técnicas de tratamento de dados utilizadas destaca-se a adimensionalização dos dados por parâmetros da própria obra garantindo melhor estabilidade à rede e melhor capacidade de previsão. Análises de sensibilidade também são realizadas para contemplar o tipo de influência que cada parâmetro exerceu nos recalques obtidos.

Palavras Chave: 1. Escavações subterrâneas. 2. Redes Neurais. 3. Recalques. 4. Metrô. 5. Túneis. 6. Instrumentação.

---



---

## ABSTRACT

SANTOS JR, O.J. (2006) Analysis of instrumentation data of São Paulo subway tunnels: a neural network approach, Dissertation (M.Sc.), Escola de Engenharia de São Carlos, Universidade de São Paulo, 160p.

Excavating shallow tunnels in densely occupied areas currently requires strict precautions to reduce risks and possible effects on nearby structures. Being able to predict excavation effects and particularly settlement- related effects is an important step forward in this respect. Artificial Neural Networks (ANNs) have emerged as a new tool for analyzing geotechnical problem. Longstanding problems have been solved and conventional solutions enhanced as the ability to generate more information grows and the understanding of obscure points is deepened. Neural networks have the ability to make generalizations: once a network has learned the characteristics of a general category of objects based on a series of examples from this category, it can provide identical or similar responses to trained responses for non-trained inputs. This study uses Artificial Neural Networks to analyze data from São Paulo Subway Line 1 and 2 to observe the effects of certain parameters and notes significantly enhanced neural network predictive ability due to the use of certain data processing techniques. The study also sets out to show that the use of dimensionless data in training may upgrade the predictive ability of the model. Knowledge acquired was applied to further develop use of this technique for tunnel instrumentation.

Keywords: 1. Underground Excavation. 2. Neural Network. 3. Settlements. 4. Subway. 5. Tunnels. 6. Instrumentation.

---



---

## LISTA DE FIGURAS

<b>Figura 2.1</b> – Representação de um neurônio biológico. ....	30
<b>Figura 2.2</b> – Esquema típico de um Neurônio Artificial. ....	30
<b>Figura 2.3</b> – Neurônio representativo com utilização de <i>bias</i> . ....	32
<b>Figura 2.4</b> – Arquitetura típicas dos modelos de RNA's, (Lins (2002) <i>apud.</i> Jain <i>et al.</i> (1996)) .....	38
<b>Figura 2.5</b> – Esquema de funcionamento de Perceptron Simples. ....	39
<b>Figura 2.6</b> – Ilustração de 2 conjuntos de dados (linearmente e não linearmente separáveis) .....	39
<b>Figura 2.7</b> – Diagrama típico de uma rede Perceptron Multi-Camadas. ....	40
<b>Figura 2.8</b> – Rede de Kohonen com duas entradas e quatro saídas .....	41
<b>Figura 2.9</b> – Influência dos pesos do neurônio vencedor, nos neurônios vizinhos. ....	42
<b>Figura 2.10</b> – Esquema de mapa de padrões obtido em uma rede de Kohonen. ....	43
<b>Figura 2.11</b> – Diagrama representativo da rede de Hopfield. ....	44
<b>Figura 3.1</b> – Tabela relacionando os tipos de região, de acordo com o número de camadas. Retirado de Lins (2002) <i>apud.</i> Lippman (1987).....	52
<b>Figura 3.2</b> – Tipos de ajuste que se pode obter de acordo com a configuração adotada. Retirado de Flood & Kartan (1994a) .....	53

---

---

<b>Figura 3.3</b> – Gráficos ilustrando a normalização dos dados. (Flood & Kartan ,1994a) ..	55
<b>Figura 3.4</b> – Gráfico de erros de acordo com a interpolação. (Flood & Kartan (1994a))	57
<b>Figura 3.5</b> – Superfície de erro com mínimos locais. ....	59
<b>Figura 3.6</b> – Superfície do erro e a influência do termo momentum. (Braga <i>et al.</i> , 2000).	59
<b>Figura 4.1</b> – Bacia de recalque durante a passagem de um túnel.....	67
<b>Figura 4.2</b> – Bacia de recalque típica e alguns fatores de influência.....	68
<b>Figura 4.3</b> – Topologia da MLP adotada no Metrô de Brasília. (Shi <i>et al.</i> , 1998) .....	71
<b>Figura 4.4</b> – Parâmetros geométricos de entrada da MLP. (Shi <i>et al.</i> (1998)).....	72
<b>Figura 4.5</b> – Comparação entre medido e calculado para durante o treinamento.....	73
<b>Figura 4.6</b> – Gráfico com os dados utilizados na fase de testes. ....	74
<b>Figura 4.7</b> – Diagrama típico de recalque no sentido longitudinal. (An <i>et al.</i> (2004)) .....	75
<b>Figura 4.8</b> – Topologia da RNA utilizada para a análise. (AN <i>et al.</i> , 2004).....	76
<b>Figura 4.9</b> – Recalques em 19/07/2002 .....	77
<b>Figura 4.10</b> – Recalques em 20/07/2002 .....	77
<b>Figura 4.11</b> – Recalques em 21/07/2002 .....	77
<b>Figura 4.12</b> – Recalques em 22/07/2002 .....	77
<b>Figura 5.1</b> – Modelo do neurônio padrão utilizado no MatLab 7®.....	81
<b>Figura 5.2</b> – Função de transferência sigmóide. $\left( a = \frac{1}{1 + e^{-n}} \right)$ .....	82
<b>Figura 5.3</b> – Função de transferência tangente hiperbólica. $\left( a = \frac{1 - e^{-n}}{1 + e^{-n}} \right)$ .....	82

---

---

<b>Figura 5.4</b> – Função de transferência linear. ( $a = n$ ) .....	83
<b>Figura 6.1</b> – Esquema ilustrando a arquitetura da RNA utilizada na Análise. ....	103
<b>Figura 6.2</b> – Comparação entre medidos e previstos pra Recalque Máximo ( $\rho_{máx}$ ). ....	106
<b>Figura 6.3</b> – Comparação entre medidos e previstos pra Largura da Bacia. ( $l$ ).....	107
<b>Figura 6.4</b> – Influência da velocidade de avanço no recalque máximo. ....	108
<b>Figura 6.5</b> – Influência da cobertura no recalque máximo.....	109
<b>Figura 6.6</b> – Seção geológica característica da região. (Rocha <i>et al.</i> , 1999).....	111
<b>Figura 6.7</b> – Ilustração da divisão por setores realizada durante a construção .....	112
<b>Figura 6.8</b> – Esquema da arquitetura utilizada na modelagem. ....	119
<b>Figura 6.9</b> – Gráfico comparando os valores previstos e medidos para o treinamento.	124
<b>Figura 6.10</b> – Gráfico comparando os valores previstos e medidos para o conjunto de testes. ....	124
<b>Figura 6.11</b> – Análise da Cobertura versus Recalque.....	125
<b>Figura 6.12</b> – Análise da influência da distância do arco invertido. ....	126
<b>Figura 6.13</b> – Análise da influência do Nível d'Água. ....	127
<b>Figura 6.14</b> – Análise da influência da velocidade de escavação. ....	127
<b>Figura 6.15</b> – Gráfico comparando dados para o treinamento no Cenário 24 .....	140
<b>Figura 6.16</b> – Gráfico comparando dados para o teste no Cenário 24.....	141
<b>Figura 6.17</b> – Comparação dos dados previstos e medidos para o treinamento. ....	142
<b>Figura 6.18</b> – Comparação dos valores previstos e medidos para o conjunto de testes.	142

---

---

<b>Figura 6.19</b> –Análise de sensibilidade de recalques com a espessura do concreto projetado. ....	144
<b>Figura 6.20</b> –Análise de sensibilidade para a cobertura.....	144
<b>Figura 6.21</b> –Análise de sensibilidade para a distância do arco invertido. ....	145
<b>Figura 6.22</b> –Análise de sensibilidade para a posição relativa da seção no túnel.....	145
<b>Figura 6.23</b> –Análise da influência da granulometria no nível de recalque.....	146
<b>Figura 6.24</b> –Análise de sensibilidade da velocidade de avanço na seção.....	147
<b>Figura 6.25</b> –Análise da influência da velocidade de escavação para 5 m antes e após..	148

---



---

## LISTA DE TABELAS

<b>Tabela 2.1</b> – Representação das principais funções de transferência usadas atualmente.	31
<b>Tabela 3.1</b> – Formas de representação da classificação das areias em uma RNA.....	55
<b>Tabela 4.1</b> – Principais Características do Túnel do Metrô de Brasília.....	70
<b>Tabela 4.2</b> – Dados de entrada da RNA utilizada para os túneis de Brasília .....	71
<b>Tabela 5.1</b> – Descrição dos parâmetros associados à função traingd. ....	84
<b>Tabela 5.2</b> – Características relevantes para análises via RNA para escavações subterrâneas. ....	95
<b>Tabela 6.1</b> – Características adotadas para o treinamento da Rede Neural.....	100
<b>Tabela 6.2</b> – Dados de entrada e saída utilizados no treinamento.....	101
<b>Tabela 6.3</b> – Configurações e topologias utilizadas durante o treinamento da Rede Neural. ....	103
<b>Tabela 6.4</b> – Configurações e topologias utilizadas durante o treinamento da Rede Neural. ....	105
<b>Tabela 6.5</b> – Características adotadas para o treinamento da Rede Neural.....	114
<b>Tabela 6.6</b> – Dados utilizados nas análises para o trecho Sumaré – Vila Madalena.....	115
<b>Tabela 6.7</b> – Configurações e topologias utilizadas durante o treinamento da Rede Neural para o trecho Sumaré - Vila Madalena.....	118

---

---

<b>Tabela 6.8</b> – Combinações realizadas para o processo de validação cruzada. ....	120
<b>Tabela 6.9</b> – Erros entre os dados de previsão e teste para cada uma dos cenários montados. ....	121
<b>Tabela 6.10</b> –Tabela com os erros obtidos no treinamento para os 6 cenários com melhores correlações, excluindo as combinações com saturação. ....	122
<b>Tabela 6.11</b> –Características adotadas para o treinamento da Rede Neural.....	132
<b>Tabela 6.12</b> –Dados utilizados nas análises para o trecho Sumaré – Vila Madalena. ....	133
<b>Tabela 6.13</b> –Configurações e topologias utilizadas durante o treinamento da Rede Neural para a re-análise do trecho Sumaré – Vila Madalena.....	135
<b>Tabela 6.14</b> –Combinações realizadas para o processo de validação cruzada. ....	137
<b>Tabela 6.15</b> –Erros obtidos em treinamento e teste para cada um dos cenários. ....	138
<b>Tabela 6.16</b> –Erros obtidos nas novas análises para determinação da influência dos parâmetros. ....	149
<b>Tabela 6.17</b> –Conexões e bias da Rede Neural ajustada.....	152

---

---

## SUMÁRIO

1.	INTRODUÇÃO .....	23
2.	REDES NEURAIS ARTIFICIAIS .....	27
2.1.	Histórico.....	27
2.2.	Conceitos e Potencialidades.....	29
2.3.	Tipos de Aprendizado .....	33
2.3.1.	Aprendizado Supervisionado .....	33
2.3.2.	Aprendizado Não-Supervisionado.....	33
2.4.	Desenvolvimento de Aplicações.....	34
2.4.1.	Coleta de Dados .....	34
2.4.2.	Separação em Conjuntos .....	34
2.4.3.	Configuração da Rede .....	35
2.4.4.	Treinamento.....	36
2.4.5.	Teste .....	37
2.4.6.	Integração em um ambiente operacional (Usuário Final) .....	37
2.5.	Principais Modelos .....	37
2.5.1.	Perceptron.....	38
2.5.2.	Multi-Layer Perceptron (MLP) .....	40
2.5.3.	Kohonen.....	41
2.5.4.	Hopfield.....	44

---

---

3.	ASPECTOS RELEVANTES DAS REDES MLP .....	49
3.1.	Princípios de Funcionamento da MLP .....	49
3.2.	Topologia .....	51
3.3.	Tratamento de Dados .....	54
3.4.	Parâmetros de Treinamento .....	57
3.4.1.	Número de Ciclos .....	58
3.4.2.	Momentum.....	58
3.5.	Análise de Sensibilidade Analítica.....	60
4.	RNA EM GEOTECNIA .....	63
4.1.	RNA na previsão de recalques em Obras Subterrâneas (Túneis).....	65
4.2.	Túnel do Metrô de Brasília.....	70
4.3.	Túnel do Metrô de Shanghai .....	75
5.	MATERIAIS E MÉTODOS.....	79
5.1.	Uso do MatLab® para RNAs.....	80
5.1.1.	Modelo de Neurônio .....	80
5.1.2.	Definição da Rede.....	81
5.1.3.	Funções de Transferência.....	82
5.1.4.	Tipos de Treinamento .....	83
5.1.5.	Treinamento.....	85
5.1.6.	Simulação.....	86
5.1.7.	Pré-processamento dos dados .....	86
5.1.8.	Pós-processamento dos dados.....	89
5.2.	Trecho a ser utilizado.....	90
5.3.	Obtenção dos dados.....	91

---

---

5.4.	Tratamento dos dados .....	94
5.5.	Cenários de entrada e saída da RNA.....	94
5.6.	Topologias e Parâmetros.....	96
6.	ANÁLISES.....	99
6.1.	Extensão Norte da Linha 1 (Jd. São Paulo – Poço Pedro Cacunda).....	99
6.1.1.	Obtenção e preparação dos dados .....	100
6.1.2.	Topologias e Parâmetros .....	102
6.1.3.	Resultados .....	104
6.1.4.	Análise de Sensibilidade.....	107
6.1.5.	Conclusões e Comentários .....	109
6.2.	Extensão Oeste da Linha 2 (Sumaré-Vila Madalena).....	110
6.2.1.	Obtenção e preparação dos Dados.....	112
6.2.2.	Topologias e Parâmetros .....	117
6.2.3.	Resultados .....	120
6.2.4.	Análise de Sensibilidade.....	125
6.2.5.	Conclusões e Comentários .....	128
6.3.	Re-análise da Extensão Oeste da Linha 2 (Sumaré-Vila Madalena) .....	129
6.3.1.	Novos Procedimentos.....	130
6.3.2.	Obtenção e preparação dos Dados.....	132
6.3.3.	Topologias e Parâmetros .....	134
6.3.4.	Resultados .....	137
6.3.5.	Análise de Sensibilidade.....	143
6.3.6.	Verificação da eficácia dos procedimentos.....	148
6.3.7.	Conclusões e Comentários .....	150

---

---

6.3.8.	Conexões e bias da Rede Neural ajustada.....	151
7.	CONCLUSÕES .....	153
8.	REFERÊNCIAS BIBLIOGRÁFICAS .....	157

---

## 1. INTRODUÇÃO

Atualmente, a escavação de túneis rasos em regiões densamente ocupadas requer medidas severas para reduzir riscos e possíveis influências em estruturas próximas. Um importante passo é a previsão dos efeitos da escavação, principalmente, no que concerne a geração de recalques.

No passado, segundo palavras de Terzaghi transcritas por Peck (1969), apenas duas abordagens eram utilizadas para superar as incertezas:

- Adotar um valor de segurança alto;
- Adotar simplificações baseadas na 'experiência'.

Estas abordagens apresentam vários problemas. A primeira opção é dispendiosa e a segunda perigosa. Além disso, a experiência é um fator que pertencia a poucos indivíduos não podendo ser repassada à coletividade técnica. Atentando para essas particularidades de um projeto geotécnico, Terzaghi sistematizou a abordagem de projeto do "learn-as-you-go", que recebe a denominação de Método Observacional.

Os métodos observacionais possuem um ciclo de retro-alimentação dos modelos utilizados em projeto, em tempo da execução do mesmo. Desta forma, usualmente ocorre um ajuste nos parâmetros do modelo. Isto se realiza para representar a realidade de forma fidedigna, permitindo assim que a execução da obra ocorra com segurança.

---

Segundo classificação de Bieniawski (1989), os métodos observacionais de projeto de escavações subterrâneas, fiam-se nos resultados de instrumentação durante a obra para detectar instabilidade e na análise da interação maciço suporte. Para o caso de obras que tratam da execução de túneis urbanos, a instrumentação que melhor realiza esse controle, e segundo a qual, os métodos de qualidade de obra estão baseados hoje em dia, são os medidores de recalque. Os recalques observados em uma obra desse tipo são ótimos indicadores da qualidade da mesma além de muitas vezes permitirem uma avaliação do sistema construtivo. Além disto são os indicadores principais da ocorrência de danos às edificações lindeiras e redes de utilidade enterradas. Tais danos constituem a maior peculiaridade de uma obra subterrânea em ambiente urbano.

As Redes Neurais Artificiais (RNAs) aparecem como uma nova ferramenta para solução de problemas geotécnicos. Aplicações com sucesso foram desenvolvidas nas mais diversas áreas da Engenharia Geotécnica. Velhos problemas têm sido resolvidos, melhorando soluções clássicas e criando uma capacidade de gerar mais informações que permitam ampliar a compreensão de pontos obscuros.

As redes neurais artificiais possuem diversas características que as qualificam como ferramenta de análise de problemas geotécnicos. Uma rede neural possui a capacidade de realizar generalizações, isto é, após a rede aprender características de uma categoria geral de objetos baseada em uma série de exemplos daquela categoria, a rede pode apresentar respostas idênticas ou similares às respostas treinadas para entradas não treinadas. Estas entradas guardam certas semelhanças com os padrões de entrada treinados.

Métodos probabilísticos também têm sido utilizados para a análise de dados de instrumentação de túneis com as mais diferentes finalidades. Hachich e Negro (1990) apresentaram um procedimento de retroanálise probabilística utilizando técnica bayesiana.

---



---

O procedimento foi aplicado a leituras de instrumentação em 4 túneis, com o intuito de obter parâmetros de modelos de estimativa de recalques superficiais, ajustando cada parâmetro proporcionalmente a sua variabilidade. Com redes neurais, uma vez feito o treinamento, análises de sensibilidade, como aquelas mostradas adiante, poderão também ser utilizadas para estimativa de alguns parâmetros, quando outros forem conhecidos.

No Capítulo 2 realiza-se um apanhado de Redes Neurais Artificiais elencando os principais conceitos e modelos utilizados com aprendizado supervisionado. Segundo a literatura, o Perceptron de Múltiplas Camadas é o mais aplicável para a análise de instrumentação de túneis, por isso, no Capítulo 3 abordam-se alguns aspectos relevantes desse modelo. No Capítulo 4 apresentam-se algumas aplicações geotécnicas de RNAs, e também algumas aplicações em análise de instrumentação de túneis. No Capítulo 5 apresentam-se as premissas do estudo, os materiais empregados e os métodos utilizados para a análise, cujos resultados e detalhamento podem ser observados no Capítulo 6.

Lançar mão de um processo racional de aprendizado, como é o caso de uma rede neural será de grande importância para a engenharia brasileira. Nesse trabalho, realiza-se a aplicação de Redes Neurais Artificiais para os dados das Linhas 1 e 2 do Metrô de São Paulo. O aprendizado, materializado na rede neural, se constitui em valioso elemento para consolidar o conhecimento dos principais fatores que influenciam nos níveis de recalque. Além disso, a experiência adquirida no manuseio e aplicação da técnica será importante para futuras aplicações.

---



## 2. REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais desenvolveram-se inspiradas no funcionamento dos neurônios biológicos. Numerosos avanços foram obtidos nos últimos anos no desenvolvimento de sistemas inteligentes, particularmente os que têm seu funcionamento inspirado nas redes neurais biológicas. Pesquisadores das mais variadas disciplinas têm as utilizado para a solução dos mais diversos tipos de problemas. Entre esses, destacam-se aqueles que envolvem o controle de sistemas complexos onde o comportamento não é rigorosamente conhecido.

### 2.1. *Histórico*

Ainda na década de 40, McCulloch & Pitts (1943) desenvolveram o primeiro modelo artificial de um neurônio biológico, descrevendo e apresentando as capacidades computacionais de um neurônio artificial sem desenvolver as técnicas de aprendizado para os mesmos. Apenas com o trabalho de HEBB (1949) estas técnicas de aprendizado tornaram-se objeto de estudo.

Posteriormente, o trabalho de Widrow & Hoff (1960) apresentou uma regra de aprendizado baseada no gradiente descendente para minimização do erro da rede, denominada regra delta, que atualmente ainda é amplamente utilizada. Rosenblatt (1958),

---

criou um novo modelo, o *perceptron*, com sinapses ajustáveis, que se prestaria ao treinamento de certos tipos de padrões.

As Redes Neurais Artificiais ficaram adormecidas durante toda a década de 70, em grande parte por conta do trabalho de Minsky & Papert (1969), que chamaram a atenção para algumas tarefas que o *perceptron* não era capaz de executar, já que só resolve problemas linearmente separáveis. Lins (2002) transcreveu de Minsky & Papert (1969) que o principal argumento se embasava no problema do crescimento explosivo tanto no espaço ocupado, como do tempo requerido para resolução de problemas complexos, o que afetaria as RNAs, inclusive os *perceptrons*.

A retomada das pesquisas se deu com o artigo de Hopfield (1982) onde o autor mostra a relação entre redes recorrentes auto-associativas e sistemas físicos. Finalmente, Rumelhart *et al.* (1986) mostraram que os estudos realizados por Minsky & Papert (1969) acerca do *perceptron* eram bastante pessimistas, e que a utilização do algoritmo de treinamento *back-propagation*, em conjunto com múltiplas camadas de neurônios (*Multi Layer Perceptron – MLP*) seria realmente capaz de resolver problemas complexos.

Com os estudos de Hopfield (1982) e Rumelhart *et al.* (1986) os avanços envolvendo as Redes Neurais Artificiais foram retomados com grande ênfase. O avanço acelerado da microeletrônica nas últimas duas décadas, também contribuiu para que pesquisadores se dedicassem ao estudo e à aplicação de RNAs em diversas áreas do conhecimento.

A Escola de Engenharia de São Carlos já tem tradição na utilização de Redes Neurais Artificiais para resolução de problemas complexos. Dentre as publicações relacionadas à Engenharia Civil da EESC/USP, pode-se citar Brega (1996), Furtado

---

(1998), Brondino (1999), Coutinho Neto (2000), Raia Junior (2000), Bocanegra (2001), Teixeira (2003), Silva (2003).

Além dessas, entre as publicações na EESC relacionadas a aspectos geotécnicos pode-se citar: Tronco (1999) que trata da implementação de um sistema de reconhecimento de imagens, baseado em Redes Neurais; Galo (2000) utilizando redes neurais artificiais para estabelecer relações de síntese entre as variáveis que representam o meio físico e fenômenos ambientais com o auxílio de sensoriamento remoto; Rodgher (2002) propõe a aplicação da técnica de redes neurais artificiais (RNAs) para a previsão de propriedades geotécnicas dos solos do município de São Carlos (SP).

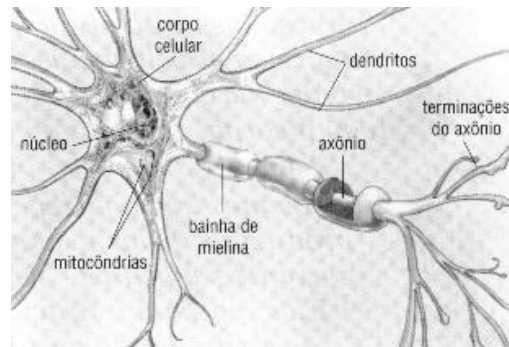
Destaca-se ainda a tese de Doutorado de Lins (2002) desenvolvida no Departamento de Geotecnia da EESC, em que os principais sistemas de classificação geomecânicas para o projeto de túneis (Sistemas Q e RMR) são descritos como representações neurais locais. Tais representações permitem uma melhor compreensão do processo de classificação e identificação de padrões realizados pelas classificações convencionais.

## ***2.2. Conceitos e Potencialidades***

As RNAs têm o objetivo de simular o cérebro humano em sua forma de processamento. Isso significa que a rede deve ser capaz de aprender com os próprios erros, ou seja, errando, corrigindo, e fazendo descobertas de como evitar que o erro se repita na próxima ocorrência de uma situação parecida. No cérebro, a principal unidade de processamento são os neurônios. Na Figura 2.1 pode-se observar os componentes de um neurônio biológico, que são:


---

- *Dentritos*: Recebe Estímulos;
- *Corpo (somma)*: Coleta e combina informações ( $\text{Na}^+$  e  $\text{K}^+$ );
- *Axônio*: Fibra que transmite os estímulos.



**Figura 2.1** – Representação de um neurônio biológico.

Procurando representar o cérebro humano, McCulloch & Pitts (1943) apresentam um modelo de neurônio artificial, que visa exercer características muito próximas às biológicas. Para isso, os neurônios artificiais possuem uma estrutura similar à dos biológicos, no que concerne à forma lógica de processamento. Na Figura 2.2 pode-se observar o esquema típico de um neurônio artificial.



**Figura 2.2** – Esquema típico de um Neurônio Artificial.

Pode-se descrever a operação de um neurônio artificial, da seguinte forma:

- 1 – Os impulsos são apresentados ao neurônio ( $x_i$ );
- 2 – Cada impulso é multiplicado por um peso ( $w_i$ ) que indica sua influência;

- 3 – A soma ponderada dos sinais indica um nível de atividade;
- 4 – Função de ativação ( $\varphi$ ) produz a saída do neurônio;

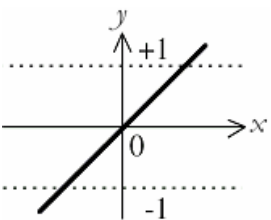
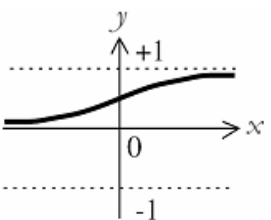
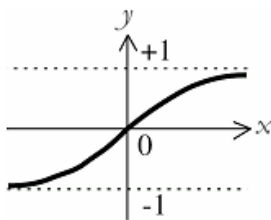
Sendo assim, pode-se definir a saída  $y$  de um neurônio pela expressão abaixo.

$$y = \varphi(w_1 \cdot x_1 + w_2 \cdot x_2 + \dots + w_n \cdot x_n)$$

No neurônio de McCulloch & Pitts (1943), a função de ativação era dada pela função limite. Ou seja, se a soma ponderada fosse maior que um valor limite  $\theta$ , a saída do neurônio seria igual a 1. Caso contrário a saída seria zero. A partir desse modelo de neurônio, outros foram desenvolvidos variando principalmente a função de ativação, de forma a obter valores intermediários, e não somente 0 ou 1.

Atualmente, as três funções de ativação mais aplicadas são a linear, a sigmoideal e a tangente hiperbólica. Na Tabela 2.1, pode-se observar as equações que regulam essas três funções de ativação, assim como o intervalo que os valores de saída podem assumir, e seus gráficos representativos. Na tabela, o valor de  $x$  corresponde ao somatório ponderado das entradas.

**Tabela 2.1** – Representação das principais funções de transferência usadas atualmente.

Linear	Sigmoideal	Tangente Hiperbólica
$y = a \cdot x$	$y = \frac{1}{1 + e^{-\gamma \cdot x}}$	$y = \frac{1 - e^{-\gamma \cdot x}}{1 + e^{-\gamma \cdot x}}$
$[-\infty, +\infty]$	$[0, 1]$	$[-1, 1]$
		

GHABOUSSI & SIDARTA (1998) utilizam como função de ativação a equação:

$$f(x) = \frac{2}{1 + e^{-\gamma x}} - 1$$

Nessa equação, os valores podem variar entre -1 e 1, assim como a função tangente hiperbólica. Os autores justificam que essa função de transferência proporciona um melhor ajuste, principalmente no que se refere ao modelo por eles utilizado.

Atualmente, ainda como variação do neurônio de McCulloch & Pitts (1943) tem sido comum o uso de um termo independente no somatório dos pesos e entradas. Esse termo é denominado *bias*, e seu funcionamento é similar a uma entrada de valor 1 e o *bias* funcionando como um peso dessa entrada que é modificado assim como os pesos em cada alteração. Na Figura 2.3 pode-se observar um modelo de neurônio, com a utilização dessa ferramenta.




Figura 2.3 – Neurônio representativo com utilização de *bias*.

O *bias* proporciona maior estabilidade à rede e, principalmente, aprimora sua capacidade de generalização. Isso se deve ao fato de que durante o treinamento ele também funciona de forma similar à ocorrência de ruídos no conjunto de dados. Além disso, ele permite que a rede possa considerar algum valor que não está relacionado a nenhum dos fatores enumerados nos parâmetros de entrada.



---

### **2.3. Tipos de Aprendizado**

Para adquirir o conhecimento do objeto de estudo, as Redes Neurais Artificiais baseiam-se no ajuste dos pesos entre as conexões para ponderar as entradas em cada neurônio. As condições de controle utilizadas para o ajuste dos pesos estão intrinsicamente relacionadas à gama de dados que serão utilizados. O ajuste dos pesos é denominado como o aprendizado da rede. De acordo com a forma de ajuste, podem-se definir 2 tipos aprendizado.

#### **2.3.1. Aprendizado Supervisionado**

Esse tipo de aprendizado é adequado para situações onde se conhecem os parâmetros de entrada e de saída de sua rede para o caso real. As redes concebidas com esse tipo de aprendizado são também chamadas de *Feed-Forward-Back*. Nesses casos os valores são calculados para cada conjunto de entrada (*Feed-Forward*), e o resultado é comparado com os dados reais que se possui, determinando assim um erro. Esse erro é utilizado para fazer o ajuste dos pesos (*Back*).

#### **2.3.2. Aprendizado Não-Supervisionado**

No Aprendizado Não-Supervisionado, não se conhecem os valores dos parâmetros de saída. Por isso, normalmente os mesmos são utilizados, em redes recorrentes, ou ainda para a definição de classes para de um certo conjunto de dados. Tem sido muito utilizada por exemplo na recuperação de dados.

---

## ***2.4. Desenvolvimento de Aplicações***

O desenvolvimento de aplicações em Redes Neurais Artificiais pode ser dividido em 6 fases principais.

### **2.4.1. Coleta de Dados**

Para uma análise por redes neurais, uma significativa quantidade de dados é essencial para a obtenção de bons resultados. A instrumentação de túneis fornece grande quantidade de dados. Contudo, deve-se salientar que a coleta de dados para uma análise por redes neurais deve ser também bastante abrangente. Isso significa que não se deve utilizar somente os valores que estejam dentro de uma faixa média dos dados obtidos. Devem ser utilizados também, valores que configurem as situações extremas, pois nesses casos, a rede também deve procurar o melhor ajuste.

### **2.4.2. Separação em Conjuntos**

Após a coleta dos dados, deve-se dividi-los de forma a utilizar uma parte deles para o treinamento da rede, e outra parte para o teste da mesma. Haykin (1994) e Braga (2000) recomendam, a divisão de cerca de 70 a 90% dos dados para o treinamento e o restante para a validação. Contudo, os mesmos ressaltam que essas porcentagens devem ser reavaliadas para cada modelo, de acordo com o caso estudado.

---

Em alguns tipos de validação da rede (validação cruzada) o mesmo conjunto de dados é dividido em várias partes (10 partes, por exemplo). Em seguida utiliza-se uma dessas partes para a fase de teste, e treina-se a rede com as partes restantes. Após esse treinamento, separa-se outra parte para a fase de testes, e utilizam-se as outras para a validação dos pesos obtidos. (Haykin, 1994)

### 2.4.3. Configuração da Rede

Considera-se que na aquisição de dados será possível a obtenção do máximo de informações possíveis sobre o caso a ser estudado. Sendo assim, pode-se definir que a configuração da rede a ser utilizada envolve a determinação de 3 fatores:

- *Seleção do paradigma neural apropriado:* de acordo com os dados que se possui, e com a característica de cada tipo de rede, deve-se determinar o melhor tipo de topologia a ser utilizado. O Perceptron de Múltiplas Camadas (*MLP – Multi Layer Perceptron*) tem-se mostrado a ferramenta mais adequada para análises envolvendo recalques obtidos através da instrumentação de túneis (Suwansawat, 2004). Essa melhor aplicabilidade das MLPs, se deve principalmente, à alta dimensionalidade que se pode obter no manuseio com os dados, pois, muitos fatores influenciam fortemente os recalques ocorridos durante a escavação de túneis.
  - *Determinação da topologia:* Após definido o paradigma, deve-se escolher as principais características do tipo escolhido. Para as MLP's, por exemplo, devem ser determinados o número de camadas, e o número de neurônios
-

para cada camada. Nessa fase, também são definidos os dados de entrada e os dados de saída da rede.

- *Escolha dos parâmetros de treinamento*: Alguns parâmetros de treinamento devem ser definidos de acordo com os objetivos. Cada arquitetura possui parâmetros a serem definidos de acordo com o método de aprendizado.

Shi *et al.* (1998) destacam ainda a importância da análise completa do problema a ser estudado, na definição da arquitetura adequada para o estudo. Segundo os mesmos, essa análise em alguns casos deve ser realizada ainda a priori no estudo, para melhor definição dos dados de entrada.

#### 2.4.4. Treinamento

Após a definição da topologia e dos parâmetros de controle, são realizados os cálculos para o ajuste dos pesos, que proporcionem o menor erro em relação aos dados originais. Nessa fase, cuidado especial deve ser tomado para se assegurar a convergência da rede, evitando problemas tais como:

- *Overflow da função de erro*: deve-se evitar que ocorra *overflow* nas variáveis responsáveis pelo cálculo dos erros. Normalmente definem-se essas variáveis com maior dimensionalidade.
  - *Saturação dos neurônios*: esse problema ocorre quando um dos neurônios, atinge valores muito próximos do limite da função de ativação, e por isso, o valor praticamente não se modifica mesmo com as alterações nos pesos causadas pela tentativa de convergência, definindo então a instabilização da rede.
-

#### **2.4.5. Teste**

Na fase de teste, após obterem-se os valores referentes aos pesos com os dados de treinamento, deve-se submeter aos exemplos de teste, e verificar a capacidade de generalização da rede, comparando as saídas obtidas com o exemplo de teste. Deve-se nesse caso definir um erro máximo, para que a rede seja considerada de boa convergência.

#### **2.4.6. Integração em um ambiente operacional (Usuário Final)**

Após o treinamento da rede e o ajuste dos pesos, deve-se proceder à implementação dos valores dos pesos obtidos em um ambiente apropriado para a utilização. Esse procedimento é importante quando se necessita aplicar os dados obtidos em novos casos. Para o caso de instrumentação de túneis, onde se pretende obter parâmetros da região, e do equipamento utilizado, a implementação em um ambiente é necessária somente na fase de previsão dos valores.

### **2.5. Principais Modelos**

Muitas topologias foram definidas para as mais diferentes aplicações. Algumas topologias são específicas para alguns sistemas. Contudo, alguns modelos destacaram-se com o tempo e suas aplicações foram se tornando mais freqüentes. Para essas topologias os estudos têm proporcionado maiores avanços no entendimento dos seus conceitos.

Na Figura 2.4 se pode observar algumas topologias, que são relacionadas ao tipo de aprendizado e ao tipo de dados que se possui.

---

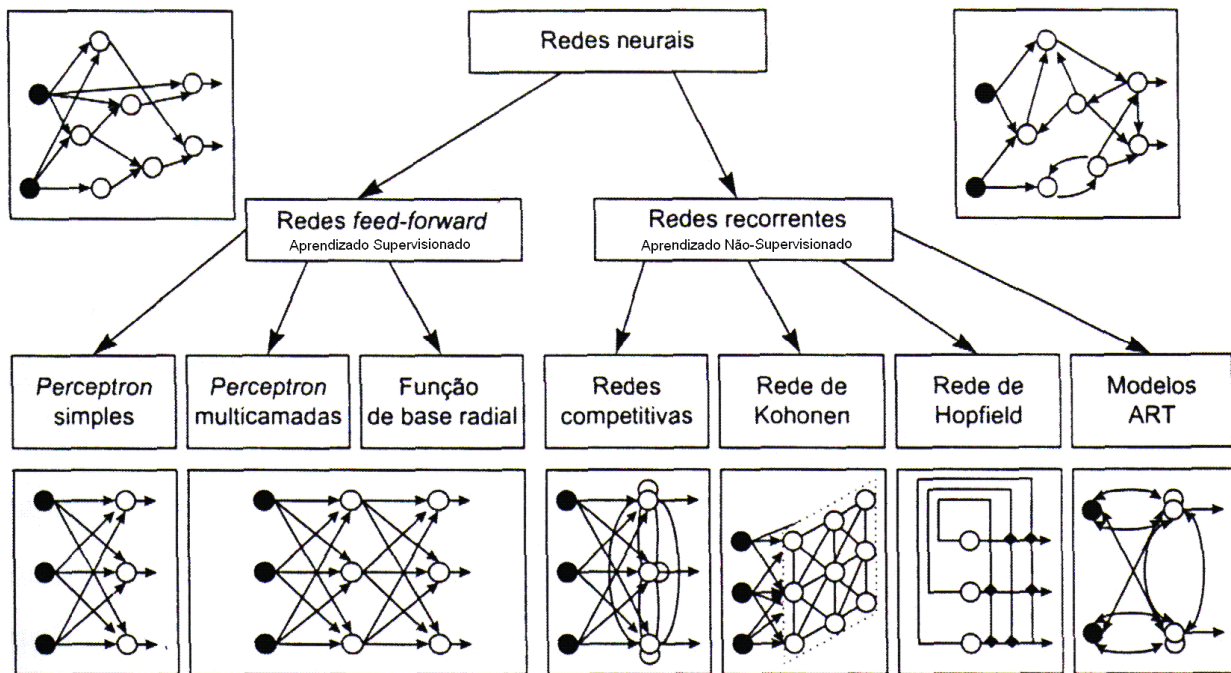


Figura 2.4 – Arquitetura típicas dos modelos de RNA's, (Lins (2002) *apud*. Jain *et al.* (1996))

### 2.5.1. Perceptron

O *Perceptron* simples foi proposto por Rosenblatt (1958), e pode resolver vários sistemas. Sua concepção correspondeu a um grande avanço no estudo das RNAs pois sua arquitetura é suficiente para a aplicação em muitos exemplos onde os dados podem ser divididos em categorias. A topologia do perceptron corresponde à organização dos neurônios em forma de uma camada. O número de elementos de saída determina a quantidade de neurônios. Na Figura 2.5 pode-se observar a representação de um modelo de *perceptron*.




Figura 2.5 – Esquema de funcionamento de Perceptron Simples.

Contudo, Minsky & Papert (1969) mostraram que o *perceptron* não possuía capacidade de se ajustar corretamente quando os dados não podiam ser separados linearmente. Ou seja, o *Perceptron* é uma ótima ferramenta para ser utilizada quando há possibilidade de separação dos dados de forma linear. Na Figura 2.6, pode-se observar duas distribuições de dados. Na Figura 2.6(a) um conjunto de dados que podem ser ajustados por um *perceptron* por se tratar de dados linearmente separáveis. Contudo, na Figura 2.6(b), os dados não podem ser separados de forma linear, impossibilitando o uso do *perceptron* para esse caso.




Figura 2.6 – Ilustração de 2 conjuntos de dados (linearmente e não linearmente separáveis)

### 2.5.2. Multi-Layer Perceptron (MLP)

Rumelhart (1986) apresentou o modelo de *Multi Layer Perceptron (MLP)* ou Perceptron de Múltiplas Camadas. A principal vantagem desse modelo em relação ao *Perceptron*, foi a sua capacidade de resolução com modelos não lineares, permitindo solucionar vários sistemas que o *perceptron* simples não permitia.

Na Figura 2.7, pode-se observar o esquema típico de utilização de uma rede MLP. Além da camada de entrada de dados, e da camada de saída, que ocorrem no perceptron simples, as MLP, são compostas por camadas intermediárias. Nessas camadas realiza-se a maior parte do processamento das informações.




Figura 2.7 – Diagrama típico de uma rede Perceptron Multi-Camadas.

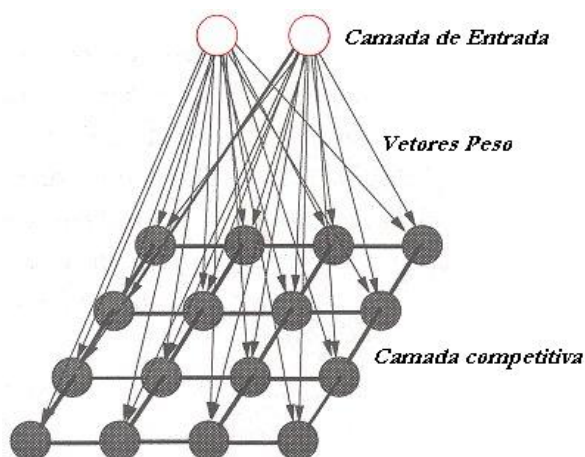
Considerações mais detalhadas desse modelo serão realizadas a posteriori. Experiências anteriores têm demonstrado que as MLPs possuem as melhores condições para a análise de instrumentação de túneis, visto que as informações normalmente não são linearmente separáveis, impossibilitando o uso do *perceptron* simples.



### 2.5.3. Kohonen

Este modelo foi proposto por Kohonen (1989). As redes de Kohonen também são chamadas de redes SOM (*Self-Organizing Maps*) ou mapa auto-organizável. É uma rede de duas camadas que pode organizar um mapa topológico a partir de um início aleatório. O mapa resultante mostra os relacionamentos naturais entre os padrões que são fornecidos à rede. A rede combina uma camada de entrada com uma camada competitiva de unidades processadoras e é treinada pelo aprendizado não supervisionado.

Na Figura 2.8 pode-se observar um exemplo com a camada de entrada, as conexões entre camadas, e a camada competitiva. Essa última é a responsável pela organização dos padrões de forma que padrões semelhantes estejam alocados em regiões próximas.

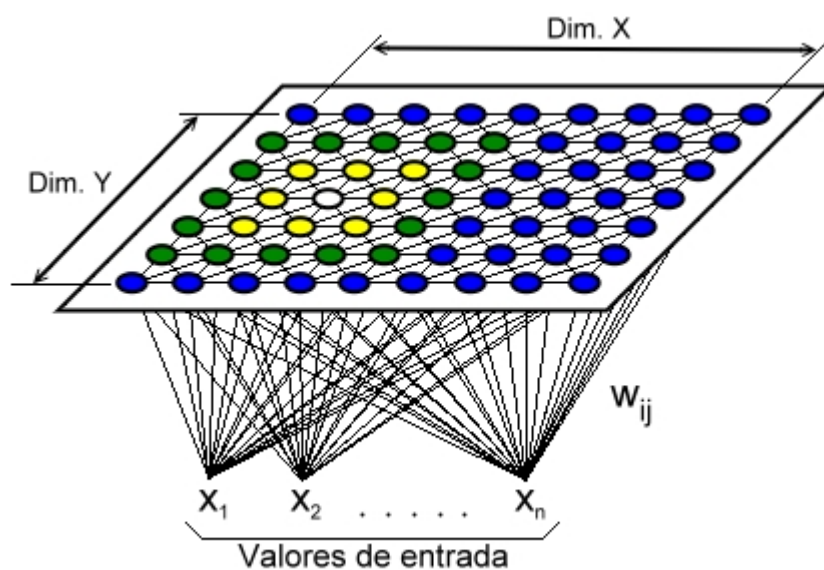


**Figura 2.8** – Rede de Kohonen com duas entradas e quatro saídas

Para definir as regiões com características semelhantes, os dados de entrada são comparados com os pesos referentes a cada um dos neurônios através do cálculo da Distância Euclidiana entre os pares de valores. O neurônio que possuir valores mais próximos aos dados de entrada é considerado o neurônio vencedor, que recebe um estímulo aproximando-o mais ainda do valor apresentado.

Em seguida, os neurônios vizinhos ao neurônio vencedor recebem também uma parcela desse estímulo. Tal estímulo à vizinhança objetiva definir as regiões com características próximas. Dessa forma, cada padrão que for apresentado a posteriori, cujas características forem próximas às do vencedor atual, será alocado nas imediações do neurônio que se tornou vencedor agora.


No estímulo à vizinhança, quanto mais distante está o neurônio  $j$  do neurônio vencedor, menor será o estímulo recebido pelo neurônio  $j$ . Na Figura 2.9 observa-se um esquema de como ocorrem esses estímulos à vizinhança. O neurônio na cor branca corresponde ao neurônio vencedor e é o que recebe maior estímulo. Em seguida os neurônios amarelos recebem um estímulo menor, e os verdes um estímulo menor ainda, até que os neurônios azuis não recebem estímulo nenhum.



**Figura 2.9** – Influência dos pesos do neurônio vencedor, nos neurônios vizinhos.

Não há propriamente um reconhecimento de padrão como em outros modelos, mas há a classificação de um padrão junto com outros que têm características semelhantes, formando classes. Estas classes são mapeadas, onde se pode observar a distribuição dos padrões, como se pode observar na Figura 2.10. Nessa figura pode-se

observar que algumas regiões possuem características bem definidas, com as cores preto, cinza e branco bem definidas. Há também limites bem definidos dessas regiões, assim como em alguns outros limites o local onde começa uma região e termina outra é difícil de ser definido. Isso se deve, ao fato de que nessa região padrões diferentes estão emaranhados entre si.




**Figura 2.10** – Esquema de mapa de padrões obtido em uma rede de Kohonen.

Desta maneira, no instante em que um padrão é inserido na rede, esta o coloca na classe onde melhor o padrão se adequa, em função das suas características. Após todos os padrões serem apresentados à rede, o mapa apresentará os agrupamentos, e regiões com características próprias que podem ser observadas, conforme a Figura 2.10.

O algoritmo de Kohonen tem sua principal aplicação direcionada ao mapeamento de dados, onde se podem obter correlações entre os mesmos. Atualmente, há aplicações até mesmo em análises de fotografias médicas, para identificar regiões propícias ao desenvolvimento de doenças.

### 2.5.4. Hopfield

Hopfield (1982) apresentou um modelo de rede recorrente. Esse modelo foi um dos responsáveis pela retomada dos estudos na área de Redes Neurais, que estiveram estagnados na década de 70. No modelo descrito por Hopfield, as saídas estão ligadas às entradas por um atraso de tempo (o que caracteriza sua recorrência). Na Figura 2.11 pode-se observar um diagrama esquemático da rede de Hopfield. Originalmente, a rede foi apresentada com a utilização de saídas (e entradas) discretas entre 1 e -1. Posteriormente, o próprio Hopfield (1984), mostrou que o modelo com saídas contínuas preserva as características do modelo discreto.



**Figura 2.11** – Diagrama representativo da rede de Hopfield.

O trabalho de Hopfield mostra que um valor de ‘energia’ pode ser associado a cada estado da rede, vindo esse a ser um dos grandes avanços desse tipo de rede. Além disso, ele mostra que esta ‘energia’ decresce à medida que uma trajetória é descrita em relação a um ponto fixo. Estes pontos fixos são, portanto, pontos estáveis de energia mínima.

Esse valor da ‘energia’ é representado por uma equação que varia de acordo com a aplicação, e é calculada com os valores dos padrões de entrada. Durante a apresentação de

um novo padrão, os pontos fixos (que são pontos de menor ‘energia’) funcionam como atratores para os novos padrões que são apresentados à rede. Cada atrator possui a sua área de influência, denominada de bacia de atração. Os pontos presentes nessa bacia irão convergir aos respectivos atratores, em um tempo finito.

Uma matriz de pesos  $\mathbf{W}$  é criada para relacionar matematicamente as saídas com as entradas. Para manter a estabilidade da rede, evitando realimentações positivas, o elemento correspondente à diagonal principal é tido como zero ( $w_{ii} = 0$ ), pois o mesmo seria o responsável pela multiplicação da saída do próprio elemento, o que poderia desestabilizar a rede. Essa matriz de pesos é baseada nos vetores de menor energia que se quer considerar, que serão os pontos fixos de cada problema.

Uma forma de satisfazer as condições de estabilidade é adotar para a matriz de pesos, os valores referentes à equação:

$$w_{ij} = \frac{1}{k} \cdot \sum_p x_i \cdot x_j \quad \text{e} \quad w_{ii} = 0$$

onde,  $k$  = número de nós da rede;

$p$  = número de vetores a serem armazenados pela rede;

$x$  = valores dos padrões para os quais se deseja que os valores apresentados venham a convergir.

Com a matriz de pesos  $\mathbf{W}$  obtida, podem-se definir as novas saídas através da seguinte equação:

$$s_{n+1} = \text{sgn}(W \times s_n)$$

onde,  $\text{sgn}$  é a função sinal.

Como os elementos da diagonal principal são iguais a zero o valor da saída nova, não dependerá do valor da saída anterior.









### 3. ASPECTOS RELEVANTES DAS REDES MLP

Para a aplicação em análise de instrumentação de túneis, por-se dispor de os valores de recalques, assim como de fatores que influem sua ocorrência será descrito o procedimento de Aprendizado Supervisionado (*Feed-Forward-Back*).

Flood & Kartan (1994b) salientam que o sucesso da aplicabilidade de uma rede neural depende não somente da qualidade dos dados utilizados, mas também do tipo (arquitetura) da rede adotada, assim como do método de treinamento, e da forma como os dados de entrada e saída são estruturados e interpretados. Os autores comentam ainda que para obter uma solução bem sucedida aplicando as Redes Neurais Artificiais são necessárias experiência e imaginação.

#### 3.1. *Princípios de Funcionamento da MLP*

As informações acerca dos princípios de funcionamento de uma MLP podem ser analisadas com maior detalhe em Braga *et al.* (2000) e Haykin (1994). A seguir são sumarizados os principais tópicos que abrangem seu funcionamento. As redes MLP possuem aprendizado supervisionado. Sendo assim, a medida do erro é diretamente proporcional à diferença entre os dados reais e os dados calculados pela rede. A função de erro a ser minimizada em uma rede MLP pode ser definida por:

---

$$E = \frac{1}{2} \cdot \sum_p \sum_{i=1}^k (d_i^p - y_i^p)^2$$

onde,  $E$  é a medida de erro total,

$p$  é o número de padrões ou número de exemplos,

$k$  é o número de unidades de saída,

$d_i$  é a  $i$ -ésima saída desejada,

$y_i$  é a  $i$ -ésima saída gerada pela rede.

A regra delta, utilizada para o treinamento das MLPs, sugere que a variação dos pesos é diretamente proporcional ao gradiente decrescente do erro, ou seja a derivada do erro em relação ao peso. Realizando as operações matemáticas devidas, obtém-se que a variação do peso entre o neurônio  $i$  (origem da conexão) e o neurônio  $j$  (destino da conexão) é dada por:

$$\Delta w_{ij} = \eta \cdot \delta_j \cdot x_i$$

onde,  $\eta$  é a taxa de aprendizado,

$\delta_j$  é o erro relativo ao neurônio  $j$ ,

$x_i$  é a saída do neurônio  $i$ .

A Taxa de Aprendizado ( $\eta$ ) corresponde à velocidade de ajuste dos pesos. Seu valor, é compreendido entre 0 e 1, e para valores próximos de 1 a convergência é mais rápida, contudo a rede se torna mais suscetível à instabilidade. Para valores mais baixos, ocorre maior estabilidade da rede, entretanto o tempo de convergência é maior.

Calculada a variação, pode-se então determinar o novo valor do peso, a partir da equação.

$$w_{ij}(t+1) = w_{ij}(t) + \Delta w_{ij}(t)$$

O erro relativo do neurônio ( $\delta_j$ ) varia de acordo com a posição do neurônio na rede modelada. Para neurônios localizados na camada de saída seu valor é dado pela equação:

$$\delta_j = (d_j - y_j) \cdot \frac{\partial f(\text{net}_j)}{\partial \text{net}_j}$$

onde,  $d_j$  é a saída desejada no neurônio  $j$ ,

$y_j$  é a saída calculada para o neurônio  $j$ ,

$\frac{\partial f(\text{net}_j)}{\partial \text{net}_j}$  é a derivada da função de ativação em relação a  $\text{net}_j$ ,

$\text{net}_j$  é o somatório ponderado das entradas do neurônio  $j$ .

Para os neurônios localizados nas camadas internas (intermediárias) o cálculo do erro deve ser realizado da camada de saída para a camada de entrada. Por esse motivo o algoritmo é chamado de *back-propagation* (propagação para trás). Assim sendo, os erros podem ser determinados pela equação a seguir.

$$\delta_j = \frac{\partial f(\text{net}_j)}{\partial \text{net}_j} \cdot \sum_l \delta_l w_{jl}$$

onde,  $w_{jl}$  corresponde ao peso entre o neurônio que se quer calcular e o neurônio da camada posterior,

$l$  é o número de neurônios da camada posterior,

$\delta_l$  é o erro referente a cada neurônio da camada posterior.

A equação mostrada acima reflete a propagação do erro da camada de saída até a primeira camada. Através dela pode-se observar que o erro obtido é propagado sempre para a camada anterior, a partir da camada de saída.

### 3.2. Topologia

Os dois fatores mais relevantes na determinação da topologia de uma MLP são o número de camadas e o número de neurônios em cada camada. Esses fatores são bem interligados. A definição de uma certa quantidade de camadas influencia na quantidade de

neurônios ideal em cada camada. O mesmo acontece se a quantidade de neurônios for adotada primeiramente.

O número de camadas ocultas utilizadas na composição da rede neural influencia na formação dos tipos de região de separação dos dados que se pode obter. Na Figura 3.1, observam-se as regiões distinguíveis de acordo com o número de camadas. Na primeira linha está representada uma MLP com apenas uma camada, que corresponde a um *perceptron* simples, onde a única camada representada é a camada de saída. Pode-se observar que com o aumento das camadas ocultas, as regiões formadas permitem um melhor ajuste aos dados.

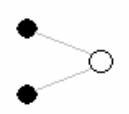
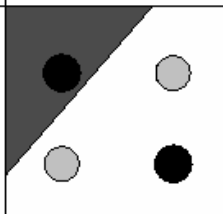
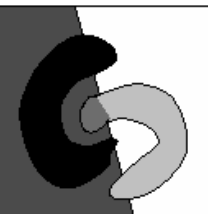

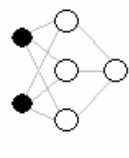
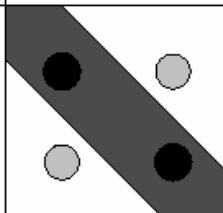
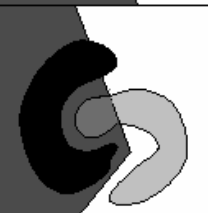
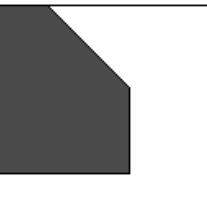
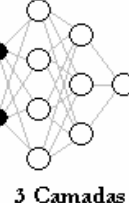
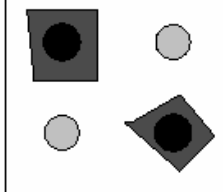


Estrutura	Tipos de regiões de decisão	Problema do ou exclusivo	Classes com regiões emaranhadas	Forma geral das regiões
 <p>1 Camada</p>	Semi-espaco limitado por um hiperplano			
 <p>2 Camadas</p>	Regiões convexas abertas, ou regiões fechadas			
 <p>3 Camadas</p>	Arbitrário (complexidade limitada pelo número de camadas escondidas)			

Figura 3.1 – Tabela relacionando os tipos de região, de acordo com o número de camadas.

Retirado de Lins (2002) *apud*. Lippman (1987)

Flood & Kartan (1994a) afirmam que as MLPs dotadas de pelo menos duas camadas escondidas provêm um acréscimo de flexibilidade necessário para modelar sistemas complexos. Contudo, é importante lembrar que a utilização de grande

quantidade de camadas pode se tornar um limitante da análise por exigir capacidade de processamento bem maior.

Na definição do número de camadas, deve-se considerar também o correto ajuste aos dados que se possui. Na Figura 3.2 se podem observar os diferentes ajustes possíveis de serem obtidas de acordo com o número de camadas adotadas. Em 3.2(a), o número de camadas foi excessivo, causando um ajuste muito preciso a dados da fase de treinamento, mas perdendo a capacidade de previsibilidade da rede (*overfitting*). Em 3.2(c) a solução obtida não acompanha os exemplos de treinamento, nem tampouco os exemplos de teste. Isso ocorre devido à uma definição de um número de camadas abaixo do ideal. Em 3.2(b), o ajuste ocorre de forma satisfatória tanto para os dados de treinamento, quanto para os dados de teste, evidenciando uma boa escolha da topologia.

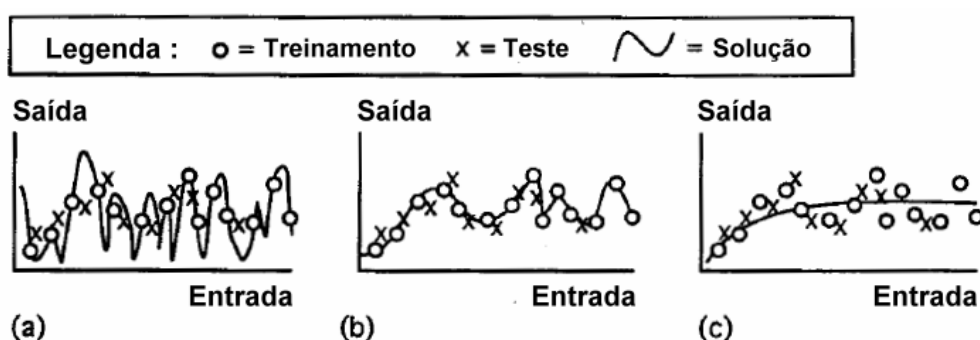


Figura 3.2 – Tipos de ajuste que se pode obter de acordo com a configuração adotada.

Retirado de Flood & Kartan (1994a)

Percebe-se que para a definição do número de camadas a ser adotado em uma MLP não há uma regra bem definida. Aconselha-se normalmente a definição de uma série de topologias de acordo com o número de dados de entrada e saída. Essas diferentes topologias deverão ser treinadas e testadas. Após esses treinamentos e testes, aconselha-se adotar aquela na qual a rede ajustou melhor os dados, gerando os menores erros tanto na fase de treinamento quanto na fase de testes, ou seja, aquela que resulta na melhor performance conjunta.

Ghaboussi & Sidarta (1998) apresentam a *Nested Adaptive Neural Networks*, que seria um novo modelo de RNA, cuja topologia se ajusta automaticamente à melhor configuração. Contudo, no próprio estudo comenta-se que esse tipo de rede é melhor indicado para situações onde a resposta atual possa depender de algumas respostas anteriores. Nesse caso os neurônios adicionais seriam baseados nos resultados anteriores.

### **3.3. Tratamento de Dados**

O tratamento dos dados de entrada e saída das redes MLP permite obter resultados bem mais efetivos. A primeira necessidade de tratamento dos dados decorre de utilizar padrões discretos de entrada e saída, pois para a operacionalização da rede é necessário que cada estado seja representado por um número. Um exemplo de variável discreta é a representação da classificação tátil-visual de areias, onde se definem quatro situações: fina, média, grossa, e pedregulho.

Uma das alternativas é representar cada classe por um número real, dando preferência a números mais próximos para parâmetros com características parecidas. Essa alternativa tem a vantagem de utilizar somente um neurônio de entrada exigindo menor capacidade computacional, contudo, pode causar instabilidade durante o treinamento.

Outra alternativa, é a utilização da notação binária, na qual, cada um dos padrões seria representado por um neurônio. Sendo assim, se faz necessário um neurônio na camada (de entrada ou saída) para cada padrão discreto. Esse tipo de representação tem a desvantagem de exigir uma maior capacidade computacional para a realização dos cálculos, contudo, a representatividade é bem melhor, além de diminuir as chances de desestabilização da rede.

---

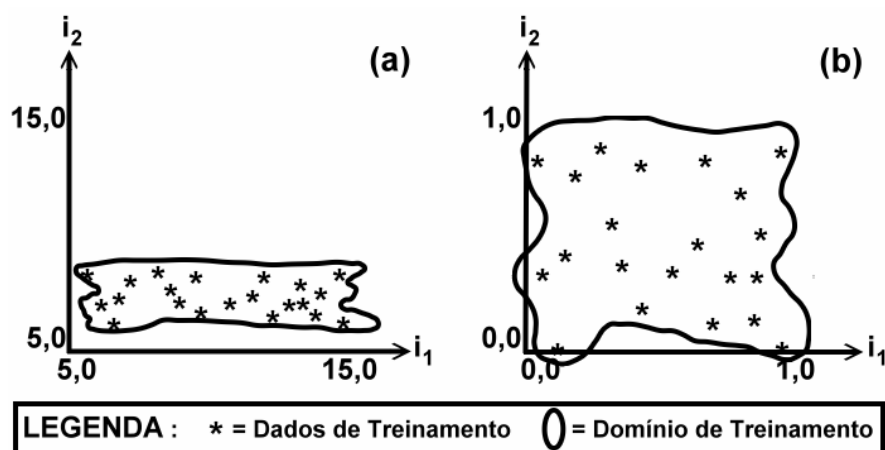
Há ainda possibilidades intermediárias, que usam a notação binária combinada com a mudança de números. Nesses casos o número de neurônios fica menor em relação à representação binária individual, e a representação é melhor do que a representação dos números.

Na Tabela 3.1 se podem observar, como exemplo, as alternativas para representar a classificação das areias, de acordo com cada tipo de representação.

**Tabela 3.1** – Formas de representação da classificação das areias em uma RNA.

Tipo de Representação	Classificação			
	Fina	Média	Grossa	Pedregulho
Real	0,00	0,33	0,67	1,00
Binária	0001	0010	0100	1000
Real / Binária	00	01	10	11

Também se faz interessante o tratamento dos dados não discretos. A normalização dos padrões dentro de uma faixa melhora consideravelmente o desempenho da rede. Isso se deve a uma melhor distribuição dos valores. Na Figura 3.3 se pode observar que com o tratamento dos dados, ocorre a compatibilização entre as dimensões dos parâmetros utilizados na análise. Com isso, a rede poderá definir as prioridades para os parâmetros garantindo uma maior liberdade para definição dos pesos, obtendo com essa operação melhores resultados.



**Figura 3.3** – Gráficos ilustrando a normalização dos dados. (Flood & Kartan ,1994a)

Para o caso em que os dados são transformados e assumem valores menores que 1, evita-se também um problema muito comum em algumas redes, que é a saturação dos pesos. Nessas situações, os dados de entrada de um neurônio atingem valores muito altos dificultando que o valor de saída do neurônio possa ser modificado caso seja necessária uma inversão.

A faixa de normalização dos dados, depende também da função de ativação utilizada. Por exemplo, quando se utiliza a função sigmoïdal, os valores de saída podem variar entre 0 e 1, sendo assim, o ideal é normalizar os dados de entrada e saída para valores entre 0 e 1. Quando se usa a função de ativação da tangente hiperbólica os valores variam entre -1 e 1.

Duas rotinas são utilizadas com mais frequência para a normalização dos dados. São elas: Máximo e Mínimo; e Variância Unitária. No processo de máximo e mínimo, o máximo valor é normalizado para 1 e o mínimo para 0. Para isso, todos os dados são diminuídos do valor mínimo, e divididos pela diferença entre o valor máximo e o valor mínimo. A equação utilizada para gerar esses valores é:

$$\bar{x} = \frac{x - x_{\min}}{x_{\max} - x_{\min}}$$

onde,

$x$ : dado não normalizado

$x_{\min}$ : valor mínimo entre os dados

$x_{\max}$ : valor máximo entre os dados

$\bar{x}$ : dado já normalizado

No tratamento de dados com variância unitária, os dados são transformados de forma que a média dos mesmos esteja centrada na origem. Além disso, a variância do conjunto de dados será igualada a 1. Com essa transformação, garante-se que os dados serão localizados próximo de zero, e com pequenos valores, como é desejável à rede.

---



Shi (2000) apresenta uma nova forma de normalizar os dados utilizando funções de distribuição cumulativa. O novo método diminuiu os erros de previsão em até 13% quando comparado com a transformação linear. Esse método permite transformar os dados com a mesma superfície de distribuição, permitindo uma uniformidade nos dados obtidos após o treinamento.

### 3.4. *Parâmetros de Treinamento*

Durante o treinamento, alguns parâmetros devem ser observados para garantir uma melhor convergência do sistema. Para isso, é interessante o acompanhamento dos erros de treinamento e dos erros de teste conjuntamente. Na Figura 3.4, pode-se observar a evolução do erro medido, tanto para os exemplos de treinamento, quanto para os exemplos de teste. Percebe-se que em uma boa interpolação o erro obtido com os exemplos de teste é próximo dos obtidos com os exemplos de teste.




Figura 3.4 – Gráfico de erros de acordo com a interpolação. (Flood & Kartan (1994a))

Quando a interpolação não ocorre satisfatoriamente o erro nos dados de treinamento, muitas vezes, continuam baixos, contudo, os exemplos de teste não convergem da mesma forma.

Nessas situações, diz-se que a RNA ‘decorou’ os dados de treinamento, o que significa que o treinamento não está permitindo que a rede mantenha a capacidade de generalização. Por isso, a rede possui ótimos ajustes para os dados de treinamento, contudo, quando ocorrem alterações nos valores de entrada (exemplo de teste), a rede não tem capacidade de obter valores coerentes. A seguir são descritos alguns parâmetros importantes de serem observados no treinamento de uma MLP, assim como as recomendações da melhor forma de proceder com cada um dos mesmos.

### **3.4.1. Número de Ciclos**

No treinamento, um ciclo corresponde à apresentação de todos os padrões que se possui. Um número excessivo de ciclos durante o treinamento pode propiciar a perda da capacidade de generalização da rede.


Nesses casos, assim como foi mostrado na Figura 3.4, a rede converge para o erro mínimo dos dados de treinamento, mas o erro obtido com os dados de teste aumenta.

Para evitar que a rede ‘decore’ os dados de treinamento deve-se limitar a quantidade de ciclos durante o treinamento. Tal limitação encerra o treinamento antes que a rede perca a capacidade de generalização.

### **3.4.2. Momentum**

Na superfície de erro, existem pontos onde a solução é estável, contudo, não é a melhor solução. Na Figura 3.5 pode-se observar um exemplo de superfície de erro e os respectivos mínimos locais, e o mínimo global.

---

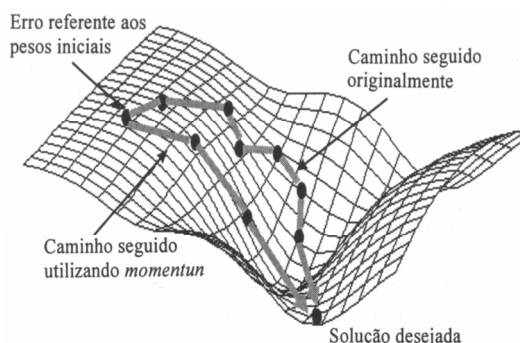


**Figura 3.5** – Superfície de erro com mínimos locais.

Algumas ferramentas são utilizadas para acelerar o algoritmo *back-propagation* e reduzir a incidência de mínimos locais. O termo *momentum* tem sido utilizado com maior frequência. Ela baseia-se na utilização do erro obtido anteriormente para também influir no incremento posterior nos pesos. O *momentum*  $\alpha$  é utilizado na equação de atualização dos pesos  $w_{ij}$  a partir do ciclo, com a equação:

$$w_{ij}(t+1) = w_{ij}(t) + \eta \cdot \delta_j(t) \cdot x_i(t) + \alpha \cdot (w_{ij}(t) - w_{ij}(t-1))$$

Na Figura 3.6 observa-se a influência que a utilização do termo *momentum* pode ter sobre o caminhamento da solução sobre uma superfície de erro, acelerando o treinamento e evitando oscilações desnecessárias nos valores dos pesos. Porém, a utilização desse termo, exige uma capacidade computacional bem maior, pois além dos cálculos a serem realizados, necessita-se também armazenar os dados relativos à solução anterior para determinar os valores. Tal necessidade, muitas vezes inviabiliza a utilização dessa ferramenta.



**Figura 3.6** – Superfície do erro e a influência do termo momentum. (Braga *et al.*, 2000).

### 3.5. Análise de Sensibilidade Analítica

Na utilização de uma Rede Neural Artificial as relações entre os parâmetros, é definida pela estrutura interna da rede. Contudo, uma análise interessante é observar a influência de um fator de entrada nos fatores de saída. A mensuração de quanto um fator de entrada pode influenciar um parâmetro de saída permite um melhor entendimento do sistema.

Em Engenharia Geotécnica, a definição de modelos que representem de forma fidedigna a relação entre os fatores de um processo, permite entender melhor o fenômeno e seus parâmetros.

Nesse sentido, Yang & Zhang (1991) apresentaram o conceito do RSE (*Relative Strength of Effect*) que analisa a influência de um certo parâmetro de entrada em um outro parâmetro de saída. A influência de um parâmetro de entrada  $i$ , sobre um parâmetro de saída  $k$ , é dada por:

$$RSE_{ki} = C \cdot \sum_{j_n} \sum_{j_{n-1}} \dots \sum_{j_1} W_{j_n k} G(e_k) W_{j_{n-1} j_n} G(e_{j_n}) W_{j_{n-2} j_{n-1}} G(e_{j_{n-1}}) \dots W_{ij_1} G(e_{j_1})$$

onde,

$C$ : é uma constante para normalizar o máximo valor de  $RSE_{ki}$  em 1.

$W_{ab}$ : são os pesos obtidos durante o treinamento relacionando os neurônios da camada a com os neurônios da camada b.

$G(e_k)$ : é a derivada da função de ativação, que no caso da função sigmoideal é dada

$$\text{por: } G(e_k) = \frac{e^{-e_k}}{(1 + e^{-e_k})^2}$$

$e_k$ : é a entrada do neurônio e é dada por:  $e_k = \sum_j W_{jk} \cdot O_j + b_k$  sendo  $O_j$ , a saída no neurônio da camada  $j$ ,  $b_k$  o *bias* do neurônio da camada  $k$ , e  $W_{jk}$  o peso que relaciona esses 2 neurônios.

---

A formulação apresentada pelos autores foi desenvolvida considerando que a função de ativação é uma função sigmoïdal.

Utilizando, ainda, essa mesma ferramenta, Yang & Zhang (1997a) mostram a aplicação dessa técnica para ensaios de carga pontual em amostras. Interessante observar que nessa aplicação, algumas variáveis discretas, como direção do carregamento em relação ao plano de fraqueza e tipo de rocha, puderam ser avaliadas pela técnica, obtendo ótimos resultados.

Com a possibilidade de mensurar o efeito de qualquer parâmetro de entrada com qualquer parâmetro de saída, podem-se hierarquizar as influências de cada fator nas saídas, definindo assim quais seriam as características mais relevantes. Yang & Zhang (1997b) aplicam essa metodologia para análises de estabilidade de taludes. De acordo com os valores obtidos, realizou-se uma hierarquização para os casos estudados, permitindo então, a definição de quais fatores têm maior influência na estabilidade dos taludes estudados.

---



#### 4. RNA EM GEOTECNIA

A solução de problemas da Engenharia Geotécnica é usualmente realizada através de abordagens teóricas e empíricas. A convivência destas duas abordagens deve-se à existência de incertezas na definição da geologia da engenharia. Um maior grau de incerteza em relação às condições geológicas e aos parâmetros geotécnicos é talvez a mais distinta característica da geomecânica comparada com outros campos da engenharia.

A maioria dos trabalhos publicados, envolvendo a aplicação de redes neurais em geotecnia, é recente. Os primeiros datam do início da década de 1990 e a quantidade de publicações cresceu de forma surpreendente até o presente ano. Nota-se por parte dos autores um grande entusiasmo.

Uma das características mais importantes das Redes Neurais Artificiais é a sua capacidade de aprendizado e generalização dos exemplos utilizados no seu treinamento. Além disso, o processo de aprendizado torna possível a realização de previsões mesmo quando os dados estão incompletos ou repletos de ruídos, o que em outras ferramentas computacionais poderia ser um limitante muito forte. (Agrawal *et al.* (1994))

Zhang *et al.* (1991) comentam que os processos de formação, as características geológicas, e as necessidades de engenharia dificultam a definição de modelos matemáticos para a modelagem do comportamento dos maciços. Nesses casos a utilização de dados experimentais pode trazer grandes avanços. Nesse sentido, as Redes Neurais Artificiais têm se tornado uma ferramenta interessantíssima, pois têm a

---

capacidade de considerar todos os fatores relevantes e definir automaticamente suas importâncias de acordo com os dados que já se possui.

Ghaboussi (1992) salienta que, quando se utilizam as RNAs, os resultados de experimentos de laboratório, ou os dados adquiridos, são utilizados diretamente, sem a realização de simplificações, sendo que todas as correlações são realizadas na estrutura interna da rede. Ou seja, a amplitude entre as ligações entre os nós revela essas correlações.

Por esses motivos, aplicações de RNAs em problemas geotécnicos têm se mostrado cada vez mais eficientes. Atualmente, são várias as sub-áreas da Engenharia Geotécnica que já tiveram uma aplicação bem sucedida das RNAs. Entre elas, destacam-se: previsão de capacidade de estacas; modelagem do comportamento de solo; caracterização local; recalques de estruturas, estabilidade de taludes; projetos de túneis e escavações subterrâneas; permeabilidade e condutividade hidráulica de solo; compactação de solo; e classificação de solo. Shanin *et al.* (2001) e Adeli (2001) resumem muito bem as aplicações já realizadas em cada uma dessas sub-áreas, mostrando sua evolução.

Goh (1995) apresenta uma aplicação de uma MLP para capacidade de carga de estacas cravadas em argila. Salienta ainda que em fenômenos onde um entendimento inadequado do mesmo ou dos fatores que o afetam, assim como uma quantidade limitada e não confiável de informações, o engenheiro geralmente se vê restrito à utilização de soluções empíricas de projeto.

Apesar do uso consagrado das MLPs para aplicações geotécnicas, a utilização de outras topologias de forma adequada pode fornecer ótimos resultados também. Cai *et al.* (1998) lançam mão de uma rede MLP e de uma rede de Hopfield para modelar as relações entre diferentes fatores geotécnicos importantes na engenharia obtendo resultados

---



bastante satisfatórios. A MLP modela os mecanismos de interação não lineares entre os parâmetros, enquanto que a rede de Hopfield simula processos dinâmicos de trocas de energias entre os fatores.

Hashash *et al.* (2002) aplicam MLPs para modelar o comportamento de um solo e também para análise do processo de escavação de uma vala. Em suas aplicações utilizam-se as técnicas descritas por Ghabossi *et al.* (1992) onde a topologia pode ser determinada de acordo com o método de resolução de forma semi-automática.

No Brasil, dentre os trabalhos pioneiros na utilização de redes neurais em geotecnia, pode-se citar o de Dyminsky *et al.* (1995) na elaboração de modelos constitutivos e o de Lolo & Zuquette (1996) que descreveram a perspectiva de utilização das redes neurais no mapeamento geotécnico através da técnica de avaliação do terreno.

Dyminsky (2000) apresenta a aplicação de MLPs para 3 problemas geotécnicos bastante comuns: interpretação de provas de carga dinâmica de fundações; modelagem do comportamento tensão  $\times$  deformação de diferentes tipos de solos; e interpretação de investigações de subsolo. Lolo (2000) apresentou, ainda, os resultados de identificação de padrões de relevo representados como perfis e modelos digitais, através de Mapeamento Geotécnico.

#### **4.1. RNA na previsão de recalques em Obras Subterrâneas (Túneis)**

O crescimento demográfico acentuado das cidades, nem sempre tem sido acompanhado por maior ocupação da área. Por isso, a disponibilidade de espaço tem se tornado uma dificuldade cada vez maior. Sendo assim, a realização de obras subterrâneas, tem sido uma crescente necessidade para garantir um melhor aproveitamento do espaço.

---

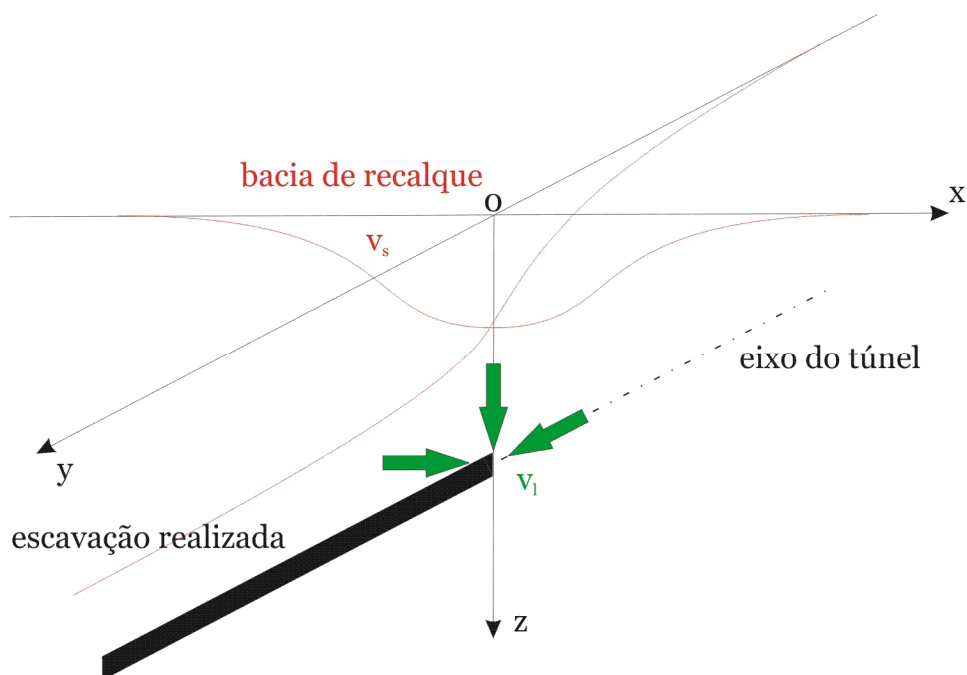
Dentre essas obras, se destacam os túneis urbanos. Dentre as muitas utilizações possíveis para os mesmos, destacam-se: rodovias; transporte público (metrô, e ônibus pelas próprias rodovias); obras de saneamento básico (água e esgoto); passagem de dutos e fios; entre outras.

Devido ao alto nível de urbanização, a construção de túneis urbanos encontra dificuldades devido à interação da obra com as construções pré-existentes. A interferência com prédios, e outras obras influencia em decisões durante o projeto, e durante a construção. No projeto, por exemplo, decisões como tipo de suporte, forma de escavações e até mesmo horário das escavações (quando se utilizam explosivos para escavações), são definidas buscando a mínima interferência possível com as obras e ocupação da região.

A instrumentação dos túneis, e da superfície por onde passa o mesmo, tem sido a melhor forma de controlar a qualidade da obra. Os recalques superficiais são normalmente medidos através de marcos superficiais, enquanto que os em profundidade são realizados através de tassômetros.

Os recalques que ocorrem durante a construção dessas obras são as formas mais significativas de interferência com as obras pré-existentes. A formação de bacias de recalque exageradas, pode introduzir esforços em edificações. Muitas vezes esses esforços não levam a construção à ruína, contudo, proporcionam algumas deteriorações desagradáveis (fissuras), que são de responsabilidade da construtora da obra subterrânea. Para esses casos, deve-se evitar a ocorrência de recalques diferenciais elevados. Na Figura 4.1 pode-se observar a forma de ocorrência de uma bacia de recalque típica para a passagem de um túnel.

---

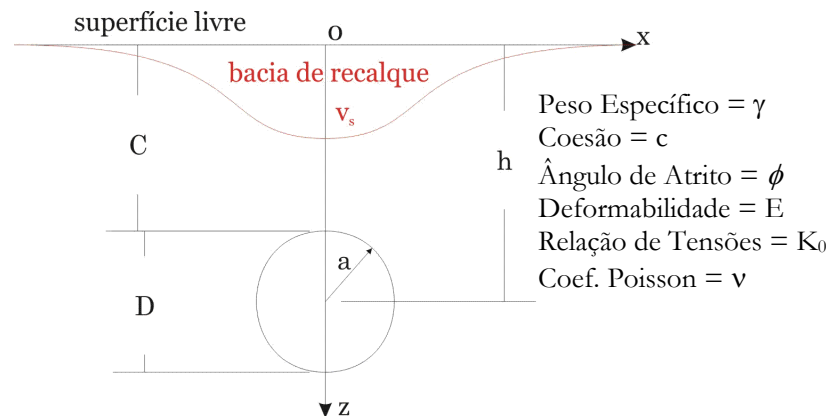


**Figura 4.1** – Bacia de recalque durante a passagem de um túnel.

Mesmo em regiões não urbanizadas, o controle dos recalques é realizado e necessário para a manutenção da integridade da obra. Instabilidades de frente de escavação, e deslocamento exagerado do maciço podem ser observados através da medição dos recalques, podendo fornecer boa previsão da qualidade da obra.

Além disso uma boa instrumentação permite, através da análise das medidas de recalque, obter informações sobre as características do maciço na região. Tais características podem ser, a posteriori, utilizadas como parâmetros de projeto em outras obras, permitindo a realização de uma construção mais adequada à região.

Na Figura 4.2, pode-se observar alguns dos fatores da obra que influenciam a ocorrência dos recalques, assim como sua intensidade. Há ainda outras informações, como velocidade de avanço do equipamento, que influenciam no recalque, e que não são mostrados na figura, mas que são de grande relevância.



**Figura 4.2** – Bacia de recalque típica e alguns fatores de influência.

As informações obtidas durante a construção dos túneis e que influenciam nas movimentação em superfície podem ser divididas em 3 grandes grupos:

- *Características Geométricas*: área da seção (diâmetro equivalente), altura da frente de escavação, tipo de suporte, cobertura (C), profundidade (h), largura do pilar, túnel simples ou gêmeo;
- *Características do Maciço*: ângulo de atrito/coesão, tipo de maciço, permeabilidade, resistência à compressão, peso específico ( $\gamma$ ), módulo de deformabilidade (E), relação das tensões verticais e horizontais ( $K_0$ ), coeficiente de poisson ( $\nu$ );
- *Processo de Escavação e Suporte*: método de escavação (NATM/Shield), tipo de escavação (arco invertido/seção plena), distância do suporte ( $Ld/R$ ), tempo de suporte, métodos de suporte (ancoragem/concreto projetado/calota metálica), velocidade de avanço;

Além da interferência com outras obras, procedimentos modernos de escavação de túneis levam em conta tanto o monitoramento e interpretação dos deslocamentos medidos quanto as informações geológicas e geotécnicas da região de escavação. O monitoramento contínuo dos deslocamentos, determinando o tipo e a dimensão do

---

suporte, e a técnica utilizada para o controle da estabilidade são partes importantes do projeto de escavações subterrâneas realizadas por NATM.(Sellner & Schubert (2000))

Sendo assim, um grande volume de informações pode ser obtido durante a construção de um túnel. Devido à grande quantidade de dados, sua análise se torna muitas vezes uma tarefa árdua e que exige grande experiência do responsável. Quando há quantidade, pode-se lançar mão de ferramentas computacionais que realizam muitas vezes com grande eficiência a análise dos dados.

A utilização das RNAs em análises de instrumentação de túneis tem ocorrido de forma crescente. Suwansawat (2004) comenta que as RNAs têm-se mostrado a melhor opção para análises dos dados de recalques devido à sua grande capacidade de se ajustar mesmo em problemas complexos, com relações não lineares, e aproveitando a experiência prática. Sua capacidade de relacionar informações com relações antes desconhecidas, torna sua utilização muito atraente, para relacionar os recalques medidos, com as características da obra.

Suwansawat (2006) aplicou também RNA aos dados obtidos nos túneis do metrô de Bangkok, onde foi utilizada uma tuneladora de frente balanceada. O autor mostra como utilizou RNA para estabelecer correlações entre os métodos construtivos da tuneladora, as características do maciço e as deformações ocorridas em superfície. O autor ressalta que uma das maiores dificuldades das análises é a obtenção de todos os parâmetros que possam ter relação com os níveis ocorridos de instrumentação. Apesar disso, a análise é considerada importante para consolidação do conhecimento e constituiu excelente oportunidade para estudar o comportamento de uma tuneladora de frente balanceada em túneis rasos.

---

A seguir, apresentam-se dois exemplos expressivos da aplicabilidade das RNAs, mais especificadamente das MLPs, para análise de dados de escavação de túneis. Os recalques são comparados e as redes são treinadas para obter as melhores previsões.

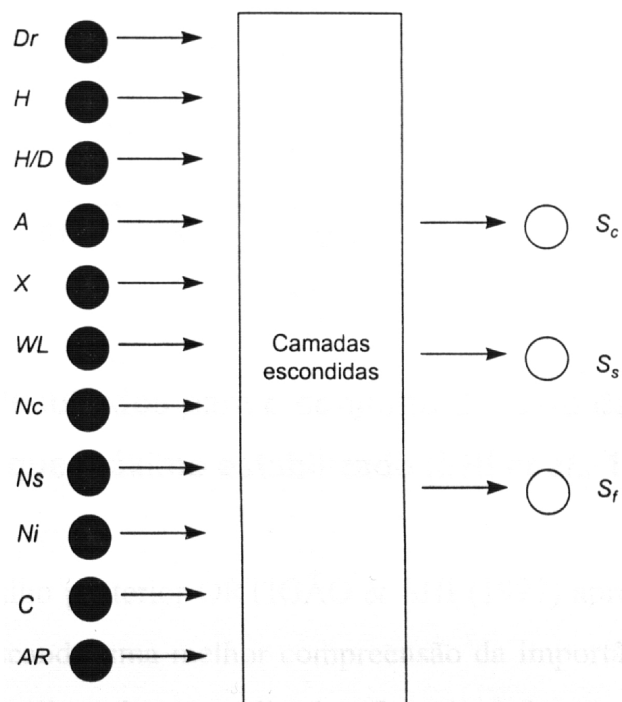
#### 4.2. *Túnel do Metrô de Brasília*

Shi *et al.* (1998) aplicaram as Redes Neurais Artificiais para o estudo dos recalques obtidos nas obras dos túneis do Metrô de Brasília, obtendo ótimos resultados. O objetivo principal da análise foi prever os recalques no último trecho de escavação, utilizando os valores obtidos no restante inicial da escavação. Na Tabela 4.1 pode-se observar as características relevantes da obra utilizada na análise.

**Tabela 4.1** – Principais Características do Túnel do Metrô de Brasília

Túnel do Metrô de Brasília	
Extensão	6,5 km
Diâmetro médio	9,6 m
Maciço / Profundidade	Argila Porosa a baixa profundidade (8-12 m)
Processos Construtivos (Três)	Seção Plena
	Avanço Parcializado com arco invertido
	Galeria Lateral

De acordo com os dados que se possuía, e os fatores influentes nos recalques, definiu-se a topologia mostrada na Figura 4.3. Na definição da arquitetura foram adotados 11 parâmetros de entrada, e 3 parâmetros de saída. Na parte oculta, adotou-se uma camada intermediária com 24 neurônios. Os autores revelam ainda que foram realizados alguns testes para a definição do número de neurônios da camada interna, sendo que, os autores justificam que essa adoção foi suficiente.




**Figura 4.3** – Topologia da MLP adotada no Metrô de Brasília. (Shi *et al.*, 1998)

Na Tabela 4.2 e na Figura 4.4, pode-se observar a descrição de todos os parâmetros e a representação dos principais parâmetros geométricos de entrada.

**Tabela 4.2** – Dados de entrada da RNA utilizada para os túneis de Brasília

Tipos de Parâmetro	Sigla do Parâmetro	Descrição
Entrada	$Dr$	Distância em relação ao início da escavação
	$H$	Profundidade do túnel (Cobertura)
	$H/D$	Relação entre a Cobertura e o Diâmetro Equivalente
	$A$	Área da Seção
	$X$	Atraso de fechamento do arco invertido
	$WL$	Profundidade do Nível d'água
	$Nc$	$N_{SPT}$ medido no nível do teto do túnel
	$Ns$	$N_{SPT}$ medido no nível inferior do túnel
	$Ni$	$N_{SPT}$ medido no nível do arco invertido
	$C$	Método de Construção
	$AR$	Velocidade de avanço da escavação
Saída	$S_{c,máx}$	Recalque na Passagem
	$S_{i,máx}$	Recalque no Fechamento
	$S_{f,máx}$	Recalque Estabilizado



**Figura 4.4** – Parâmetros geométricos de entrada da MLP. (Shi *et al.* (1998))

O parâmetro referente ao método de escavação merece especial atenção, pois é o único dos itens cujo valor não corresponde a um número retirado em campo. Os métodos de escavação utilizados foram: seção plena; avanço parcial com arco invertido; e galeria lateral. Nesses casos, se faz necessária a adoção de algum critério para a definição numérica do parâmetro.

Os autores optaram pela adoção dos números 1, 2 e 3, relacionando-os com cada tipo de escavação. Para a definição do valor referente a cada tipo de escavação os autores observaram a similaridade entre os métodos de escavação. Sendo assim, os números foram definidos da seguinte forma: 1 para seção plena; 2 para avanço parcializado com arco invertido; e 3 para avanço parcializado com galeria lateral.


Na separação dos dados, adotou-se que os primeiros 6 km de escavação seriam utilizados para o treinamento da rede. Por conseguinte, os recalques medidos nos últimos 500 m da obra seriam utilizados para a fase de testes. Tal divisão considerou o fato de que o estudo visava à previsão de recalques, a partir, dos recalques anteriores medidos na obra. Sendo assim, a fase de testes também foi utilizada para a análise da qualidade da previsão de recalques.



Shi *et al.* (1998) comentam que durante a fase de treinamento ocorreram problemas de instabilidade numérica em alguns pontos da rede. Segundo os autores, o fato de usar como saídas da rede os valores de recalque em três níveis diferentes, implicava na divergência entre valores. Por isso, muitas vezes, segundo um dos padrões de recalque a solução deveria convergir em um sentido. Contudo, o outro valor forçava a convergência em sentido diferente. Sendo assim, o algoritmo tinha dificuldades para convergir. Para solucionar esse problema, optou-se por modelar uma Rede Neural para cada tipo de recalque que se conhecia.

O treinamento excessivo da rede trouxe à tona um problema muito comum quando o critério de parada não está bem ajustado. A RNA modelada começou a perder a capacidade de previsão, ou seja, ela passou a “decorar” os padrões da fase de treinamento.


Para os valores apresentados nessa fase, a resposta da rede era coerente e próxima da medida. Contudo, para os valores de teste, os resultados não tinham boa correlação com os dados medidos. Para correção desse problema, adotou-se também a quantidade de ciclos como uma limitante para finalizar o treinamento da rede. Assim, melhores resultados foram obtidos. Na Figura 4.5, pode-se observar o gráfico que correlaciona os recalques medidos com os obtidos pela rede, para os dados da fase de treinamento.



**Figura 4.5** – Comparação entre medido e calculado para durante o treinamento.

Os valores obtidos para a fase de treinamento foram considerados pelos autores, valores com ótima correlação. E, realmente, pode-se observar que os gráficos estão bem próximos, e que os valores calculados pela RNA acompanham muito bem os dados medidos. Nesses casos é importante a utilização de todos os exemplos do banco de dados, incluindo os casos mais extremos.

Na fase de teste, foram utilizados os dados obtidos nos últimos 500m de escavação. Esses dados foram inseridas na RNA modelada, para a obtenção do recalque calculado. Na Figura 4.6, apresenta-se o gráfico com os dados da fase de testes. Pode-se observar os valores medidos e os determinados pela rede, comparados de acordo com a distância dos mesmos ao início do túnel.



**Figura 4.6** – Gráfico com os dados utilizados na fase de testes.

Os resultados obtidos são considerados pelos autores como de ótima qualidade. A correlação entre os valores calculados e os medidos é bastante satisfatória. No trecho entre as progressivas 6100 m e 6150 m, a ocorrência de uma rodovia em superfície reduziu consideravelmente os valores dos recalques medidos, sendo por essa razão,

observada tamanha diferença dos valores calculados pela rede, que não pôde considerar a rodovia.

Os autores salientam ainda que a modelagem da RNA permitiu grande redução dos erros para a previsão dos recalques. Pois, segundo os modelos clássicos, o erro entre os valores previstos comparados com os valores medidos em campo foi de até 70 mm. Com a modelagem da RNA, esses valores tiveram um ajuste maior, sendo que o erro máximo de previsão foi reduzido para 33,4 mm, demonstrando assim, a ótima capacidade de uso dessa ferramenta na previsão de recalques em túneis.

### 4.3. Túnel do Metrô de Shanghai

An *et al.* (2004) apresentam o estudo realizado utilizando Redes Neurais aplicadas para o túnel do Metrô de Shanghai. As RNA's foram utilizadas para prever a distribuição dos recalques longitudinais. A partir das seções anteriores, a rede buscava prever os recalques a ocorrerem na próxima seção. Na Figura 4.7, pode-se observar uma curva típica de recalque longitudinal.

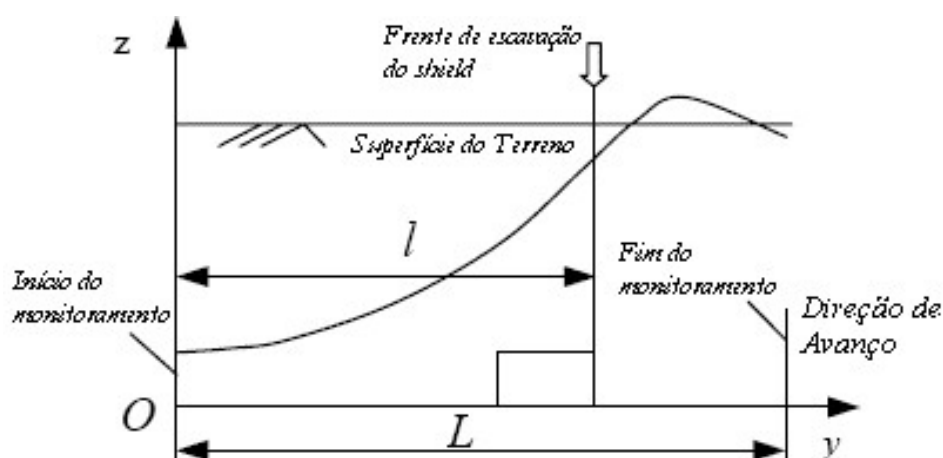
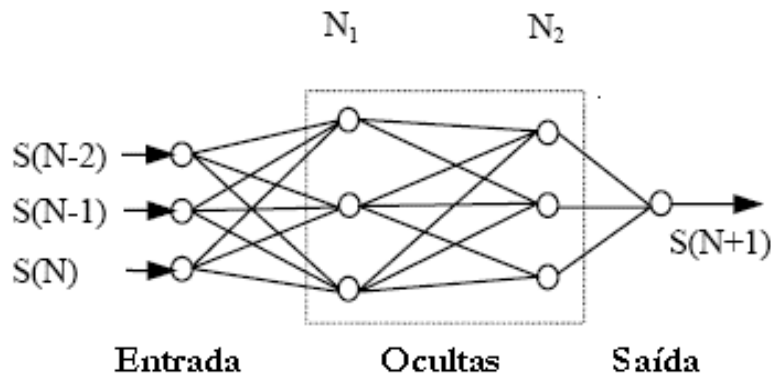


Figura 4.7 – Diagrama típico de recalque no sentido longitudinal. (An *et al.* (2004))

Modelou-se então uma MLP para a previsão. A definição dos parâmetros como número de camadas intermediárias, e número de neurônios para cada camada, foi realizada utilizando-se técnicas de algoritmo genético, para determinar a melhor topologia. Na Figura 4.8, pode-se observar a Rede Neural modelada para a análise do problema.



**Figura 4.8** – Topologia da RNA utilizada para a análise. (AN *et al.*, 2004)

Os parâmetros de entrada utilizados foram:


- $S(N-2)$ : Recalques observados 2 dias antes
- $S(N-1)$ : Recalques observados no dia anterior
- $S(N)$ : Recalques observados no dia

Parâmetro de Saída:


- $S(N+1)$ : Recalque a ser previsto para o dia posterior

As análises conduziram a resultados adequados. Nas Figuras 4.9 a 4.12 pode-se observar a comparação dos valores medidos e dos valores previstos através da RNA. Pode-se observar que, mesmo quando ocorrem significativas alterações na forma da curva, as previsões se ajustam aos valores medidos.


Tal ajuste não seria esperado quando se considera que no modelo não foram utilizados parâmetros geométricos e do material. Contudo, pode-se perceber que as correlações são muito boas.



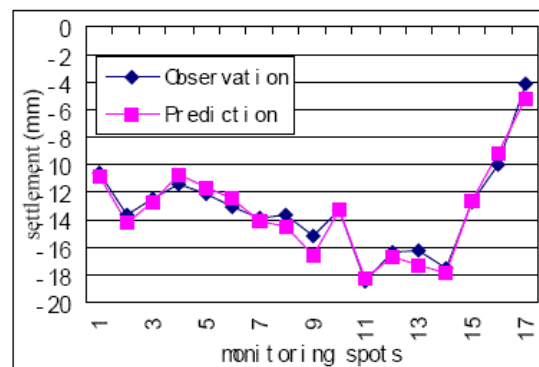
**Figura 4.9** – Recalques em 19/07/2002



**Figura 4.10** – Recalques em 20/07/2002



**Figura 4.11** – Recalques em 21/07/2002



**Figura 4.12** – Recalques em 22/07/2002

Além disso, ressalta-se aqui, a utilização dos Algoritmos Genéticos para determinação da melhor topologia para ser utilizada pelo modelo. Devido à pouca quantidade de informações no início da escavação, a determinação anterior da melhor topologia pode otimizar o uso da rede, permitindo o treinamento da mesma.



## 5. MATERIAIS E MÉTODOS

A utilização de Redes Neurais Artificiais nesse campo, visa à previsão de recalques e ao estudo da influência dos parâmetros geológicos, construtivos e de projeto na magnitude dos mesmos. Com essa técnica, realiza-se o ajuste de uma rede a partir de dados históricos obtidos, para permitir a previsão a partir de parâmetros semelhantes, mas nem sempre iguais.

Na década de 90, deu-se a construção de grande parte dos túneis em operação do Metrô de São Paulo. Por se tratar de uma obra executada em regiões densamente povoadas e com alto nível de ocupação, um rigoroso controle dos recalques se fez necessário. Para isso as obras foram instrumentadas para um melhor controle dos recalques e de prováveis interferências em construções pré-existentes (redes de água e esgoto, fundações dos prédios e outras). O acompanhamento foi constante, com frequência de leitura no mínimo diária para as seções que se encontravam próximas à frente de escavação.

O plano de instrumentação foi composto por seções típicas para medição dos recalques ocorridos através de placas superficiais e de tassômetros profundos. A maioria dos túneis das Linhas 1 e 2 foi executada com método NATM de escavação. O estudo da influência dos mesmos é interessante para outras obras subterrâneas a serem executadas.

---

## 5.1. *Uso do MatLab<sup>®</sup> para RNAs*

O pacote MatLab 7<sup>®</sup> corresponde a um conjunto de ferramentas para computação numérica científica e de engenharia. Uma das grandes potencialidades do MatLab é a sua facilidade em realizar operações com matrizes, que é o elemento básico utilizado pelo programa. A sigla MatLab reflete essa característica: MATrix LABoratory. Tal habilidade permite uma redução nos tempos de resolução de muitos sistemas, se comparados com outras linguagens de programação.

Além disso, o MatLab, possui algumas caixas de ferramentas (*TOOLBOX*) para várias aplicações. Dentre elas, destaca-se aqui aquela criada para as Redes Neurais. Nessa *toolbox*, muitos algoritmos amplamente utilizados em análises por RNA, já estão implementados. A abordagem feita pelo programa assim como os comandos utilizados pelo mesmo serão aqui apresentados. Ressalta-se ainda que o estudo foi realizado com abordagem voltada para as redes MLP (Back-Propagation), e que portanto algumas ferramentas do pacote MatLab utilizadas em outras aplicações não são abordadas.

### 5.1.1. **Modelo de Neurônio**

No MatLab 7<sup>®</sup> o modelo de neurônio utilizado em uma rede *back-propagation* é o neurônio com a inserção do parâmetro *bias*. Sendo assim, as entradas são multiplicadas pelos pesos das conexões. Em seguida os resultados dessas multiplicações são somados, e a essa soma acrescenta-se o *bias*. Só então aplica-se a função de ativação à soma, gerando a saída do neurônio. A utilização dos *bias* visa a flexibilizar a rede, de forma que, ruídos nos dados possam ser contornados. Sendo assim, a análise possui maior capacidade de

---



generalização. Na Figura 5.1 pode-se observar o esquema típico do neurônio utilizados nas análises realizadas pelo programa MatLab.




Figura 5.1 – Modelo do neurônio padrão utilizado no MatLab 7<sup>®</sup>.

### 5.1.2. Definição da Rede

No MatLab 7<sup>®</sup> a rede neural é tratada como um argumento. Primeiramente deve-se definir as características da rede para que a mesma possa ser utilizada. Para isso, utiliza-se o comando a seguir, com a definição de 4 parâmetros:

```
net = newff(variacao,camadas,funcoes,treinamento)
```


Os parâmetros citados representam características da rede a ser modelada. O parâmetro *variacao* corresponde a um vetor onde são colocados os valores máximos e mínimos possíveis para cada elemento do conjunto de entrada. A característica *camadas* representa um vetor que contém o número de neurônios de cada camada da rede a ser modelada. A característica *funcoes*, corresponde aos *strings* referentes a função de transferência adotada em cada camada. Esse parâmetro será melhor detalhado a seguir. O parâmetro *treinamento* corresponde ao tipo de treinamento que será utilizado na rede, é denotado por um *string*, e será melhor detalhado em seguida.

A seguir observa-se um exemplo do comando de inicialização de uma rede com 2 elementos de entrada, 1 elemento de saída, uma camada intermediária (3 neurônios), assim como a representação das funções de transferência da camada intermediária (tangente hiperbólica) e da camada de saída (linear), além do tipo de treinamento (gradiente decrescente)


```
net=newff([-1 2;0 5],[3,1],{'tansig','purelin'},'traingd')
```

### 5.1.3. Funções de Transferência


O MatLab já inclui em sua biblioteca de funções as mais utilizadas no estudo de Redes Neurais. Nas Figuras 5.2, 5.3 e 5.4 a seguir apresentam-se as 3 principais funções de transferência já definidas no MatLab, e mais comumente utilizadas na abordagem de Redes Neurais.



**Figura 5.2** – Função de transferência sigmóide.  $\left( a = \frac{1}{1 + e^{-n}} \right)$



**Figura 5.3** – Função de transferência tangente hiperbólica.  $\left( a = \frac{1 - e^{-n}}{1 + e^{-n}} \right)$



**Figura 5.4** – Função de transferência linear. ( $a = n$ )

Para cada uma dessas funções estão também definidas as respectivas funções que correspondem à derivada dos mesmos e dadas por: `dlogsig`, `dtansig`, e `dpurelin`. Essas funções são importantes na determinação dos erros do algoritmo de treinamento da rede *back-propagation*.

#### 5.1.4. Tipos de Treinamento

A seguir são definidos os dois tipos de treinamento mais utilizados em redes MLP. Trata-se do treinamento com gradiente decrescente, sem e com momentum. Os dois modelos de treinamento aqui mostrados e já definidos no MatLab 7<sup>®</sup>, correspondem ao treinamento do tipo *batch*. No treinamento tipo *batch* os pesos sinápticos são atualizados somente depois que se completa um ciclo de apresentações de todos os padrões. No treinamento tipo *padrão* os pesos são atualizados a cada padrão apresentado.

O modo *batch* possui a vantagem de que a convergência da rede para o erro global permite uma melhor capacidade de generalização da rede treinada, pois, trabalha-se com erro global e não com o erro de cada padrão apresentado para atualizar os pesos.

#### 5.1.4.1. Gradiente Decrescente sem momentum (*traingd*)

No gradiente decrescente os pesos e *bias* são atualizados no sentido oposto ao gradiente da função erro. Para esse tipo de treinamento há 5 parâmetros associados, que podem ser definidos de acordo com o interesse que se possui no treinamento. Tais parâmetros são mostrados e definidos na Tabela 5.1.

**Tabela 5.1** – Descrição dos parâmetros associados à função *traingd*.

Sigla	Significado
epochs	Número máximo de ciclos a serem realizados
show	Indica o número de iterações entre as apresentações de parâmetros.
goal	O treinamento para se a função erro for menor que esse valor
time	Finaliza o treinamento se exceder o tempo
lr	Taxa de Aprendizagem: Regula a velocidade do treinamento

Cada um desses parâmetros podem ser definidos através do comando `net.trainParam`, onde deve-se ainda escrever o parâmetro que se quer alterar, como mostrado a seguir:

```
net.trainParam.show = 50;
net.trainParam.lr = 0.5;
net.trainParam.epochs = 300;
net.trainParam.goal = 1e-5;
```

#### 5.1.4.2. Gradiente Decrescente com momentum (*traingdm*)

O treinamento utilizando o momentum possui melhor capacidade de convergência, quando comparado ao treinamento somente com o gradiente decrescente. Para esse treinamento, acrescenta-se o parâmetro momentum, designado por *mc*. Para

alterar o valor desse parâmetro utiliza-se também o comando `net.trainParam` com a simbologia indicada a seguir:

```
net.trainParam.mc = 0.9;
```

Contudo, tal ferramenta exige uma maior capacidade computacional para a realização dos cálculos, pois, necessita armazenar também as variações dos pesos relativas ao ciclo anterior. Por isso, a utilização desse método é realizada quando o treinamento sem o mesmo não traz resultados satisfatórios.

### 5.1.5. Treinamento

Quando da realização de um treinamento da rede, mesmo que se deseje realizar um retreinamento, deve-se inicializar os pesos e biases da rede, de forma randômica, ao iniciar o treinamento. Para isso utiliza-se o comando `init`. Com esse comando os pesos e *bias* serão inicializados com valores entre -1 e 1, evitando assim, a ocorrência de saturação nos neurônios. A simbologia do comando é:

```
net = init(net)
```

Inicializada a rede, pode-se realizar o treinamento para obter os valores dos pesos que determinam o menor erro da rede. O comando `train` realiza esse treinamento. Os argumentos necessários para a execução desse comando são: a variável que denota a rede (`net` no nosso caso); os dados de entrada (vetor `p`); e os valores de saída conhecidos (vetor `t`). O comando produz 2 argumentos de saída, que são: a rede treinada com os pesos e *bias* ajustados (novamente utilizado `net`); e o vetor `tr` que contém informações de como se desenvolveu o processamento, com a obtenção de informações a cada

---

número de ciclos definida pela variável `show`, já comentada anteriormente. A simbologia do comando `train` é a seguinte.

```
[net, tr] = train(net, p, t)
```

### 5.1.6. Simulação

Após treinada a rede, normalmente, tem-se o interesse de simular alguns valores de entrada para se obter a saída dos mesmos, muitas vezes fornecendo uma previsão ótima dos dados. No ambiente MatLab essa simulação é realizada com o comando `sim`. Com esse comando pode-se simular facilmente quaisquer valores de entrada, obtendo-se os valores de saída correspondentes à rede treinada anteriormente.

```
a = sim(net, p)
```

onde,

`a` = valores de saída;  
`net` = rede treinada;  
`p` = valores de entrada.

Salienta-se ainda que através desse comando, pode-se simular não somente um conjunto de dados, pois o parâmetro `p` (valores de entrada) pode possuir mais de um padrão, resultando em um conjunto de saída para cada padrão apresentado.

### 5.1.7. Pré-processamento dos dados

Para obter melhores resultados durante o treinamento, realiza-se um pré-processamento dos dados de entrada e saída. No MatLab, estão pré-definidas as rotinas

---

mais utilizadas com essa finalidade. A seguir, apresenta-se a forma de utilização e de abordagem de duas das rotinas mais utilizadas, e que estão implementadas no MatLab.

#### 5.1.7.1. *Mínimo e Máximo*

Segundo esse tipo de pré-processamento, os dados devem ser alocados com os valores entre -1 e 1, ou seja, o valor máximo passará a ser 1 e o valor mínimo passará a ser -1. Para isso utiliza-se o comando `premnmx`, e sua nomenclatura é dada por:

$$[pn, minp, maxp, tn, mint, maxt] = premnmx(p, t)$$

onde,

`p` e `t` = são os dados a serem processados;

`pn` e `tn` = são os dados pré-processados;

`minp`, `mint` = são os valores mínimos de `p` e `t`, respectivamente;

`maxp`, `maxt` = são os valores máximos de `p` e `t`, respectivamente;

O armazenamento dos valores máximos e mínimos do conjunto de dados é importante, pois os mesmos serão utilizados para transformar futuros valores de entrada que se queira simular e retornar os valores de saída transformados que serão obtidos na rede.

Isto se deve ao fato de que após o treinamento os valores de saída também estarão normalizados. Sendo assim, é necessário retornar para a ordem de grandeza original dos valores. Ou seja, como os valores de saída também foram normalizados, qualquer simulação posterior, gerará saídas de dados normalizados. Por isso, esses dados deverão ser transformados novamente para a ordem de grandeza original. Para isso utiliza-se o comando `postmnmx`. Tal operação normalmente é realizada com os elementos resultantes da rede (valores de saída) quando a rede foi treinada com os valores pré-processados.

---

---

```
a = postmnmx(an, mint, maxt)
```

onde,

an = valores transformados de saída da rede;  
mint, maxt = valores máximo e mínimo do vetor de saída t (treinamento);  
a = valores na ordem de grandeza original.

Contudo, após o treinamento da rede, quando se desejar realizar alguma simulação, deve-se também realizar o processamento dos valores de entrada. Nesse caso, o comando `tramnmx` realiza o processamento dos dados, de acordo com o processamento realizado anteriormente.

```
pnewn = tramnmx(pnew, minp, maxp)
```

onde,

pnewn = valores transformados de entrada da rede;  
minp, maxp = valores máximo e mínimo do vetor de entrada p (treinamento);  
pnew = valores na ordem de grandeza original.

#### 5.1.7.2. Média zero e Variância Unitária

Nesse tipo de pré-processamento, os dados devem ser alocados de forma que a média dos mesmos seja zero, e a variância dos dados seja igual a 1. A seguir observa-se a nomenclatura utilizada no MatLab para tratar os dados sob esses preceitos. O comando utilizado é o `prestd`.

```
[pn, meanp, stdp, tn, meant, stdt] = prestd(p, t)
```

onde,

p e t = são os dados a serem processados;  
pn e tn = são os dados pré-processados;  
meanp, meant = são os valores médios de p e t, respectivamente;  
stdp, stdt = são os desvios-padrão de p e t, respectivamente;

---



Após o treinamento da rede com os dados pré-processados, deve-se retornar os dados de saída para a ordem de grandeza anterior. Para isso utiliza-se o comando `poststd`. Tal operação normalmente é realizada com os elementos resultantes da rede (valores de saída) quando a rede foi treinada com os valores pré-processados. Por isso é importante armazenar os dados relativos ao conjunto que é submetido a um pré-processamento dos dados:

$$a = \text{poststd}(an, \text{meant}, \text{stdt})$$

onde,

$an$  = valores transformados de saída da rede;

$\text{mint}, \text{maxt}$  = valores máximo e mínimo do vetor de saída  $t$  (treinamento);

$a$  = valores na ordem de grandeza original.

Quando se desejar realizar alguma simulação, deve-se também realizar o pré-processamento dos valores de entrada, para se adequarem ao conjunto de dados que foi utilizado para o treinamento. Para isso, o comando `trastd` normaliza os dados seguindo os mesmos critérios utilizados para normalizar os dados que foram utilizados no treinamento.

$$pnewn = \text{trastd}(pnew, \text{minp}, \text{maxp})$$

onde,

$pnewn$  = valores transformados de entrada da rede;

$\text{minp}, \text{maxp}$  = valores máximo e mínimo do vetor de entrada  $p$  (treinamento);

$pnew$  = valores na ordem de grandeza original.

### 5.1.8. Pós-processamento dos dados

Após o treinamento e a simulação, deve-se realizar a verificação da qualidade dos dados. O comando `postreg` possui a capacidade de comparar dois conjuntos de dados,

---

gerando correlações entre os mesmos. O comando gera 3 valores:  $m$ , que corresponde ao coeficiente angular da reta de comparação entre os valores;  $b$ , que corresponde ao valor em que a reta obtida cruza o eixo  $y$ ; e  $r$  que corresponde ao coeficiente de correlação entre os dados padrões e os calculados. É intuitivo que quanto mais próximos forem os valores calculados dos dados reais utilizados para treinamento e teste, mais próximos os valores de  $m$ ,  $b$ , e  $r$ , estarão de 1, 0, e 1 respectivamente.

$$[m, b, r] = \text{postreg}(a, t)$$

## **5.2. Trecho a ser utilizado**

Em Redes Neurais Artificiais um dos itens que mais influenciam na obtenção de melhores resultados é a quantidade de dados disponíveis. Quanto maior a quantidade de dados, mais situações serão “absorvidas” pela estrutura da rede aumentando assim a capacidade de generalização da rede.

Em vista disso, para definição do trecho a ser utilizado, foram considerados 2 itens principais. Primeiramente optou-se por trechos com construção de túnel duplo, ou seja, onde foi construída somente uma seção de túnel para abrigar a linha nos dois sentidos. Em segunda instância optou-se pelo maior trecho que, possuindo essas características, dispusesse de grande quantidade de informações de projeto e de medições realizadas. Sendo as seções instrumentadas igualmente espaçadas, uma maior quantidade de dados implicava em uma maior extensão do trecho.

Seguindo essa premissa, tentou-se primeiramente a utilização de dados da Extensão Norte da Linha 1. Nesse trecho a disponibilidade dos dados de projeto era maior, sendo possível também um melhor contato com o projetista. A maior extensão de

---

que se dispunha de dados era de 400 m, equivalendo a 20 seções de dados. Esse trecho se mostrou de grande importância para aquisição de conhecimento e elucidação do melhor procedimento a ser utilizado. Contudo, um dos ensinamentos obtidos foi de que a quantidade de dados ainda se mostrava insuficiente para uma análise adequada.

Assim sendo, observou-se a necessidade de encontrar um trecho com uma maior quantidade de dados. A alternativa mais interessante foi obtida na extensão Oeste da Linha 2 no trecho compreendido entre as estações Sumaré e Vila Madalena, com cerca de 2 km de extensão, compreendendo cerca de 80 seções instrumentadas representando assim uma quantidade satisfatória de dados a serem utilizados.

Em ambos os trechos as escavações foram executadas utilizando o método NATM (*New Austrian Tunneling Method*). O perfil geológico predominante da região da Linha 2 é composto por intercalações de camadas de argila e areia. Essas intercalações proporcionam a ocorrência de vários níveis d'água, devido à baixa permeabilidade das argilas. Nas seções de escavação a resistência  $N_{SPT}$  apresenta um valor médio de 25 golpes, mas com grande variação de valores entre 20 e 40.

### **5.3. Obtenção dos dados**

Os dados foram obtidos de duas formas. Os relativos ao recalque, e algumas características construtivas puderam ser obtidos do programa de armazenamento consulta de dados utilizado pela Companhia Metropolitana de São Paulo (SACI). As características geológicas, geotécnicas e informações construtivas foram obtidas junto aos projetos utilizados durante a obra, assim como dos projetos *as built*.

---

Durante a execução da obra, a Companhia do Metropolitano de São Paulo utilizou um *software* denominado Sistema de Acompanhamento e Controle Interativo de Instrumentação (SACI), que realiza o registro e atualização das informações obtidas pelas medições e permite a geração de gráficos e relatórios (Domingues *et al.*, 1988).

Tal *software* foi desenvolvido em linguagem de programação Pascal, em computadores com processadores que não existem mais no mercado. Foi necessária a adaptação do programa para as tecnologias atuais com o ajuste das suas rotinas para se enquadrarem no tempo de processamento dos atuais equipamentos. Sendo assim, foi possível a extração dos dados do programa. O programa de aquisição de dados realizou o registro dos recalques lidos pela instrumentação (tassômetro e placas superficiais).

Para utilização em RNA, buscou-se uma forma de representar os níveis de recalques para todas seções, seguindo um mesmo padrão. Nesse sentido a utilização do conceito de bacia de recalque auxilia nessa padronização. Bacia de Recalque corresponde à depressão em superfície formada após a passagem da escavação (túnel). Para cada bacia de recalque há um volume de recalque correspondente.

Dentre as metodologias existentes para a definição da bacia de recalque, a mais utilizada foi proposta por Peck (1969) e utiliza a curva de distribuição de Gauss invertida para definir a superfície. Segundo o método proposto, os parâmetros importantes para caracterização da superfície de recalque são o recalque máximo na seção ( $\rho_{máx}$ ) e a largura da bacia de recalque ( $i$ ) que corresponde à distância entre o eixo de simetria da curva e o ponto de inflexão da mesma.

Celestino e Ruiz (1998) propuseram o uso de curvas tipo *yield-density*, definidas por três parâmetros, portanto mais flexíveis do que as gaussianas. O ajuste de curvas *yield-density* a dados reais de recalque tem-se mostrado bem melhor do que o de gaussianas.

---

Entretanto, nos trechos utilizados para o treinamento das redes neurais, não havia dados suficientes para o uso desse modelo.

De posse dos valores de recalque obtidos pela instrumentação (marcos superficiais e tassômetros) realizada em cada seção e utilizando a formulação proposta por Peck (1969), pôde-se obter para cada seção os valores de recalque máximo e largura de bacia que melhor se ajustariam aos dados obtidos em campo.

Além dos valores de recalque, os registros do programa também continham os valores dos avanços. Sendo assim, informações sobre velocidade de avanço relacionadas a cada seção do túnel, também foram obtidas através do programa.

As outras informações relevantes foram obtidas através dos desenhos de Instrumentação, Geologia e Métodos Construtivos. Nos projetos de instrumentação pôde-se observar as locações das seções e do posicionamento de cada instrumento da seção. Para as seções foram observados os valores das progressivas, e para os instrumentos as informações mais importantes foram de distância do eixo e profundidade de instalação.

Nos desenhos de geologia foram obtidas informações como:  $N_{SPT}$ ; tipo de material escavado (quantidade de areia ou argila presente na seção); profundidade do nível d'água; cobertura (profundidade da escavação).

Todas essas informações foram obtidas para cada uma das seções instrumentadas que se ia analisar. Nos projetos de métodos construtivos obteve-se: diâmetro da escavação; espessura do revestimento (concreto projetado); tipo e intensidade do drenagens realizadas.

---

#### **5.4. Tratamento dos dados**

Como já mostrado, para utilização em Redes Neurais Artificiais tipo *Perceptron* de Múltiplas Camadas as informações devem ser agrupadas em dois conjuntos: entrada e saída; sabe-se que os dados de entrada influenciam nos valores de saída. No caso estudado as informações de entrada correspondem às características da obra (geotécnicas, geométricas e de construção), enquanto que as de saída correspondem àquelas que definem o nível de recalque ocorrido após a passagem.

Para obtenção de melhores resultados nas análises utiliza-se o artifício da normalização dos dados (entrada e saída). A normalização evita que os pesos assumam valores muito altos durante o processo de ajuste, o que causaria um aumento substancial na soma ponderada implicando em valores de saída de neurônio sempre próximos de 1. Assim sendo, a sensibilidade da rede para as influências de cada parâmetro ficaria inviabilizada, além de provocar uma estabilização equivocada dos valores daquele neurônio. Na análise realizada optou-se pela normalização dos dados utilizando o método dos máximos e mínimos, já mostrado anteriormente, com definição do valor máximo de 1 e valor mínimo de -1. Com essa faixa de valores, evita-se a ocorrência de *overfitting* dos pesos durante o processo de ajuste (Haykin, 1994).

#### **5.5. Cenários de entrada e saída da RNA**

De posse dos dados ficou então definido que os valores de recalque máximo ( $\rho_{máx}$ ) e largura de bacia de recalque ( $i$ ) seriam utilizados para a camada de saída, e os outros

---

dados obtidos seriam utilizados como parâmetros de entrada, já que exercem influência na magnitude dos valores da superfície da bacia de recalque.

Com relação aos parâmetros de entrada, os mesmos foram divididos em três tipos de informações: geotécnicas, geométricas e construtivas. Os mesmos foram retirados essencialmente dos desenhos de projeto e *as built*. As informações mais relevantes para utilização em análises de escavações subterrâneas, mais gerais que as das obras do Metrô de São Paulo, são mostradas na Tabela 5.2, com a descrição, o tipo e a unidade rotineiramente utilizada para cada parâmetro.

**Tabela 5.2** – Características relevantes para análises via RNA para escavações subterrâneas.

Tipo	Descrição	Unidade
Geométrico	Cobertura do túnel <sup>(1)</sup> - <i>C</i>	m
	Diâmetro Equivalente da Escavação ou Área Escavada – <i>D</i> ou <i>A</i>	m
	Concreto Projetado de 1ª fase (espessura) – <i>CP1</i>	cm
	Concreto Projetado de 2ª fase (espessura) – <i>CP2</i>	cm
Geotécnicas	Progressiva – <i>P</i>	m
	Porcentagem de Argila – % <i>Arg</i>	0 a 1
	Porcentagem de Areia – % <i>Are</i>	0 a 1
	Resistência pelo ensaio SPT médio na seção escavada – <i>N<sub>SPT</sub></i>	–
Escavação	Nível d'água <sup>(2)</sup> - <i>NA</i>	m
	Ancoragem	tirantes/m <sup>2</sup>
	Instalação da Enfilagem	0 ou 1
	Drenagem (Rebaixamento do <i>NA</i> )	0 ou 1
	Seção Plena	0 ou 1
	Arco Invertido	0 ou 1
	Distância entre frente de escavação e arco invertido - <i>AI</i>	m
	Galeria Lateral	0 ou 1
	Velocidade de Avanço (seção anterior)	m/dia
	Velocidade de Avanço (seção)	m/dia
Velocidade de Avanço (seção posterior)	m/dia	

(1) É a profundidade até a geratriz superior do túnel;

(2) Para o nível d'água considera-se a altura de água a partir da geratriz inferior da seção escavada.

É importante salientar que as unidades mostradas na Tabela 5.2 são as utilizadas durante a uniformização e aquisição dos dados. Para o treinamento de desenvolvimento da rede, esses dados são transformados e normalizados entre os valores de 0 e 1. Tal procedimento, como já fora explanado evita a ocorrência de erros durante o treinamento.

Para os itens relacionados ao tipo de suporte (ancoragem, concreto projetado, cambotas metálicas) o valor 0 indica que o item não foi utilizado durante a escavação. Já valores diferentes de 0 para a ancoragem e para o concreto projetado representam o nível de suporte utilizado. Para os itens de escavação (suporte) o valor zero significa que não foi utilizado.

Julga-se importante a consideração da influência da velocidade escavação não somente na seção instrumentada, mas também no trecho anterior e posterior à mesma. Acredita-se que essas grandezas podem exercer forte influência nos níveis de recalque ocorridos.

## **5.6. Topologias e Parâmetros**

Na utilização das Redes Neurais Artificiais, a configuração apropriada da topologia e dos parâmetros que envolvem a etapa de treinamento, proporciona a obtenção de resultados mais efetivos. Por isso a verificação da qualidade de diferentes configurações se faz necessária para a escolha do melhor resultado.

Muitos estudos já buscaram métodos no intuito de determinar a topologia que conduzisse aos melhores resultados para cada problema estudado. No entanto, durante a realização dos testes, tem-se observado que os desenvolvimentos teóricos nem sempre apresentam os melhores resultados. Por isso a melhor opção ainda tem sido baseada na realização de testes e a verificação do erro.

Nesse estudo algumas premissas foram utilizadas para a definição das possíveis topologias. Segundo Haykin (1994) e Braga *et al.* (2000) estudos realizados demonstram que uma rede de 2 camadas internas já é suficiente para obter resultados satisfatórios,

---



---

mesmo em problemas de maior complexidade. Variou-se o número de neurônios em cada camada, de acordo com o problema analisado, buscando definir pelo menos 4 combinações de quantidade de neurônios diferentes para cada camada.

A função de transferência adotada foi a Tangente Hiperbólica, visto que os dados de entrada e saída foram tratados entre os valores de -1 a 1. Os pesos das conexões para o início do treinamento são definidos com valores aleatórios entre -1 e 1. Esses valores iniciais podem influenciar na convergência durante a fase de treinamento. Normalmente, essa influência não é significativa, mas a adoção de valores baixos, busca evitar a ocorrência de saturação do valor do peso durante a convergência.

---



## 6. ANÁLISES

### *6.1. Extensão Norte da Linha 1 (Jd. São Paulo – Poço Pedro Cacunda)*

Durante os anos de 1988 a 1998, foram executados alguns túneis da Linha 1 do Metrô de São Paulo. A Estação Jd. São Paulo é a estação da extensão Norte. O trecho é localizado sob a Formação Resende, composta por argilas rijas e lentes de areia com teor adequado de argila para atingir boa compacidade. A obra foi bem instrumentada visando ao controle dos recalques e de prováveis interferências em construções pré-existentes (redes de água e esgoto, fundações dos prédios, e outras). Durante a escavação foi realizada somente uma frente de trabalho, com a mesma equipe trabalhando na execução todo o tempo.

Em Redes Neurais Artificiais um dos itens que mais influenciam a obtenção de melhores resultados é a quantidade de dados disponíveis. Quanto maior a quantidade de dados, mais situações serão “absorvidas” pela estrutura da rede aumentando assim sua capacidade de generalização.

Considerando critérios de escolha descritos no Capítulo 6, utilizou-se um trecho com a maior extensão disponível de 250 m entre as estações Jardim São Paulo e o Poço Pedro Cacunda, equivalendo a aproximadamente 12 seções instrumentadas.

---

### 6.1.1. Obtenção e preparação dos dados

Através do SACI pôde-se obter registro dos recalques lidos da instrumentação (tassômetros e placas superficiais). A partir desses valores determinou-se a bacia de recalque compatível com os dados de acordo com os estudos de PECK (1969) e que se baseia na curva de distribuição de Gauss para determinação da bacia de recalque. Considera-se que 2 fatores permitem a caracterização da bacia de recalque: recalque máximo  $\rho_{m\acute{a}x}$ ; e largura da bacia de recalque  $i$ . A normalização dos dados foi realizada para evitar que os mesmos assumissem valores muito altos durante o processo de treinamento.

Os parâmetros de entrada (divididos em três tipos: geotécnicos, geométricos e construtivos) foram retirados essencialmente dos desenhos de projeto. Na Tabela 6.1, pode-se observar os parâmetros de entrada adotados na rede modelada. Apresenta-se também o símbolo, a descrição e a unidade utilizada para cada um deles. É importante salientar que as unidades mostradas foram utilizadas durante a uniformização e aquisição dos dados, sendo que, após o processo de normalização as mesmas perdem sentido.

**Tabela 6.1** – Características adotadas para o treinamento da Rede Neural.

Neurônio	Tipo	Descrição	Unid
1	Geométrico	Cobertura do túnel <sup>(1)</sup> – $C$	m
2	Geotécnicas	Porcentagem de Argila – $\%Arg$	0-100
3		Porcentagem de Areia – $\%Are$	0-100
4		Nível d'água <sup>(2)</sup> – $NA$	m
5		Resistência pelo ensaio SPT médio na escavação – $N_{SPT}$	–
6	Escavação	Velocidade de Avanço Ant. (média dos 5 m antes da seção) – $AA$	m/dia
7		Velocidade de Avanço (média dos 5 m no entorno da seção) – $A$	m/dia
8		Velocidade de Avanço Post. (média dos 5 m após a seção) – $AP$	m/dia
9		Distância entre a frente ao arco invertido – $D$	m

(1) É a profundidade até a geratriz superior do túnel;

(2) Para o nível d'água considera-se a altura de água a partir da geratriz inferior da seção escavada.

Alguns parâmetros como largura, altura e área da escavação e espessura do concreto projetado, foram descartados da análise, apesar de sua reconhecida importância

no comportamento de escavações de túneis, pois os valores desses itens se mantiveram constantes no trecho analisado. Sendo assim, os mesmos não exercem influência na ponderação dos pesos na RNA, e sua utilização pode inclusive trazer dificuldades no processo de convergência da rede.

A consideração das porcentagens de argila e de areia procura refletir a influência da granulometria durante o processo de escavação. Análise detalhada dessa influência para o caso de areias já foi apresentada por Rocha (1995).

Nos parâmetros referentes à velocidade de avanço, pode-se observar a utilização de valores não somente na região da seção instrumentada, mas também nas regiões anterior e posterior à seção. Entende-se que as velocidades de avanço anterior e posterior à seção, possuem influência significativa nos recalques ocorridos.

A resistência do ensaio SPT ( $N_{SPT}$ ) obtida através dos desenhos de seções geológicas foi definida como a média das resistências que ocorriam à frente de escavação. Para cada um dos perfis de sondagem foi calculada essa média. Nas situações onde a seção se localizava entre duas sondagens, adotou-se a média entre as sondagens, ponderada pela distância da seção a cada uma das sondagens.

Na Tabela 6.2 pode-se observar os cenários obtidos baseado nos dados de cada umas das 12 seções que ocorrem no trecho. Os símbolos adotados para essa tabela correspondem aos mostrados na Tabela 6.1.

**Tabela 6.2** – Dados de entrada e saída utilizados no treinamento

Seção	Entrada									Saída	
	C	%Arg	%Are	NA	$N_{SPT}$	AA	A	AP	D	i	$\rho_{m\acute{a}x}$
SA-01	10,7	75	25	8,20	18,40	0,000	0,620	0,425	2,000	6,93	28,2
SA-02	10,8	100	0	9,20	22,80	0,733	0,700	0,964	3,900	7,53	20,9
SA-03	11,4	100	0	10,70	27,30	0,808	1,723	1,867	4,300	11,75	13,9
SA-04	11,9	100	0	7,30	28,70	1,575	3,150	2,450	9,300	9,71	16,8
SA-05	13,2	100	0	9,00	29,60	2,650	1,733	2,312	27,000	7,67	24,5
SA-06	14,4	100	0	6,60	29,50	2,150	1,625	1,733	37,600	6,29	71,0

Seção	Entrada									Saída	
	C	%Arg	%Are	NA	N <sub>SPT</sub>	AA	A	AP	D	i	$\rho_{\text{máx}}$
SA-07	11,1	89	11	9,30	29,50	2,400	1,600	2,150	50,700	7,25	77,2
SA-08	11,4	44	56	11,40	29,50	1,800	2,800	2,400	50,300	8,43	52,8
SA-09	12,3	63	37	11,80	30,80	1,800	3,300	2,730	4,400	14,84	38,6
SA-10	13,4	80	20	12,70	30,00	2,800	2,029	2,800	5,800	7,52	48,5
SA-11	15,0	100	0	12,90	28,60	2,600	2,029	2,600	6,800	7,40	42,0
SA-12	18,4	100	0	12,90	28,10	2,600	2,139	0,000	4,900	9,07	34,6

Tanto os parâmetros de entrada quanto os de saída foram submetidos à normalização utilizando o método dos máximos e mínimos onde os valores foram transformados para estarem no intervalo de valores entre -1 e 1.

### 6.1.2. Topologias e Parâmetros

Definida a utilização de 2 camadas internas, a montagem dos possíveis cenários foi realizada com a variação da quantidade de neurônios em cada camada. Na primeira e na segunda camada o número máximo de neurônios variou entre 3, 6, 9 e 12. Limitou-se à utilização de 12 neurônios, pois o número de parâmetros de entrada é de 9, e segundo Haikyn (1994) a utilização de grande número de neurônios não significa um melhor ajuste, e muitas vezes pode inviabilizar a análise. Adotou-se também que o número de neurônios da 2ª camada é sempre inferior ou igual à quantidade colocada na 1ª camada.


Como descrito no Capítulo 4, o Método do Gradiente Decrescente com Momentum, necessita da definição de 2 parâmetros: taxa de aprendizado; e o *momentum*.. Para a taxa de aprendizado definiu-se 2 valores para taxa: 0,5 e 0,7. Entretanto, para o termo *momentum* optou-se por adotar o valor de 0,9 e não variá-lo, visto que como descrito por Haikyn (1994), se trata de um elemento para dar mais estabilidade à rede. Sendo assim, para cada arquitetura definida para a rede foram realizadas duas etapas de treinamento variando o valor da taxa de aprendizado.

Nesse sentido, definiram-se vários modelos para o treinamento dos mesmos, visando a encontrar qual atingiria o melhor ajuste aos dados. Na Tabela 6.3 se pode observar os cenários obtidos. Ressalta-se que todos os modelos possuem 9 parâmetros de entrada e 2 neurônios na camada de saída.

**Tabela 6.3** – Configurações e topologias utilizadas durante o treinamento da Rede Neural.

Modelo RNA	Neurônios nas Camadas Intermediárias		Taxa de Aprendizado	Termo Momentum	
	1ª	2ª			
01	6	3	0,7	0,9	
02			0,5	0,9	
03		6	0,7	0,9	
04			0,5	0,9	
05		9	3	0,7	0,9
06				0,5	0,9
07	6		0,7	0,9	
08			0,5	0,9	
09	9		0,7	0,9	
10			0,5	0,9	
11	12	3	0,7	0,9	
12			0,5	0,9	
13		6	0,7	0,9	
14			0,5	0,9	
15		9	0,7	0,9	
16			0,5	0,9	
17	12	0,7	0,9		
18		0,5	0,9		

Na Figura 6.1, observa-se o esquema da configuração adotada.



**Figura 6.1** – Esquema ilustrando a arquitetura da RNA utilizada na Análise.

Ainda como parâmetro da rede, a função de transferência adotada foi a tangente hiperbólica. Adotaram-se 2 critérios de parada para o treinamento. O primeiro é a consideração de um valor aceitável de 0,001 para a soma dos erros quadráticos de cada um dos padrões utilizados para o treinamento. O segundo corresponde ao número de ciclos, limitado a 10000.

No início do treinamento, os pesos são definidos com valores aleatórios entre -1 e 1, para se evitar a ocorrência de *overfitting* do valor do peso no início do processo de treinamento e convergência.

Para verificar a eficiência de cada uma das topologias, optou-se pela divisão dos dados em 6 conjuntos, de forma que para cada uma das topologias seriam realizadas 6 simulações, utilizando em cada uma delas um dos conjuntos para a fase de teste, e o restante para o treinamento. Os erros foram calculados para todas as simulações e a seguir determinou-se a média dos erros para cada um dos modelos utilizados. Esse método é denominado de validação cruzada e permite verificar a eficiência da topologia para um conjunto de dados.

### 6.1.3. Resultados

De acordo com as topologias e os parâmetros definidos, realizou-se o treinamento para cada um dos cenários, utilizando o software MatLab®. Em cada modelo foi obtido um ajuste de pesos mais adequado. Em seguida, fez-se a simulação dos valores de entrada utilizados no treinamento e dos separados para teste também, obtendo-se os valores de saída correspondentes da rede. Esses valores obtidos foram comparados com os valores medidos em campo. Para os dados de treinamento foi possível obter as diferenças

---



percentuais e o valor do coeficiente de correlação  $R^2$ . Para os dados de teste (que só continham 2 padrões) não foi possível a obtenção de um coeficiente de correlação, sendo portanto, analisada somente a diferença percentual.

Os erros foram determinados separadamente para cada um dos parâmetros de saída (recalque máximo e largura da bacia de recalque). Isso permite verificar a influência e a dificuldade da rede em prever cada um dos itens. Podem-se observar os erros obtidos após as simulações na Tabela 6.4.

**Tabela 6.4** – Configurações e topologias utilizadas durante o treinamento da Rede Neural.


Modelo RNA	Recalque Máximo ( $\rho_{máx}$ )			Largura da bacia de recalque ( $i$ )		
	Treinamento		Teste	Treinamento		Teste
	$R^2$	Erro %	Erro %	$R^2$	Erro %	Erro %
01	0,9095	4,4642	51,5612	0,9791	3,0943	44,9195
02	0,9227	3,9151	37,1711	0,9774	4,0604	81,0175
03	0,9934	1,1063	21,8379	0,9911	2,7557	30,4556
04	0,9906	1,4862	32,5776	0,9989	1,7320	42,7734
05	0,9863	1,8290	20,1120	0,9243	8,2956	61,4343
06	0,9739	1,9744	20,3214	0,9770	3,5605	66,4997
07	0,9930	1,2169	20,9964	0,8325	8,8870	57,2661
08	0,9957	1,1556	16,0283	0,9647	4,0578	55,6645
09	0,8067	5,3340	31,4035	0,8498	9,8605	49,9341
10	0,8106	5,2456	26,2771	0,9271	10,0331	51,9359
11	0,9544	3,1246	38,8377	0,9415	4,9537	53,6676
12	0,9917	1,4240	39,0689	0,9792	2,8254	42,2004
13	0,8446	4,4688	33,0495	0,9985	1,7264	51,2501
14	0,9941	1,1917	32,0528	0,9978	2,2507	53,9158
15	0,9390	5,1919	23,4062	0,8442	10,6948	45,1035
16	0,9788	1,5052	15,1179	0,9982	1,9044	55,3268
17	0,8307	4,1916	36,4320	0,9990	1,0665	46,3674
18	0,8310	4,0672	37,0364	0,9986	1,4886	50,1135

Apesar da pequena quantidade de dados, os resultados podem ser considerados satisfatórios. Para definição do modelo mais adequado optou-se por considerar o menor erro obtido com os dados de teste, visando àquele cenário que melhor generalizou o problema. Assim sendo, observa-se que a configuração da rede que forneceu os melhores resultados foi o Modelo 3, que é dotado de 6 neurônios nas duas camadas intermediárias e


a taxa de aprendizado de 0,7. A escolha do modelo ótimo baseou-se nos erros da fase de teste para garantir que o mesmo tivesse a melhor representação do problema.

A diferença entre os erros resultantes com os dados de treinamento e os obtidos com os dados de teste evidencia que a pequena quantidade de dados dificultou a generalização do problema durante o ajuste, e que a rede ‘decorou’ os dados de treinamento, tendo, por isso, dificuldades em realizar as previsões com a devida eficácia. Para superar esse problema se faz necessária a utilização de uma maior quantidade de dados.

As Figuras 6.2 e 6.3 mostram gráficos comparativos dos valores previstos e dos valores medidos em cada seção para recalque máximo e largura da bacia de recalque, respectivamente. Os dados foram obtidos utilizando o Modelo 3 que demonstrou o melhor ajuste.



**Figura 6.2** – Comparação entre medidos e previstos pra Recalque Máximo ( $\rho_{m\acute{a}x}$ ).



**Figura 6.3** – Comparação entre medidos e previstos pra Largura da Bacia. (*i*)


Observa-se que apesar da ocorrência de alguns erros pontuais significativos (seção 6 para recalque máximo e seções 1 e 3 para bacia de recalque) a RNA ajustada demonstrou boa capacidade de previsão. Além disso, percebe-se que os valores previstos têm boa aderência aos valores medidos, evidenciando que o fenômeno foi bem representado pela rede, e as tendências foram mantidas.

#### 6.1.4. Análise de Sensibilidade

Foram realizadas análises de sensibilidade relacionando os parâmetros de entrada da rede e o recalque máximo para observar a relação entre os mesmos. Fixaram-se os parâmetros de entrada no valor correspondente à média do conjunto de dados. Variou-se o parâmetro a ser analisado entre os valores mínimo e máximo (desse parâmetro)


presentes no conjunto de dados. Adotaram-se 8 intervalos (que correspondem a 9 pontos) igualmente espaçados para previsão de recalques.

Na Figura 6.4 observa-se a influência da velocidade de avanço no recalque máximo de acordo com a modelagem realizada. Sabe-se de experiência que o aumento da velocidade de avanço da escavação propicia a ocorrência de menores recalques em superfície em escavações subterrâneas. A curva mostrada evidencia a relação entre o aumento da velocidade e a diminuição dos recalques máximos, estando de acordo com a experiência usual.



**Figura 6.4** – Influência da velocidade de avanço no recalque máximo.

Outro parâmetro cuja influência se conhece é a cobertura. O aumento da cobertura causa uma diminuição nos recalques máximos em materiais não suscetíveis à variação de volume, com o que é o caso em questão. A curva fornecida pelo modelo e mostrada na Figura 6.5 evidencia que o modelo se ajustou de forma a caracterizar essa influência, ou seja, com o aumento da cobertura há uma diminuição dos recalques.



**Figura 6.5** – Influência da cobertura no recalque máximo.

Pode-se observar que quando os valores de cobertura são baixos o comportamento esperado (queda dos recalques com o aumento da cobertura) não ocorre. Considera-se que a pequena quantidade de dados nessa faixa de valores de cobertura utilizada no treinamento da rede dificultou as previsões para esse trecho.

### 6.1.5. Conclusões e Comentários

A rede foi modelada utilizando os dados obtidos em 12 seções instrumentadas no trecho de túnel único entre as estações Jardim São Paulo e o Poço Pedro Cacunda, da Linha 1 do Metrô de São Paulo.

Apesar da pequena quantidade de dados, a modelagem via RNA se mostrou satisfatória e forneceu resultados adequados, demonstrando a aplicabilidade das Redes Neurais Artificiais para a análise de instrumentação de túneis, e ratificando a capacidade

da arquitetura MLP (Multi Layer Perceptron) de se ajustar ao fenômeno de recalques em túneis.

Observa-se que o erro médio de previsão (dados de testes) foi de 29,6% e 52,2% para recalque máximo e largura da bacia de recalque, respectivamente. A melhor modelagem, considerando a soma dos erros obtidos nos dois parâmetros, foi obtida pelo modelo 3. O mesmo é constituído por duas camadas intermediárias com 6 neurônios em cada uma e taxa de aprendizado de 0,7. Considerando-se também os dados de treinamento, o erro médio obtido nesse modelo foi de 21,8 % e 30,4 % para recalque máximo e largura da bacia de recalque, respectivamente. Além disso, ao observar o gráfico de dados medidos e previstos com o modelo 3 para cada uma das seções instrumentadas observa-se que a RNA fornece boa correlação com o fenômeno e suas características, pois os resultados previstos acompanham a tendência dos dados medidos. Há alguns pontos discrepantes, mas em sua maioria os valores são próximos.

Nas análises de sensibilidade os resultados podem ser considerados satisfatórios. Observou-se que as influências de velocidade de avanço da escavação e cobertura nos recalques máximos foram condizentes com o esperado e mostrado na literatura.

## **6.2. *Extensão Oeste da Linha 2 (Sumaré-Vila Madalena)***


A análise realizada no trecho da Extensão Norte da Linha 1 (Jd. São Paulo – Poço Pedro Cacunda) mostrou que uma maior quantidade de dados se fazia necessária para obtenção de correlações mais coerentes. Sendo assim, foi necessária a busca de um outro trecho para o estudo. O novo trecho também deveria contemplar um túnel duplo, e atingir maior extensão permitindo uma maior quantidade de padrões para serem utilizados

---

na RNA. Sendo assim, optou-se pela utilização do trecho entre as estações de Sumaré e Vila Madalena, na Extensão Oeste da Linha 2 metrô de São Paulo.

As obras dos túneis da Linha 2 do Metrô de São Paulo ocorreram nos anos de 1992 a 1997. O trecho foi executado pelo método NATM (New Austrian Tunneling Method), com seções transversais médias de 75m<sup>2</sup>. A Geologia do trecho é constituída pelos sedimentos terciários da Formação São Paulo, consistindo de argilas siltosas porosas vermelhas, argilas silto-arenosas variegadas e areias argilosas variegadas, e sedimentos da Formação Resende consistindo de argilas siltosas cinza e amarelas e areias silto-argilosas amarelas e alaranjadas. As escavações foram executadas na região de transição entre as duas camadas. (Rocha *et al.*, 1999) Na Figura 6.6, pode-se observar a seção geológica simplificada do trecho.

### Seção Geológica - Trecho Sumaré - Vila Madalena




**Figura 6.6** – Seção geológica característica da região. (Rocha *et al.*, 1999)

Uma análise interessante de recalques e de outras grandezas resultantes da instrumentação de túneis escavados na Cidade de São Paulo, em maciços das Formações Resende e São Paulo foi apresentado por Negro *et al.* (1992). Os dados foram

convenientemente apresentados de forma adimensional em função de parâmetros geotécnicos e construtivos. Tal análise é orientativa das grandezas importantes a serem consideradas em uma rede neural. Durante a construção, o trecho escolhido foi dividido em 4 setores, como se pode observar na Figura 6.7. Assim, as informações também foram organizadas seguindo essa divisão. Os trechos utilizados na análise são:

- Túnel Estacionamento: Poço Juatuba – Poço Vila Madalena
- Túnel Luminárias: Túnel de Acesso Leste – Poço Luminárias
- Túnel Jaciporá: Poço Jaciporã – Poço Gaú
- Túnel Gaú: Poço Gaú – Estação Sumaré



**Figura 6.7** – Ilustração da divisão por setores realizada durante a construção

### 6.2.1. Obtenção e preparação dos Dados

Como já comentado, os dados foram obtidos para os 4 trechos definidos durante a construção e foram organizados separadamente. A partir do programa de aquisição de dados SACI juntamente com os projetos de instrumentação pode-se obter informações de recalque e avanço da escavação. A instrumentação realizada nesse trecho não era densa e por isso, em muitas seções ficou inviabilizada a determinação de parâmetros como Largura de Bacia de Recalque e Recalque Máximo pelo método de Peck (1969). Nesses casos, considerou-se que o recalque medido pelo instrumento instalado no eixo longitudinal da seção correspondia ao recalque máximo observado na seção



instrumentada. Tal limitação fez com que a Rede fosse modelada utilizando como parâmetro de saída somente o valor do recalque máximo, visto que não havia um número de seções consideráveis com instrumentação a contento para determinação das larguras de bacias de recalque.

Outro fator relevante foi a ausência de registro de algumas seções. Observou-se que nos desenhos de projeto havia a representação das seções, contudo no programa de aquisição de dados não havia registro de informações de recalque e avanço para a mesma. Assim sendo, essas seções foram desconsideradas da análise, já que as informações necessárias para os dados de saída não puderam ser obtidas. Ainda utilizando o programa de aquisição de dados, obtiveram-se informações de velocidade de avanço da obra. Adotaram-se as velocidades de avanço em três regiões, uma delas correspondendo justamente ao avanço do dia em que a escavação passou pela seção instrumentada.

Para as velocidades antes e após a seção instrumentada, optou-se pela determinação da média dos valores para as faixas de 5 e 10 metros anteriores e posteriores. Sendo assim, além da velocidade de avanço na seção instrumentada, foram determinados os valores de velocidade de avanço para os trechos anteriores (5 e 10 metros antes da seção) e para o posterior (5 e 10 metros após a seção).

A partir dos desenhos de projeto foram obtidas as informações restantes e necessárias para a análise, principalmente no que concerne os dados de entrada da rede que influenciariam nos valores de recalque. Nos desenhos de geologia, obtiveram-se os valores de: resistência  $N_{SPT}$ ; nível d'água; porcentagem de argila e areia na frente de escavação; cobertura (profundidade).

Dos projetos de método construtivo pode-se observar os tipos de tratamento realizados para cada setor. Nesses parâmetros também foram utilizados o conhecimento

---

dos engenheiros e geólogos que participaram da realização da obra, e que puderam dar ótimo testemunho de como ocorreu o tratamento nas regiões onde as informações eram escassas ou de difícil entendimento. Dentre os parâmetros Geométricos foram utilizadas: a área escavada da seção; a cobertura do túnel; e a progressiva.

Na Tabela 6.5 observa-se a relação dos parâmetros considerados na análise com a descrição dos mesmos a simbologia utilizada e as unidades de obtenção dos valores.

**Tabela 6.5** – Características adotadas para o treinamento da Rede Neural.

Tipo	Descrição	Unidade
Geométrico	Cobertura do túnel <sup>(1)</sup> – <i>C</i>	m
	Área da Seção – <i>A</i>	m <sup>2</sup>
	Progressiva – <i>P</i>	m
Geotécnicas	Porcentagem de Argila – % <i>Arg</i>	0 a 100
	Porcentagem de Areia – % <i>Are</i>	0 a 100
	Nível d'água <sup>(2)</sup> – <i>NA</i>	m
	Resistência pelo ensaio SPT médio na escavação – <i>N<sub>SPT</sub></i>	–
Escavação	Concreto Projetado de 1ª Fase – <i>CP</i>	m
	Avanço Ant. (média dos 10 m antes da seção) – <i>AA10</i>	m/dia
	Avanço Ant. (média dos 5 m antes da seção) – <i>AA5</i>	m/dia
	Avanço na seção – <i>A</i>	m/dia
	Avanço Post. (média dos 5 m após a seção) – <i>AP5</i>	m/dia
	Avanço Post. (média dos 10 m após a seção) – <i>AP10</i>	m/dia
	Distância entre a frente ao arco invertido – <i>AI</i>	m
	Ocorrência de Enfilagem	0 ou 1
	Ocorrência de Túnel Piloto	0 ou 1

(3) É a profundidade até a geratriz superior do túnel;

(4) Para o nível d'água considera-se a altura de água a partir da geratriz inferior da seção escavada.

Na Tabela 6.6 observa-se a relação dos dados obtidos para cada um dos padrões (seções instrumentadas) divididos por túnel analisado, e que foram utilizados no treinamento. Nessa tabela os valores são apresentados de acordo com as unidades mostradas na Tabela 6.5 e seguindo a mesma simbologia mostrada. Cabe ressaltar que os dados aqui mostrados, foram normalizados e aleatorizados para a aplicação nas análises, visto que esse procedimento permitiria melhores resultados.

**Tabela 6.6** – Dados utilizados nas análises para o trecho Sumaré – Vila Madalena.

Seções	Área <i>m</i> <sup>2</sup>	CP <i>m</i>	C <i>m</i>	P <i>m</i>	AI <i>m</i>	N <sub>SPT</sub> –	NA <i>m</i>	Arg %	Are %	AA10 <i>m/dia</i>	AA5 <i>m/dia</i>	A <i>m/dia</i>	AP5 <i>m/dia</i>	AP10 <i>m/dia</i>	ρ <i>mm</i>
<b>Túnel Estacionamento – 20 Seções</b>															
SE-01	74,80	0,27	23,2	10,9	8,0	32,5	10,8	78,7	21,3	0,58	1,00	1,60	0,28	0,38	17,4
SE-03	74,80	0,27	28,2	65,7	6,4	32,5	11,5	76,0	24,0	0,88	0,67	2,40	0,42	0,65	12,7
SE-04	74,80	0,27	29,2	85,7	6,4	41,2	13,1	77,1	22,9	0,68	0,67	0,80	1,00	0,96	7,5
SE-05	74,80	0,27	30,8	108,7	7,2	35,2	12,8	72,2	27,8	0,96	0,80	2,40	0,96	1,37	12,2
SE-06	74,80	0,27	32,1	127,5	6,4	33,7	12,4	72,1	27,9	1,20	1,07	3,20	3,20	1,76	9,6
SE-07	74,80	0,27	33,2	146,5	8,0	32,6	12,3	64,0	36,0	1,30	1,60	1,60	1,60	1,14	8,7
SE-08	74,80	0,27	34,2	171,5	5,6	32,2	12,4	47,2	52,8	1,67	2,30	2,93	2,30	1,78	6,6
SE-09	74,80	0,27	34,5	202,0	5,6	33,4	12,5	58,0	42,0	1,16	1,60	4,00	1,20	1,80	10,5
SE-09A	74,80	0,27	34,8	220,1	5,6	30,0	12,4	48,2	51,8	2,10	2,08	4,80	2,40	2,13	10,6
SE-10	74,80	0,27	35,0	236,0	6,4	29,4	12,1	47,1	52,9	1,92	1,87	2,40	2,13	2,40	13,1
SE-10A	74,80	0,27	35,4	253,7	7,2	29,7	11,5	37,1	62,9	2,24	2,40	3,20	1,60	1,73	11,8
SE-11	74,80	0,27	35,6	260,5	8,0	29,8	11,3	34,3	65,7	2,24	2,13	3,20	1,33	1,60	13,5
SE-12	74,80	0,27	36,2	282,0	7,2	30,7	11,2	37,7	62,3	1,50	1,20	2,40	1,60	1,37	11,5
SE-13	74,80	0,27	36,4	301,0	7,2	34,5	11,2	56,2	43,8	1,24	1,47	2,40	1,60	2,08	10,1
SE-14A	74,80	0,27	37,0	341,0	6,4	40,5	11,8	69,8	30,2	1,71	1,44	4,00	0,57	0,90	11,9
SE-15	74,80	0,27	37,0	361,0	6,4	38,1	11,6	47,9	52,1	1,10	1,03	2,40	1,40	1,20	11,4
SE-15A	74,80	0,27	37,1	379,5	6,4	36,3	11,0	15,3	84,7	1,24	1,33	1,60	0,96	0,88	7,7
SE-16	74,80	0,27	37,0	397,0	6,4	37,7	10,1	23,3	76,7	1,24	1,20	3,20	0,93	0,98	8,4
SE-17	74,80	0,27	36,7	420,0	5,6	39,7	9,7	52,8	47,2	1,60	1,12	2,40	0,60	0,80	7,1
SE-18	74,80	0,27	36,2	446,2	6,4	44,2	10,3	56,4	43,6	1,40	1,40	2,40	0,91	1,02	4,3
<b>Túnel Luminárias – 22 Seções</b>															
SL-02	79,60	0,27	9,6	18,8	4,8	15,7	9,1	19,5	80,5	2,80	2,40	1,60	1,03	1,11	68,4
SL-03	79,60	0,27	10,7	40,1	4,0	17,0	9,6	26,1	73,9	1,04	1,40	1,60	0,23	0,39	63,7
SL-04	79,60	0,27	11,4	60,8	4,8	19,1	10,0	36,1	63,9	0,91	0,89	3,20	0,64	1,26	26,6
SL-05	79,60	0,27	11,6	76,8	5,6	20,7	10,3	60,4	39,6	1,30	1,03	2,40	0,80	1,20	20,7
SL-06	79,60	0,27	11,7	92,6	5,6	23,1	10,5	59,0	41,0	1,50	1,80	1,20	1,20	1,07	24,9
SL-07	79,60	0,27	11,6	111,8	5,6	27,7	10,8	76,7	23,3	1,30	1,00	1,60	2,00	1,49	51,7
SL-08	79,60	0,27	11,6	126,9	5,6	30,4	10,6	85,4	14,6	0,95	0,60	0,80	1,12	1,37	55,7
SL-08A	79,60	0,27	11,6	135,5	6,4	24,9	10,1	73,7	26,3	1,33	1,87	1,60	0,60	0,86	40,6
SL-09	79,60	0,27	11,3	149,8	4,8	15,8	9,3	47,0	53,0	1,47	2,80	2,40	1,12	1,30	35,9
SL-09A	79,60	0,27	11,2	155,8	4,8	15,3	9,1	36,3	63,7	1,60	1,12	1,60	2,00	1,71	32,8
SL-09B	79,60	0,27	11,1	160,9	5,6	15,6	8,8	42,9	57,1	1,94	2,20	4,00	1,60	2,00	37,0
SL-09C	79,60	0,27	11,0	163,6	5,6	15,8	8,6	41,9	58,1	2,00	2,40	4,00	1,20	1,40	41,5
SL-10	79,60	0,27	11,0	166,6	5,6	15,9	8,5	42,9	57,1	1,60	1,60	0,80	2,80	1,73	52,4
SL-10A	79,60	0,27	10,9	170,3	4,8	16,2	8,3	45,4	54,6	2,00	1,60	3,20	1,60	0,73	51,3
SL-10B	79,60	0,27	11,0	173,1	4,8	16,3	8,2	39,6	60,4	1,69	1,76	3,20	1,87	0,94	53,3
SL-10C	79,60	0,27	11,0	179,1	4,8	16,7	8,0	39,7	60,3	0,93	0,60	1,60	2,30	1,93	51,7
SL-11	79,60	0,27	11,0	184,2	4,8	17,0	7,7	46,1	53,9	0,94	2,30	3,00	1,30	1,64	45,1
SL-12	79,60	0,27	10,7	198,2	5,6	19,0	8,0	58,4	41,6	1,98	3,00	2,30	1,57	1,19	26,1
SL-12A	79,60	0,27	10,4	209,8	4,8	21,2	8,6	61,0	39,0	1,29	1,07	3,20	1,33	1,00	10,8
SL-13	79,60	0,27	10,0	222,1	5,2	23,5	7,4	55,8	44,2	1,59	1,80	2,40	1,60	1,00	8,3
SL-14	79,60	0,27	9,7	241,5	5,6	22,8	6,4	50,0	50,0	1,71	1,87	0,80	1,28	1,40	17,0
SL-15	79,60	0,27	9,0	264,8	5,6	16,2	6,1	69,9	30,1	1,42	1,44	1,60	0,69	0,53	34,9

Seções	Área <i>m</i> <sup>2</sup>	CP <i>m</i>	C <i>m</i>	P <i>m</i>	AI <i>m</i>	N <sub>SPT</sub> –	NA <i>m</i>	Arg %	Are %	AA10 <i>m/dia</i>	AA5 <i>m/dia</i>	A <i>m/dia</i>	AP5 <i>m/dia</i>	AP10 <i>m/dia</i>	ρ <i>mm</i>
<b>Túnel Jaciporã – 21 Seções</b>															
S3-01	76,79	0,25	18,4	42,9	6,4	44,5	16,4	75,6	24,4	1,60	1,28	1,60	2,40	2,40	11,7
S3-02	76,79	0,25	17,3	66,2	8,8	47,8	17,8	78,2	21,8	1,71	1,44	0,80	2,40	2,40	11,1
S3-03	76,79	0,25	16,5	80,7	8,8	48,5	17,3	66,7	33,3	1,71	1,44	2,40	2,40	1,37	9,9
S3-05	76,79	0,25	16,9	127,4	9,0	24,2	16,6	79,5	20,5	2,13	1,60	1,07	3,20	3,20	12,8
S3-06	76,79	0,25	16,9	146,7	9,1	52,0	16,1	71,8	28,2	2,13	1,60	3,20	2,80	1,50	11,8
S3-07	76,79	0,25	16,8	169,7	8,7	45,1	14,9	59,0	41,0	3,20	3,20	3,20	1,87	2,40	11,8
S3-08	76,79	0,25	16,9	186,2	10,0	38,3	14,3	56,4	43,6	2,72	3,20	4,00	1,87	2,08	12,3
S3-09	76,79	0,25	17,3	191,1	8,5	24,5	14,4	55,1	44,9	2,40	2,40	1,60	2,40	1,37	12,0
S3-10	76,79	0,25	17,3	201,1	6,5	20,6	14,6	53,8	46,2	1,42	1,20	0,53	2,00	1,33	13,7
S3-11	76,79	0,25	17,1	206,2	9,2	29,5	14,8	50,0	50,0	1,40	1,12	2,40	0,00	0,01	13,6
S3-12	76,79	0,25	16,9	210,9	6,5	24,9	14,9	52,6	47,4	0,01	1,20	0,80	0,48	0,46	13,6
S3-13	76,79	0,25	16,7	216,2	9,6	20,1	15,0	43,6	56,4	0,69	0,48	0,20	0,44	0,47	13,1
S3-14	76,79	0,25	16,7	226,2	10,0	19,8	15,1	48,7	51,3	0,47	0,51	0,20	0,35	0,42	12,1
S3-15	76,79	0,25	16,5	246,2	10,8	18,8	15,3	53,8	46,2	1,16	1,12	0,80	0,80	0,96	13,1
S3-16	76,79	0,25	15,8	266,2	9,2	15,6	15,9	51,3	48,7	1,30	1,12	2,40	1,60	1,49	14,7
S3-17	76,79	0,25	14,6	286,2	10,0	16,4	16,0	48,7	51,3	1,28	1,03	1,60	1,20	1,26	23,4
S3-18	76,79	0,25	14,7	295,7	8,0	45,7	14,3	41,0	59,0	1,24	1,40	0,80	1,60	1,37	23,8
S3-19	76,79	0,25	14,2	304,2	8,8	43,6	11,2	41,0	59,0	1,30	0,96	0,85	0,69	0,67	17,7
S3-21	76,79	0,25	13,1	323,7	7,1	38,5	5,5	32,5	67,5	0,69	0,69	1,60	0,69	0,87	14,0
S3-22	76,79	0,25	13,2	329,4	7,8	36,0	4,1	27,5	72,5	0,56	0,80	1,60	0,57	0,85	25,1
S3-24	76,79	0,25	13,2	344,4	8,8	21,7	4,1	0,0	100,0	0,43	0,35	1,60	0,60	0,48	30,2
<b>Túnel Gaú – 18 Seções</b>															
S1-02	68,84	0,25	26,5	58,9	10,2	16,3	12,5	38,7	61,3	0,83	0,94	1,20	0,53	0,64	19,6
S1-03	68,84	0,25	25,7	71,2	8,1	15,9	12,6	54,7	45,3	0,80	0,83	2,40	0,60	0,70	19,7
S1-04	68,84	0,25	25,1	77,3	9,4	15,2	12,6	61,3	38,7	0,86	0,98	1,80	0,62	0,53	21,9
S1-06	68,84	0,25	24,7	90,0	10,2	10,9	12,3	72,0	28,0	0,43	0,40	1,70	0,82	0,22	33,7
S1-07	68,84	0,25	24,1	95,3	8,5	9,1	12,1	76,0	24,0	0,52	0,82	0,40	0,11	0,22	34,6
S1-08	68,84	0,25	23,5	110,8	8,7	10,8	11,4	78,7	21,3	1,30	1,20	1,60	1,00	1,47	29,0
S1-09	68,84	0,25	23,1	128,8	8,7	10,5	10,5	66,7	33,3	1,60	1,28	2,40	0,60	0,86	36,0
S1-11	68,84	0,25	21,2	168,8	9,9	10,6	11,3	45,3	54,7	2,27	1,92	1,95	3,30	2,40	18,4
S1-13	68,84	0,25	20,0	188,8	8,0	12,5	10,8	57,3	42,7	2,24	2,03	3,30	2,40	2,80	28,8
S1-14	68,84	0,25	19,6	208,8	8,6	14,3	9,8	73,3	26,7	2,27	2,67	4,00	3,20	1,97	47,9
S1-15	68,84	0,25	19,2	218,8	8,7	15,1	9,0	80,0	20,0	2,38	1,97	1,20	3,25	3,23	55,3
S1-16	68,84	0,25	18,8	228,8	11,2	14,2	8,2	80,0	20,0	2,42	3,25	3,20	1,40	1,87	52,3
S1-17	68,84	0,25	18,4	238,8	10,5	13,3	6,2	82,6	17,4	1,87	2,00	2,40	0,69	1,10	49,0
S1-18	68,84	0,25	18,0	248,8	8,0	12,5	4,5	58,6	41,4	1,24	0,94	4,00	3,20	2,56	58,2
S1-19	68,84	0,25	17,6	258,8	7,2	11,7	4,1	60,0	40,0	2,56	2,40	4,00	3,20	1,26	32,6
S1-20	68,84	0,25	16,3	268,8	7,0	11,0	3,8	61,3	38,7	1,60	1,26	2,40	3,20	2,93	28,3
S1-23	68,84	0,25	14,8	298,8	8,5	9,4	3,5	66,7	33,3	2,13	2,20	1,60	3,20	3,73	14,9
S1-25	68,84	0,25	13,5	318,8	7,5	12,0	3,6	78,7	21,3	2,56	2,00	2,00	3,20	2,80	12,2
<b>Máx</b>	<b>79.60</b>	<b>0.27</b>	<b>37.1</b>	<b>446.2</b>	<b>11.2</b>	<b>52.0</b>	<b>17.8</b>	<b>85.4</b>	<b>100.0</b>	<b>3.20</b>	<b>3.25</b>	<b>4.80</b>	<b>3.30</b>	<b>3.73</b>	<b>68.4</b>
<b>Méd</b>	<b>75.30</b>	<b>0.26</b>	<b>20.1</b>	<b>195.9</b>	<b>7.3</b>	<b>25.0</b>	<b>10.8</b>	<b>55.1</b>	<b>44.9</b>	<b>1.49</b>	<b>1.51</b>	<b>2.18</b>	<b>1.50</b>	<b>1.39</b>	<b>24.3</b>
<b>Mín</b>	<b>68.84</b>	<b>0.25</b>	<b>9.0</b>	<b>10.90</b>	<b>4.00</b>	<b>9.1</b>	<b>3.5</b>	<b>0.00</b>	<b>14.6</b>	<b>0.01</b>	<b>0.35</b>	<b>0.20</b>	<b>0.00</b>	<b>0.01</b>	<b>4.30</b>

### 6.2.2. Topologias e Parâmetros

No que concerne à topologia, definiu-se a utilização de 2 camadas internas, variando o número de neurônios das mesmas para elaborar cenários diferenciados que serão treinados e comparar os erros para determinar a melhor topologia.

Sendo assim, e visto que são 14 parâmetros de entrada e 1 parâmetro de saída, realizou-se a combinação dos números de neurônios nas camadas intermediárias. Os neurônios nas camadas intermediárias foram variados de 4 em 4, mantendo a quantidade de neurônios da 2ª camada sempre menor ou igual à quantidade de neurônios da primeira camada intermediária.

Além da quantidade de neurônios em cada camada, foram variados os parâmetros de treinamento. No caso do Método de aprendizado do gradiente decrescente com momentum, os parâmetros mais importantes são: taxa de aprendizado e o termo *momentum*. Para a taxa de aprendizado foram adotados 2 valores de 0,7 e 0,5. Para o termo *momentum* optou-se por adotar os valores de 0,9 e 0,3, para verificar se a variação do mesmo exerceria influência.

Sendo assim, para cada modelo de topologia foram montados 4 cenários variando os parâmetros de treinamento. Na Tabela 6.7 pode-se observar os modelos obtidos com as variações dos cenários. O treinamento foi realizado para cada um desses modelos para determinar qual deles poderia alcançar melhores previsões.

---

**Tabela 6.7** – Configurações e topologias utilizadas durante o treinamento da Rede Neural para o trecho Sumaré - Vila Madalena.

Cenário	Neurônios nas Camadas Intermediárias		Taxa de	Termo
	1ª	2ª	Aprendizado	Momentum
01				0,3
02			0,5	0,9
03	4	4		0,3
04			0,7	0,9
05				0,3
06	8	4	0,5	0,9
07			0,7	0,3
08				0,9
09				0,3
10			0,5	0,9
11	8	8		0,3
12			0,7	0,9
13				0,3
14	12	4	0,5	0,9
15			0,7	0,3
16				0,9
17				0,3
18	12	8	0,5	0,9
19			0,7	0,3
20				0,9
21				0,3
22	12	12	0,5	0,9
23			0,7	0,3
24				0,9
25				0,3
26			0,5	0,9
27	16	4	0,7	0,3
28				0,9
29				0,3
30	16	8	0,5	0,9
31			0,7	0,3
32				0,9
33				0,3
34			0,5	0,9
35	16	12	0,7	0,3
36				0,9
37				0,3
38	16	16	0,5	0,9
39			0,7	0,3
40				0,9

Na Figura 6.8 pode-se observar um esquema geral da arquitetura resultante dos modelos.




Figura 6.8 – Esquema da arquitetura utilizada na modelagem.

Seguindo as mesmas premissas da análise anterior adotou-se como função de transferência a tangente hiperbólica por englobar os valores entre -1 e 1. Como critérios de parada adotaram-se novamente os dois critérios já utilizados na análise anterior: erro quadrático menor que 0,001 para todo o conjunto de padrões; ou número de ciclos igual a 10000.

A satisfação de um dos critérios é suficiente para interromper o treinamento. A limitação pelo erro garante uma precisão adequada à rede, e a limitação pelo número de ciclos evita que no ajuste a rede “decore” os dados e perca a capacidade de generalizações.

Os 81 padrões foram colocados em uma ordem definida randomicamente, e foram divididos em 9 grupos de 9 padrões para o treinamento e a realização do processo de

validação cruzada. Segundo esse método o treinamento é realizado com um conjunto de valores, e o teste com os que restam. Definiu-se que seriam utilizados 7 grupos pra o treinamento e 2 grupos para o teste, variando-os de 1 em 1 em seqüência (já que os dados foram aleatórios). Sendo assim foram realizadas 8 combinações mostradas na Tabela 6.8.

**Tabela 6.8** – Combinações realizadas para o processo de validação cruzada.

Combinação	Grupos no Treinamento	Grupos no Teste
1	3, 4, 5, 6, 7, 8, 9	1, 2
2	1, 4, 5, 6, 7, 8, 9	2, 3
3	1, 2, 5, 6, 7, 8, 9	3, 4
4	1, 2, 3, 6, 7, 8, 9	4, 5
5	1, 2, 3, 4, 7, 8, 9	5, 6
6	1, 2, 3, 4, 5, 8, 9	6, 7
7	1, 2, 3, 4, 5, 6, 9	7, 8
8	1, 2, 3, 4, 5, 6, 7	8, 9

### 6.2.3. Resultados

A partir das premissas já mostradas no item topologias e parâmetros, foram realizadas as análises com o *software* MatLab®. Durante a validação cruzada cada uma das combinações gerava um erro. Na Tabela 6.9 apresentam-se as médias dos erros obtidos durante a validação cruzada para cada um dos modelos. O erro entre a previsão e os dados medidos é representado de duas formas, através do coeficiente de correlação e através do erro percentual entre os dados.



**Tabela 6.9** – Erros entre os dados de previsão e teste para cada uma dos cenários montados.

Cenário	Treinamento		Teste	
	R <sup>2</sup>	Erro %	R <sup>2</sup>	Erro %
01	0,586	36,61	0,231	60,79
02	0,585	36,94	0,233	59,73
03	0,580	36,89	0,157	65,84
04	0,580	36,89	0,157	65,84
05	0,994	5,90	0,350	55,88
06	0,994	5,90	0,350	55,88
07	0,661	25,83	0,178	60,16
08	0,661	25,83	0,178	60,16
09	0,523	39,01	0,216	59,85
10	0,557	36,78	0,235	62,79
11	0,382	47,32	0,178	59,54
12	0,382	47,32	0,178	59,54
13	0,765	22,72	0,285	59,27
14	0,765	22,72	0,285	59,27
15	0,630	31,12	0,228	59,23
16	0,630	31,12	0,228	59,23
17	0,762	22,16	0,348	56,62
18	0,762	22,16	0,348	56,62
19	0,513	38,74	0,189	65,49
20	0,513	38,74	0,189	65,49
21	0,293	55,75	0,100	69,68
22	0,293	55,75	0,100	69,68
23	0,288	55,70	0,090	70,47
24	0,288	55,70	0,090	70,47
25	0,752	22,48	0,318	56,00
26	0,752	22,48	0,318	56,00
27	0,642	30,60	0,260	56,91
28	0,642	30,60	0,260	56,91
29	0,636	30,22	0,169	61,70
30	0,636	30,22	0,169	61,70
31	0,508	38,87	0,148	64,64
32	0,508	38,87	0,148	64,64
33	0,409	43,85	0,188	57,82
34	0,409	43,85	0,188	57,82
35	0,406	44,24	0,201	57,38
36	0,406	44,24	0,201	57,38
37	0,409	43,85	0,188	57,82
38	0,409	43,85	0,188	57,82
39	0,406	44,24	0,201	57,38
40	0,406	44,24	0,201	57,38

Considera-se que a análise alcançou precisão adequada. Os erros percentuais no treinamento foram entre 5,9 e 55,8 %. Para o conjunto de teste, o erro percentual resultou um valor médio de 60,7% (entre 55,9 e 70,5%).

Observando os erros obtidos, principalmente para os dados de teste e o valor do coeficiente de correlação destacam-se os cenários 5, 6, 17, 18, 25 e 26. Desses seis observa-se ocorrerem somente 3 topologias diferentes ou seja com variação do número de camadas. Sendo assim, foram analisados para esses seis cenários os erros ocorridos em cada um dos oito conjuntos utilizados para a validação cruzada.

Observou-se que em 4 deles (17, 18, 25 e 26) ocorreram saturação dos neurônios em algumas das 8 combinações realizadas. Nesses casos a rede assumiu valores de bias muito altos ocasionando a geração de valores de saída constantes, não importando os valores de entrada. Procedeu-se então à exclusão dos erros obtidos por essas combinações realizando a média somente com os que não ocasionaram saturação. Na Tabela 6.10 observa-se os valores para esses 6 cenários após a filtragem.

**Tabela 6.10** – Tabela com os erros obtidos no treinamento para os 6 cenários com melhores correlações, excluindo as combinações com saturação.

Cenário	Treinamento		Teste	
	R <sup>2</sup>	Erro %	R <sup>2</sup>	Erro %
05	0,994	5,90	0,350	55,88
06	0,994	5,90	0,350	55,88
17	0,996	5,44	0,412	50,16
18	0,996	5,44	0,412	50,16
25	0,996	5,61	0,409	50,25
26	0,996	5,61	0,409	50,25

Shi *et al.* (1998) obtiveram valores de coeficiente de correlação de 0,832 e 0,575, para treinamento e teste, respectivamente. A comparação desses valores com os obtidos na análise realizada revela que a rede modelada forneceu ótimas correlações para a fase de treinamento. No entanto a fase de testes não forneceu melhores previsões. No caso da

análise, as previsões e o treinamento foram realizados com 4 túneis (ainda que com propriedades parecidas), o que pode ter exercido influência nesses valores, já que equipes diferentes trabalharam nas distintas frentes da obra.

A partir desses valores, pode-se observar que os cenários 17 e 18 apresentaram melhor correlação tanto para a fase de testes, quanto para a fase de treinamento. Esses dois cenários são compostos por 12 neurônios na primeira camada intermediária e 8 neurônios na camada intermediária. Observa-se então que essa topologia alcançou melhores resultados tanto para os dados de treinamento ( $R^2=0,996$  e Erro percentual=5,44%) e de teste ( $R^2=0,412$  e Erro percentual=50,16%) ratificando sua adoção para a realização das análises de sensibilidade a seguir.

Para ratificar a qualidade de previsão do modelo adotado foram separadas aleatoriamente 4 seções de cada túnel, sendo elas:

- Túnel Estacionamento: SE-06; SE-10; SE-13; SE-16
- Túnel Luminárias: SL-07; SL-09; SL-10B; SL-13
- Túnel Jaciporã: S3-02; S3-12; S3-15; S3-21
- Túnel Gaú: S1-04; S1-09; S1-17; S1-23

Essas seções foram utilizadas no conjunto de teste, e as restantes para o conjunto de treinamento. Na Figura 6.9 observa-se a comparação dos dados medidos com os previstos para o conjunto de treinamento. O erro percentual foi de 5,82 % e o coeficiente de correlação de 0,996. Pode-se observar também no gráfico que, para os dados de treinamento os dados previstos ficaram muito próximos dos dados medidos. Tal qualidade de ajuste reflete o erro máximo adotado como critério de parada do treinamento (erro quadrático médio de 0,001).

---




Figura 6.9 – Gráfico comparando os valores previstos e medidos para o treinamento.

A comparação entre os valores medidos e previstos para os dados de teste pode ser observada no gráfico da Figura 6.10. Pode-se observar boa correlação dos valores obtidos, com erro percentual médio de 66% e o coeficiente de correlação de 0,563.





Figura 6.10 – Gráfico comparando os valores previstos e medidos para o conjunto de testes.

#### 6.2.4. Análise de Sensibilidade


As análises de sensibilidade foram realizadas com a topologia adotada com menor erro e a mesma foi treinada com todo o conjunto de dados, inclusive os que antes foram utilizados no conjunto de teste. Os valores dos parâmetros foram variados limitados pelo intervalo de dados do conjunto de que se dispõe. Foram considerados 9 pontos igualmente espaçados, sendo definidos 8 intervalos. Nas figuras a seguir apresentam-se as análises de sensibilidade realizadas para parâmetros cujos resultados comprovam a capacidade de ajuste da modelagem, e dos quais já se possui bom conhecimento do provável comportamento.

A Figura 6.11 mostra a relação obtida entre o recalque obtido e a cobertura. A relação mostrada no gráfico está coerente com o esperado, pois, da literatura sabe-se que o aumento da cobertura da escavação resulta na diminuição dos recalques em superfície.




**Figura 6.11** – Análise da Cobertura versus Recalque

A Figura 6.12 apresenta o gráfico obtido com a análise de sensibilidade para o fator de distância do arco invertido. Assim como era de se esperar, pode-se observar que o aumento da distância do arco invertido resulta em aumento dos recalques. Este comportamento é coerente, visto que quanto maior essa distância maior será o tempo de exposição do maciço sem o devido suporte. O gráfico demonstra também uma queda dos recalques a partir da distância de 9 metros. Esse comportamento não está conforme o esperado, e provavelmente é reflexo do fato que 80% do conjunto possui valores menores que 9 metros, restando poucos dados acima deste para um ajuste adequado.




**Figura 6.12** – Análise da influência da distância do arco invertido.

A Figura 6.13 apresenta os resultados para a variação do recalque com a profundidade do nível d'água que está bem coerente com o que se espera. Pode-se observar que com o aumento da altura do nível d'água os recalques também aumentam. Além de ser um parâmetro que colabora para a queda da resistência do maciço, sabe-se que a geologia local é composta por lentes de areia intercaladas às camadas de argila. **A presença de água em conjunto com a areia pode desencadear fluxo de água em conjunto com carreamento de areia.**



**Figura 6.13** – Análise da influência do Nível d'Água.

A Figura 6.14 apresenta a influência da velocidade de avanço antes e após a seção. Acredita-se que o recalque observado na seção também sofre influência das velocidades de avanço anterior e posterior à seção instrumentada. O gráfico demonstra essa dependência pois com o aumento da velocidade de avanço ocorre a queda dos valores de recalque na seção instrumentada.



**Figura 6.14** – Análise da influência da velocidade de escavação.

Pode-se considerar que as análises de sensibilidade realizadas se mostraram coerentes. Os parâmetros de cobertura, profundidade do nível d'água e distância do arco invertido mostram o comportamento exato que era esperado. Para os parâmetros como velocidade de avanço pode-se observar a influência esperada. Pode-se observar a influência das velocidades de avanço anteriores e posteriores à seção instrumentada, demonstrando que não somente a velocidade na seção influencia a ocorrência dos mesmos.

#### 6.2.5. Conclusões e Comentários

A análise realizada para o trecho Sumaré – Vila Madalena da Linha 2 do Metrô de São Paulo pode ser considerada satisfatória. Foram utilizadas 81 seções instrumentadas, divididas em 4 trechos de construção.

A topologia adotada por obter os menores erros compõe-se de 2 camadas intermediárias com 12 neurônios na primeira camada e 8 neurônios na segunda. A taxa de aprendizado foi de 0,5 e termo *momentum* de 0,3. Para esse modelo os erros obtidos podem ser observados na Tabela 6.10, e são de 5,44% para os dados de treinamento e 50,16 % para os dados de teste. Os coeficientes de correlação obtidos foram de 0,996 para o treinamento e 0,412 para os dados de teste.

Tais valores podem ser comparados com os obtidos por Shi *et al.* (1998), com coeficiente de correlação de 0,832 para treinamento e 0,575 para testes. Observa-se que se obteve um melhor ajuste para o treinamento mas, não para o teste. Provavelmente a limitação do erro médio quadrático tenha utilizado um valor muito pequeno (0,001) que pode ter causado um ajuste excessivo dos dados de treinamento, e uma dificuldade de

---



generalização aos dados de teste. Mesmo assim, os gráficos obtidos para valores medidos e previstos mostram boa correlação, principalmente por trechos, pois percebe-se que mesmo para obras com características tão parecidas, os níveis de recalque obtidos são bastante diferentes.

As análises de sensibilidade ratificaram a influência de alguns parâmetros cuja influência já é conhecida e esperada. Para os outros parâmetros, as curvas obtidas também refletem o comportamento esperado, principalmente no que concerne as velocidades de avanço, já que os valores desenvolvidos antes e após a seção instrumentadas influenciam claramente nos níveis de recalque obtidos. A velocidade no trecho posterior à seção parece ter maior influência na ocorrência dos recalques.

### **6.3. *Re-análise da Extensão Oeste da Linha 2 (Sumaré-Vila Madalena)***

A análise realizada no item anterior para o trecho Sumaré – Vila Madalena obteve resultados considerados satisfatórios. No entanto ao se comparar com os resultados obtidos por Shi *et al.* (1998) há indícios de que os mesmos podem ser melhorados. Além disso, algumas informações adicionais sobre o tipo de tratamento realizado foram consolidadas e obtidas após a análise anterior.

Por isso, optou-se pela re-análise dos dados utilizando outras configurações e procedimentos, na intenção de obter um ajuste ainda melhor. A seguir descreve-se essa re-análise, onde alguns itens como a descrição geológica e os tratamentos padrões dos dados não são explanados já que apenas repetem o caso anterior.

---

### 6.3.1. Novos Procedimentos

A primeira alternativa adotada foi a preferência pela utilização de dados adimensionalizados, ou seja, os valores foram divididos por um parâmetro relacionado aos mesmos, e com a mesma unidade dimensional. Com tal procedimento acredita-se que a sensibilidade dos parâmetros durante o treinamento possa ser melhorada e com isso o ajuste se tornar mais preciso e generalizado.

O parâmetro mais utilizado para adimensionalizar dados geométricos foi o diâmetro equivalente ( $D_E$ ) que corresponde ao diâmetro do círculo de mesma área que a área escavada. Os itens que foram divididos pelo diâmetro equivalente foram: espessura do concreto projetado; cobertura; distância do arco invertido; altura do nível d'água. Para velocidade de escavação, utilizou-se a 'velocidade típica' de um diâmetro por dia para realizar a adimensionalização.

A área escavada, as porcentagens de areia e argila, e os valores de  $N_{SPT}$  não sofreram alterações. No caso da área escavada considera-se importante a amplitude desse valor nas análises. Para o valor de  $N_{SPT}$  não há dimensão ou valor base para se fazer a mesma. As porcentagens de areia e argila já são adimensionais. A progressiva da seção instrumentada foi adimensionalizada pelo comprimento total de cada túnel (Estacionamento, 477 m; Luminárias, 288 m; Jaciporã, 405 m; Gaú, 375m) e colocado em forma percentual.

Na análise anterior observou-se que a alteração do termo momentum não alterava os resultados da rede. Por isso, nessa re-análise optou-se pela utilização de somente um valor para o termo momentum durante o treinamento. Com a adoção de um valor único,

---

o número de cenários diminuiu significativamente permitindo a utilização de uma quantidade maior de topologias com o mesmo número de cenários.

Com a intenção de diminuir a ocorrência de *overflow* durante o treinamento e obter uma melhor capacidade de generalização optou-se pela definição de alguns cenários com somente uma camada intermediária.

Além disso foram acrescentados parâmetros de tratamento cujas informações puderam ser melhor obtidas e consolidadas após a análise anterior. Dentre os tratamentos incorporados destacam-se os de drenagem prévia com utilização de túnel piloto e equipamentos externos (bombas), além da utilização de injeções de CCP em algumas regiões. Sabe-se também que foi realizado tratamento com DHP em toda a extensão dos 4 túneis. Como esse tratamento foi realizado em toda a extensão, sua consideração não é necessária.

Optou-se também pela alteração da amplitude do erro utilizado como critério de parada no treinamento. Na análise anterior o Erro Médio Quadrático foi fixado em 0,001 para o treinamento. Na re-análise adotou-se então o valor de 0,01 para que uma adequação menos exigente da rede ao conjunto de dados de treinamento possibilitasse uma maior capacidade de generalização. Acredita-se que com o erro de 0,001 os dados eram “decorados” durante o treinamento, o que dificultava a previsão. A utilização do valor de 0,01 corresponde há um erro aproximado médio de 10% a 15% nos valores utilizados durante o treinamento sendo uma precisão adequada e satisfatória. A utilização de um erro maior (0,1 por exemplo) poderia melhorar a capacidade de generalização da rede, entretanto já atingiria um valor exagerado para o erro no ajuste aos dados de treinamento de 30% a 35%.

---

### 6.3.2. Obtenção e preparação dos Dados

Novamente os dados foram obtidos e organizados separadamente para os 4 trechos definidos durante a construção.

Para definição dos novos parâmetros de tratamento foram utilizados os trabalhos de Rocha *et al.* (1999) além da colaboração intensiva dos engenheiros e geólogos que participaram da realização da obra, e que puderam dar ótimo testemunho de como ocorreu o tratamento nas regiões onde as informações eram escassas ou de difícil compreensão.

Na Tabela 6.11 observa-se a relação dos parâmetros considerados na análise com a descrição dos mesmos, a simbologia utilizada e as unidades de obtenção dos valores.

**Tabela 6.11** – Características adotadas para o treinamento da Rede Neural.

Tipo	Descrição	Unidade
Geométrico	Cobertura do túnel <sup>(1)</sup> – <i>C</i>	m
	Área da Seção – <i>A</i>	m <sup>2</sup>
	Concreto Projetado de 1ª Fase – CP	m
	Progressiva – P	m
Geotécnicas	Porcentagem de Argila – % <i>Arg</i>	0 a 1
	Porcentagem de Areia – % <i>Are</i>	0 a 1
	Nível d'água <sup>(2)</sup> – <i>NA</i>	m
	Resistência pelo ensaio SPT médio na escavação – <i>N<sub>SPT</sub></i>	–
Escavação	Avanço Ant. (média dos 10 m antes da seção) – <i>AA10</i>	m/dia
	Avanço Ant. (média dos 5 m antes da seção) – <i>AA5</i>	m/dia
	Avanço na seção – <i>A</i>	m/dia
	Avanço Post. (média dos 5 m após a seção) – <i>AP5</i>	m/dia
	Avanço Post. (média dos 10 m após a seção) – <i>AP10</i>	m/dia
	Distância entre a frente ao arco invertido – <i>AI</i>	m
	Ocorrência de Injeção de CCP	0 ou 1
	Rebaixamento do NA Externo	0 ou 1
Ocorrência de Túnel Piloto	0 ou 1	

(1) É a profundidade até a geratriz superior do túnel;

(2) Para o nível d'água considera-se a altura de água a partir da geratriz inferior da seção escavada.

Na Tabela 6.12 observa-se a relação dos dados obtidos para cada um dos padrões (seções instrumentadas) divididos por túnel analisado, e que foram utilizados no

treinamento. Nessa tabela os valores são apresentados de acordo com as unidades mostradas na Tabela 6.11 e seguindo a mesma simbologia mostrada. Cabe ressaltar que os dados aqui apresentados foram normalizados e aleatorizados antes de sua utilização nas análises, visto que esse procedimento permitiria melhores resultados.

**Tabela 6.12** – Dados utilizados nas análises para o trecho Sumaré – Vila Madalena.

Seção	Área <i>m</i> <sup>2</sup>	CP1 <i>m</i>	C <i>m</i>	P <i>m</i>	AI <i>m</i>	N <sub>SPT</sub>	NA <i>m</i>	Argila %	Areia %	AA10 <i>m/dia</i>	AA5 <i>m/dia</i>	A <i>m/dia</i>	AP5 <i>m/dia</i>	AP10 <i>m/dia</i>	Reb –	CCP –	Pil –	ρ <i>mm</i>
<b>Túnel Estacionamento - 20 seções</b>																		
SE-01	74,80	0,27	23,2	10,9	8,0	32,5	10,8	78,7	21,3	0,58	1,00	1,60	0,28	0,38	0	1	1	17,4
SE-03	74,80	0,27	28,2	65,7	6,4	32,5	11,5	76,0	24,0	0,88	0,67	2,40	0,42	0,65	0	1	1	12,7
SE-04	74,80	0,27	29,2	85,7	6,4	41,2	13,1	77,1	22,9	0,68	0,67	0,80	1,00	0,96	0	1	1	7,5
SE-05	74,80	0,27	30,8	108,7	7,2	35,2	12,8	72,2	27,8	0,96	0,80	2,40	0,96	1,37	0	1	1	12,2
SE-06	74,80	0,27	32,1	127,5	6,4	33,7	12,4	72,1	27,9	1,20	1,07	3,20	3,20	1,76	0	1	0	9,6
SE-07	74,80	0,27	33,2	146,5	8,0	32,6	12,3	64,0	36,0	1,30	1,60	1,60	1,60	1,14	0	1	0	8,7
SE-08	74,80	0,27	34,2	171,5	5,6	32,2	12,4	47,2	52,8	1,67	2,30	2,93	2,30	1,78	0	1	0	6,6
SE-09	74,80	0,27	34,5	202,0	5,6	33,4	12,5	58,0	42,0	1,16	1,60	4,00	1,20	1,80	0	1	0	10,5
SE-09A	74,80	0,27	34,8	220,1	5,6	30,0	12,4	48,2	51,8	2,10	2,08	4,80	2,40	2,13	0	1	0	10,6
SE-10	74,80	0,27	35,0	236,0	6,4	29,4	12,1	47,1	52,9	1,92	1,87	2,40	2,13	2,40	0	1	0	13,1
SE-10A	74,80	0,27	35,4	253,7	7,2	29,7	11,5	37,1	62,9	2,24	2,40	3,20	1,60	1,73	0	1	0	11,8
SE-11	74,80	0,27	35,6	260,5	8,0	29,8	11,3	34,3	65,7	2,24	2,13	3,20	1,33	1,60	0	1	0	13,5
SE-12	74,80	0,27	36,2	282,0	7,2	30,7	11,2	37,7	62,3	1,50	1,20	2,40	1,60	1,37	0	1	0	11,5
SE-13	74,80	0,27	36,4	301,0	7,2	34,5	11,2	56,2	43,8	1,24	1,47	2,40	1,60	2,08	0	1	0	10,1
SE-14A	74,80	0,27	37,0	341,0	6,4	40,5	11,8	69,8	30,2	1,71	1,44	4,00	0,57	0,90	0	1	0	11,9
SE-15	74,80	0,27	37,0	361,0	6,4	38,1	11,6	47,9	52,1	1,10	1,03	2,40	1,40	1,20	0	1	0	11,4
SE-15A	74,80	0,27	37,1	379,5	6,4	36,3	11,0	15,3	84,7	1,24	1,33	1,60	0,96	0,88	0	1	0	7,7
SE-16	74,80	0,27	37,0	397,0	6,4	37,7	10,1	23,3	76,7	1,24	1,20	3,20	0,93	0,98	0	1	0	8,4
SE-17	74,80	0,27	36,7	420,0	5,6	39,7	9,7	52,8	47,2	1,60	1,12	2,40	0,60	0,80	0	1	0	7,1
SE-18	74,80	0,27	36,2	446,2	6,4	44,2	10,3	56,4	43,6	1,40	1,40	2,40	0,91	1,02	0	1	0	4,3
<b>Túnel Luminárias - 22 seções</b>																		
SL-02	79,60	0,27	9,6	18,8	4,8	15,7	9,1	19,5	80,5	2,80	2,40	1,60	1,03	1,11	1	1	1	68,4
SL-03	79,60	0,27	10,7	40,1	4,0	17,0	9,6	26,1	73,9	1,04	1,40	1,60	0,23	0,39	1	1	1	63,7
SL-04	79,60	0,27	11,4	60,8	4,8	19,1	10,0	36,1	63,9	0,91	0,89	3,20	0,64	1,26	1	1	1	26,6
SL-05	79,60	0,27	11,6	76,8	5,6	20,7	10,3	60,4	39,6	1,30	1,03	2,40	0,80	1,20	1	1	1	20,7
SL-06	79,60	0,27	11,7	92,6	5,6	23,1	10,5	59,0	41,0	1,50	1,80	1,20	1,20	1,07	1	1	1	24,9
SL-07	79,60	0,27	11,6	111,8	5,6	27,7	10,8	76,7	23,3	1,30	1,00	1,60	2,00	1,49	1	1	0	51,7
SL-08	79,60	0,27	11,6	126,9	5,6	30,4	10,6	85,4	14,6	0,95	0,60	0,80	1,12	1,37	1	1	0	55,7
SL-08A	79,60	0,27	11,6	135,5	6,4	24,9	10,1	73,7	26,3	1,33	1,87	1,60	0,60	0,86	1	1	0	40,6
SL-09	79,60	0,27	11,3	149,8	4,8	15,8	9,3	47,0	53,0	1,47	2,80	2,40	1,12	1,30	1	1	0	35,9
SL-09A	79,60	0,27	11,2	155,8	4,8	15,3	9,1	36,3	63,7	1,60	1,12	1,60	2,00	1,71	1	1	0	32,8
SL-09B	79,60	0,27	11,1	160,9	5,6	15,6	8,8	42,9	57,1	1,94	2,20	4,00	1,60	2,00	1	1	0	37,0
SL-09C	79,60	0,27	11,0	163,6	5,6	15,8	8,6	41,9	58,1	2,00	2,40	4,00	1,20	1,40	1	1	0	41,5
SL-10	79,60	0,27	11,0	166,6	5,6	15,9	8,5	42,9	57,1	1,60	1,60	0,80	2,80	1,73	1	1	0	52,4
SL-10A	79,60	0,27	10,9	170,3	4,8	16,2	8,3	45,4	54,6	2,00	1,60	3,20	1,60	0,73	1	1	0	51,3
SL-10B	79,60	0,27	11,0	173,1	4,8	16,3	8,2	39,6	60,4	1,69	1,76	3,20	1,87	0,94	1	1	0	53,3
SL-10C	79,60	0,27	11,0	179,1	4,8	16,7	8,0	39,7	60,3	0,93	0,60	1,60	2,30	1,93	1	1	0	51,7
SL-11	79,60	0,27	11,0	184,2	4,8	17,0	7,7	46,1	53,9	0,94	2,30	3,00	1,30	1,64	1	1	0	45,1
SL-12	79,60	0,27	10,7	198,2	5,6	19,0	8,0	58,4	41,6	1,98	3,00	2,30	1,57	1,19	1	1	0	26,1
SL-12A	79,60	0,27	10,4	209,8	4,8	21,2	8,6	61,0	39,0	1,29	1,07	3,20	1,33	1,00	1	1	0	10,8
SL-13	79,60	0,27	10,0	222,1	5,2	23,5	7,4	55,8	44,2	1,59	1,80	2,40	1,60	1,00	1	1	0	8,3
SL-14	79,60	0,27	9,7	241,5	5,6	22,8	6,4	50,0	50,0	1,71	1,87	0,80	1,28	1,40	1	1	0	17,0
SL-15	79,60	0,27	9,0	264,8	5,6	16,2	6,1	69,9	30,1	1,42	1,44	1,60	0,69	0,53	1	1	0	34,9

Seção	Área <i>m</i> <sup>2</sup>	CP1 <i>m</i>	C <i>m</i>	P <i>m</i>	AI <i>m</i>	N <sub>SPT</sub>	NA <i>m</i>	Argila %	Areia %	AA10 <i>m/dia</i>	AA5 <i>m/dia</i>	A <i>m/dia</i>	AP5 <i>m/dia</i>	AP10 <i>m/dia</i>	Reb -	CCP -	Pil -	ρ <i>mm</i>
<b>Túnel Jaciporã - 21 seções</b>																		
S3-01	76,79	0,25	18,4	42,9	6,4	44,5	16,4	75,6	24,4	1,60	1,28	1,60	2,40	2,40	0	1	0	11,7
S3-02	76,79	0,25	17,3	66,2	8,8	47,8	17,8	78,2	21,8	1,71	1,44	0,80	2,40	2,40	0	1	0	11,1
S3-03	76,79	0,25	16,5	80,7	8,8	48,5	17,3	66,7	33,3	1,71	1,44	2,40	2,40	1,37	0	0	0	9,9
S3-05	76,79	0,25	16,9	127,4	9,0	24,2	16,6	79,5	20,5	2,13	1,60	1,07	3,20	3,20	0	0	0	12,8
S3-06	76,79	0,25	16,9	146,7	9,1	52,0	16,1	71,8	28,2	2,13	1,60	3,20	2,80	1,50	0	0	0	11,8
S3-07	76,79	0,25	16,8	169,7	8,7	45,1	14,9	59,0	41,0	3,20	3,20	3,20	1,87	2,40	0	0	0	11,8
S3-08	76,79	0,25	16,9	186,2	10,0	38,3	14,3	56,4	43,6	2,72	3,20	4,00	1,87	2,08	0	0	0	12,3
S3-09	76,79	0,25	17,3	191,1	8,5	24,5	14,4	55,1	44,9	2,40	2,40	1,60	2,40	1,37	0	0	0	12,0
S3-10	76,79	0,25	17,3	201,1	6,5	20,6	14,6	53,8	46,2	1,42	1,20	0,53	2,00	1,33	0	0	0	13,7
S3-11	76,79	0,25	17,1	206,2	9,2	29,5	14,8	50,0	50,0	1,40	1,12	2,40	0,00	0,01	0	0	0	13,6
S3-12	76,79	0,25	16,9	210,9	6,5	24,9	14,9	52,6	47,4	0,01	1,20	0,80	0,48	0,46	0	0	0	13,6
S3-13	76,79	0,25	16,7	216,2	9,6	20,1	15,0	43,6	56,4	0,69	0,48	0,20	0,44	0,47	0	0	0	13,1
S3-14	76,79	0,25	16,7	226,2	10,0	19,8	15,1	48,7	51,3	0,47	0,51	0,20	0,35	0,42	0	0	0	12,1
S3-15	76,79	0,25	16,5	246,2	10,8	18,8	15,3	53,8	46,2	1,16	1,12	0,80	0,80	0,96	0	0	0	13,1
S3-16	76,79	0,25	15,8	266,2	9,2	15,6	15,9	51,3	48,7	1,30	1,12	2,40	1,60	1,49	0	0	0	14,7
S3-17	76,79	0,25	14,6	286,2	10,0	16,4	16,0	48,7	51,3	1,28	1,03	1,60	1,20	1,26	0	0	0	23,4
S3-18	76,79	0,25	14,7	295,7	8,0	45,7	14,3	41,0	59,0	1,24	1,40	0,80	1,60	1,37	0	0	0	23,8
S3-19	76,79	0,25	14,2	304,2	8,8	43,6	11,2	41,0	59,0	1,30	0,96	0,85	0,69	0,67	0	0	0	17,7
S3-21	76,79	0,25	13,1	323,7	7,1	38,5	5,5	32,5	67,5	0,69	0,69	1,60	0,69	0,87	0	0	0	14,0
S3-22	76,79	0,25	13,2	329,4	7,8	36,0	4,1	27,5	72,5	0,56	0,80	1,60	0,57	0,85	0	0	0	25,1
S3-24	76,79	0,25	13,2	344,4	8,8	21,7	4,1	0,0	100,0	0,43	0,35	1,60	0,60	0,48	0	0	0	30,2
<b>Túnel Gaú - 18 seções</b>																		
S1-02	68,84	0,25	26,5	58,9	10,2	16,3	12,5	38,7	61,3	0,83	0,94	1,20	0,53	0,64	0	0	0	19,6
S1-03	68,84	0,25	25,7	71,2	8,1	15,9	12,6	54,7	45,3	0,80	0,83	2,40	0,60	0,70	0	0	0	19,7
S1-04	68,84	0,25	25,1	77,3	9,4	15,2	12,6	61,3	38,7	0,86	0,98	1,80	0,62	0,53	0	0	0	21,9
S1-06	68,84	0,25	24,7	90,0	10,2	10,9	12,3	72,0	28,0	0,43	0,40	1,70	0,82	0,22	0	0	0	33,7
S1-07	68,84	0,25	24,1	95,3	8,5	9,1	12,1	76,0	24,0	0,52	0,82	0,40	0,11	0,22	0	0	0	34,6
S1-08	68,84	0,25	23,5	110,8	8,7	10,8	11,4	78,7	21,3	1,30	1,20	1,60	1,00	1,47	0	0	0	29,0
S1-09	68,84	0,25	23,1	128,8	8,7	10,5	10,5	66,7	33,3	1,60	1,28	2,40	0,60	0,86	0	0	0	36,0
S1-11	68,84	0,25	21,2	168,8	9,9	10,6	11,3	45,3	54,7	2,27	1,92	1,95	3,30	2,40	0	0	0	18,4
S1-13	68,84	0,25	20,0	188,8	8,0	12,5	10,8	57,3	42,7	2,24	2,03	3,30	2,40	2,80	0	0	0	28,8
S1-14	68,84	0,25	19,6	208,8	8,6	14,3	9,8	73,3	26,7	2,27	2,67	4,00	3,20	1,97	0	0	0	47,9
S1-15	68,84	0,25	19,2	218,8	8,7	15,1	9,0	80,0	20,0	2,38	1,97	1,20	3,25	3,23	0	0	0	55,3
S1-16	68,84	0,25	18,8	228,8	11,2	14,2	8,2	80,0	20,0	2,42	3,25	3,20	1,40	1,87	0	0	0	52,3
S1-17	68,84	0,25	18,4	238,8	10,5	13,3	6,2	82,6	17,4	1,87	2,00	2,40	0,69	1,10	0	0	0	49,0
S1-18	68,84	0,25	18,0	248,8	8,0	12,5	4,5	58,6	41,4	1,24	0,94	4,00	3,20	2,56	0	0	0	58,2
S1-19	68,84	0,25	17,6	258,8	7,2	11,7	4,1	60,0	40,0	2,56	2,40	4,00	3,20	1,26	0	0	0	32,6
S1-20	68,84	0,25	16,3	268,8	7,0	11,0	3,8	61,3	38,7	1,60	1,26	2,40	3,20	2,93	0	0	0	28,3
S1-23	68,84	0,25	14,8	298,8	8,5	9,4	3,5	66,7	33,3	2,13	2,20	1,60	3,20	3,73	0	0	0	14,9
S1-25	68,84	0,25	13,5	318,8	7,5	12,0	3,6	78,7	21,3	2,56	2,00	2,00	3,20	2,80	0	0	0	12,2
<b>Máx</b>	<b>79,60</b>	<b>0,27</b>	<b>37,1</b>	<b>446,2</b>	<b>11,2</b>	<b>52,0</b>	<b>17,8</b>	<b>85,4</b>	<b>100,0</b>	<b>3,20</b>	<b>3,25</b>	<b>4,80</b>	<b>3,30</b>	<b>3,73</b>				<b>68,40</b>
<b>Méd</b>	<b>75,30</b>	<b>0,26</b>	<b>20,1</b>	<b>195,9</b>	<b>7,3</b>	<b>25,0</b>	<b>10,8</b>	<b>55,1</b>	<b>44,89</b>	<b>1,49</b>	<b>1,51</b>	<b>2,18</b>	<b>1,50</b>	<b>1,39</b>				<b>24,33</b>
<b>Mín</b>	<b>68,84</b>	<b>0,25</b>	<b>9,0</b>	<b>10,90</b>	<b>4,00</b>	<b>9,10</b>	<b>3,50</b>	<b>0,00</b>	<b>14,60</b>	<b>0,01</b>	<b>0,35</b>	<b>0,20</b>	<b>0,00</b>	<b>0,01</b>				<b>4,30</b>

### 6.3.3. Topologias e Parâmetros

Com relação às alterações realizadas no que concerne à topologia, utilizaram-se configurações com 1 e 2 camadas intermediárias agora com um intervalo menor para

variação dos neurônios em cada camada. Como mostrado na Tabela 6.11 são 17 parâmetros de entrada e 1 parâmetro de saída. Sendo assim, nas camadas intermediárias os neurônios foram variados de 3 em 3, mantendo a quantidade da 2ª camada sempre menor ou igual à da primeira camada intermediária.

Quanto aos parâmetros de treinamento, adotaram-se 2 valores para a taxa de aprendizado, 0,7 e 0,5, e para o termo *momentum* optou-se por adotar somente o valor de 0,5, visto que na análise anterior o seu a utilização de 2 valores para esse termo forneceu os mesmos resultados para a mesma topologia. Manteve-se então a utilização de um valor médio visto que o mesmo propicia maior estabilidade durante o treinamento, como descrito por Haykin (1994). Sendo assim, para cada arquitetura de topologia foram montados 2 cenários variando a taxa de aprendizado. Na Tabela 6.13 pode-se observar os cenários obtidos e utilizados para o processo de validação cruzada.

**Tabela 6.13** – Configurações e topologias utilizadas durante o treinamento da Rede Neural para a re-análise do trecho Sumaré – Vila Madalena.

Cenário	Neurônios nas Camadas Intermediárias		Taxa de Aprendizado
	1ª	2ª	
01			0,5
02		–	0,7
03	3		0,5
04		3	0,7
05			0,5
06		–	0,7
07			0,5
08	6	3	0,7
09			0,5
10		6	0,7
11			0,5
12		–	0,7
13			0,5
14		3	0,7
15	9		0,5
16		6	0,7
17			0,5
18		9	0,7
19			0,5
20	12	–	0,7
21		3	0,5

Cenário	Neurônios nas Camadas Intermediárias		Taxa de
	1ª	2ª	Aprendizado
22	12		0,7
23			0,5
24		6	0,7
25		9	0,5
26			0,7
27		12	0,5
28			0,7
29			0,5
30			0,7
31			0,5
32		0,7	
33	15	6	0,5
34			0,7
35		9	0,5
36			0,7
37		12	0,5
38			0,7
39		15	0,5
40		0,7	
41	18		0,5
42			0,7
43		3	0,5
44			0,7
45		6	0,5
46			0,7
47		9	0,5
48			0,7
49		12	0,5
50			0,7
51	15	0,5	
52		0,7	
53	18	0,5	
54		0,7	
55		0,5	
56		0,7	
57		0,5	
58		0,7	
59		0,5	
60		0,7	
61	21	9	0,5
62			0,7
63		12	0,5
64			0,7
65		15	0,5
66			0,7
67		18	0,5
68			0,7
69		21	0,5
70			0,7



Seguindo as mesmas premissas da análise anterior adotou-se como função de transferência a tangente hiperbólica por englobar os valores entre -1 e 1. Como critérios de parada adotaram-se novamente os dois critérios já utilizados na análise anterior: mas com erro quadrático menor que 0,01 para todo o conjunto de padrões; ou número de ciclos igual a 10000.

A satisfação de um dos critérios é suficiente para interromper o treinamento. A limitação pelo erro garante uma precisão adequada à rede, e a limitação pelo número de ciclos evita que no ajuste a rede ‘decore’ os dados e perca a capacidade de generalizações.

Os 81 padrões foram colocados em uma ordem definida randomicamente, e foram divididos em 9 grupos de 9 padrões para o treinamento e a realização do processo de validação cruzada. Segundo esse método o treinamento é realizado com um conjunto de valores, e o teste com os que restam. Definiu-se que seriam utilizados 7 grupos pra o treinamento e 2 grupos para o teste, variando-os de 1 em 1 em seqüência (já que os dados foram aleatórios). Sendo assim foram realizadas 8 combinações mostradas na Tabela 6.14.

**Tabela 6.14** – Combinações realizadas para o processo de validação cruzada.

Combinação	Grupos no Treinamento	Grupos no Teste
1	3, 4, 5, 6, 7, 8, 9	1, 2
2	1, 4, 5, 6, 7, 8, 9	2, 3
3	1, 2, 5, 6, 7, 8, 9	3, 4
4	1, 2, 3, 6, 7, 8, 9	4, 5
5	1, 2, 3, 4, 7, 8, 9	5, 6
6	1, 2, 3, 4, 5, 8, 9	6, 7
7	1, 2, 3, 4, 5, 6, 9	7, 8
8	1, 2, 3, 4, 5, 6, 7	8, 9

#### 6.3.4. Resultados

A partir das premissas já mostradas no item topologias e parâmetros, foram realizadas as análises com o *software* MatLab®. Durante a validação cruzada, cada uma das

combinações gerava um erro. Na Tabela 6.15 apresentam-se as médias dos erros obtidos durante a validação cruzada para cada um dos modelos de duas formas: coeficiente de correlação; e erro percentual.

**Tabela 6.15** – Erros obtidos em treinamento e teste para cada um dos cenários.

Cenário	Treinamento		Teste	
	R	Erro %	R	Erro %
1	0,9613	16,61	0,6617	48,93
2	0,9708	16,40	0,6085	52,98
3	0,9697	15,11	0,5978	48,04
4	0,9533	14,26	0,5511	43,86
5	0,9816	14,36	0,6374	44,61
6	0,9639	13,36	0,5760	49,27
7	0,9820	14,13	0,5445	54,74
8	0,9815	14,49	0,5906	44,03
9	0,9816	14,37	0,6362	44,01
10	0,9815	14,60	0,5691	43,20
11	0,9749	14,98	0,6165	49,60
12	0,9826	14,40	0,5863	52,37
13	0,9815	12,55	0,6527	46,46
14	0,9815	14,71	0,6226	43,34
15	0,9815	12,86	0,6046	44,89
16	0,9821	14,40	0,6216	45,19
17	0,9816	14,68	0,6143	44,12
18	0,9816	13,59	0,6367	43,55
19	0,9818	13,46	0,6340	44,44
20	0,9183	17,41	0,5922	49,16
21	0,9817	13,80	0,6075	44,04
22	0,9825	13,97	0,6632	42,46
23	0,9815	13,62	0,6129	42,64
24	0,9821	13,97	0,6808	41,65
25	0,9816	14,32	0,6508	44,21
26	0,9444	19,03	0,6896	43,52
27	0,9816	13,25	0,6420	42,88
28	0,9815	13,83	0,6187	47,17
29	0,8980	21,60	0,6212	52,37
30	0,6631	35,86	0,4392	57,12
31	0,9815	14,80	0,6264	41,56
32	0,9821	14,75	0,6477	45,44
33	0,9823	13,30	0,6217	43,10
34	0,9470	15,31	0,5931	47,25
35	0,9816	13,56	0,6213	45,02
36	0,9818	13,58	0,6771	41,57
37	0,8043	19,75	0,4068	46,84
38	0,9484	13,63	0,5868	51,57
39	0,8650	21,43	0,4314	53,15
40	0,6498	33,33	0,4942	52,87
41	0,9067	21,49	0,5242	53,16
42	0,8228	27,48	0,4363	62,44
43	0,9816	14,50	0,5671	44,15
44	0,9472	15,20	0,6572	49,20
45	0,9816	13,66	0,6144	45,80
46	0,9817	13,20	0,5462	49,60
47	0,9818	13,87	0,6349	42,21

Cenário	Treinamento		Teste	
	R	Erro %	R	Erro %
48	0,9829	13,46	0,6181	47,24
49	0,9816	13,81	0,6301	42,60
50	0,9826	12,53	0,5961	51,07
51	0,9585	13,32	0,6634	47,97
52	0,7923	24,53	0,4067	56,90
53	0,9499	13,61	0,6788	41,96
54	0,7569	56,02	0,4951	87,38
55	0,7806	29,07	0,4454	49,19
56	0,7236	35,31	0,5008	66,26
57	0,9816	14,80	0,6806	41,82
58	0,9546	15,74	0,5813	43,29
59	0,9816	14,45	0,6035	45,70
60	0,9762	14,00	0,6507	46,98
61	0,9823	14,12	0,6379	44,42
62	0,9768	13,94	0,6185	47,73
63	0,8384	20,00	0,5857	47,47
64	0,9818	12,87	0,6736	43,45
65	0,9663	16,13	0,6483	45,23
66	0,9821	13,80	0,5543	49,16
67	0,8385	21,17	0,5950	46,70
68	0,9822	15,50	0,6452	45,17
69	0,8705	24,55	0,5374	48,66
70	0,8024	21,27	0,5106	49,04
<b>Média</b>	<b>0,9372</b>	<b>17,15</b>	<b>0,5948</b>	<b>47,79</b>


Como pode-se observar na Tabela 6.15 os erros percentuais médios foram de 17,15 e 47,79 % para os dados de treinamento e teste, respectivamente. A média do coeficiente de correlação foi de 0,937 e 0,597 para treinamento e teste, respectivamente. Em comparação com a análise anterior, esses valores são considerados satisfatórios, principalmente com relação aos dados de teste, visto que, na análise anterior o erro médio percentual para esse conjunto foi de 60,7%.

Os erros obtidos se mostraram satisfatórios também, quando comparados com os valores obtidos por Shi *et al.* (1998) que realizou análise semelhante para os túneis do Metrô de Brasília (também com método construtivo NATM) e obtiveram valores de coeficiente de correlação médios de 0,832 e 0,575, para treinamento e teste, respectivamente. A comparação desses valores com os obtidos na análise realizada permite concluir que a rede modelada forneceu previsões adequadas tanto para a fase de


teste quanto para a fase de treinamento, demonstrando adequada capacidade de generalização.

Os Cenários 24, 31, 36, 53 e 57 apresentaram erros médios percentuais menores que 42 %, sendo os menores observados. Dentre esses destaca-se o Cenário 24 que obteve o melhor coeficiente de correlação para os dados de teste. Além disso, esse cenário também demonstra melhores resultados obtidos com os dados de treinamento, quando comparado com os outros cenários citados. Conclui-se então que a topologia e as configurações adotadas no Cenário 24 demonstraram melhor capacidade de ajuste para os dados estudados. Nesse cenário utilizaram-se 2 camadas intermediárias, a primeira com 12 neurônios e a segunda com 3 neurônios. A taxa de aprendizado foi de 0,7 e o termo *momentum* (o mesmo para todos os cenários) foi de 0,5.

As Figuras 6.15 e 6.16 apresentam os gráficos de comparação dos dados medidos e previstos para a combinação 8 de treinamento e teste, com o Cenário 24. Observa-se boa correlação dos dados previstos e medidos para os conjuntos de treinamento e teste.



**Figura 6.15** – Gráfico comparando dados para o treinamento no Cenário 24




**Figura 6.16** – Gráfico comparando dados para o teste no Cenário 24.

Para ratificar a qualidade de previsão do modelo adotado foram separadas aleatoriamente 4 seções de cada túnel, sendo elas:


- Túnel Estacionamento: SE-06; SE-10; SE-13; SE-16
- Túnel Luminárias: SL-07; SL-09; SL-10B; SL-13
- Túnel Jaciporã: S3-02; S3-12; S3-15; S3-21
- Túnel Gaú: S1-04; S1-09; S1-17; S1-23

Essas seções foram utilizadas no conjunto de teste, e as restantes para o conjunto de treinamento. Na Figura 6.17 observa-se a comparação dos dados medidos com os previstos para o conjunto de treinamento. No treinamento o erro percentual foi de 7,76% e o coeficiente de correlação de 0,9821.



**Figura 6.17** – Comparação dos dados previstos e medidos para o treinamento.

Para o conjunto de testes, mostrado na Figura 6.18, o erro percentual médio foi de 32,11% e o coeficiente de correlação de 0,8178. Os erros obtidos para essa validação também demonstram uma melhor qualidade da modelagem na reanálise.



**Figura 6.18** – Comparação dos valores previstos e medidos para o conjunto de testes.

### 6.3.5. Análise de Sensibilidade


As análises de sensibilidade foram realizadas com o Cenário 24 que obteve melhor qualidade no ajuste dos dados. O treinamento foi realizado novamente utilizando todo o conjunto de dados. Com a rede treinada e ajustada foram separados alguns itens para a simulação dos recalques que se obteria.

Variou-se o parâmetro cuja influência se tinha interesse avaliar dentro do intervalo de dados do conjunto de que se dispõe, e os outros parâmetros foram considerados com valor médio e constante. Para os parâmetros tipo 0 e 1 (referentes ao tratamento realizado) considerou-se o valor de 0. A variação de cada parâmetro foi realizada com 9 pontos igualmente espaçados, sendo definidos 8 intervalos.

Dentre os parâmetros utilizados para a análise, alguns foram definidos com a intenção de verificar a eficácia da previsão, visto que o comportamento já era esperado. Outros parâmetros foram escolhidos com a intenção de verificar a influência dos mesmos nos níveis de recalque. A seguir apresentam-se as análises de sensibilidade realizadas. Nas legendas dos eixos a sigla  $D_E$  corresponde a Diâmetro Equivalente, que foi utilizado para a adimensionalização.


Na Figura 6.20 observa-se o gráfico que demonstra a diminuição dos recalques em superfície de acordo com o aumento da espessura do concreto projetado de 1ª fase. Tal comportamento já era esperado visto que uma maior espessura de concreto projetado confere maior rigidez ao revestimento dificultando os deslocamentos iniciais do maciço.

---



**Figura 6.19** – Análise de sensibilidade de recalques com a espessura do concreto projetado.


A Figura 6.21 demonstra a relação obtida entre a cobertura e o nível de recalque. A relação mostrada no gráfico está coerente com o esperado, pois, como mostrado por Negro (1992) o aumento da cobertura da escavação resulta na diminuição dos recalques em superfície.




**Figura 6.20** – Análise de sensibilidade para a cobertura.



Na Figura 6.22 pode-se observar o gráfico que relaciona o aumento do nível de recalque com o aumento da distância do arco invertido. Este comportamento é coerente, visto que maior será o tempo de exposição do maciço sem o devido suporte.



**Figura 6.21** – Análise de sensibilidade para a distância do arco invertido.




**Figura 6.22** – Análise de sensibilidade para a posição relativa da seção no túnel.

Na análise de sensibilidade mostrada na Figura 6.23 observa-se o comportamento do nível de recalque em relação à progressiva do túnel. Os valores de progressiva

mostrados no gráfico são adimensionais correspondendo a uma porcentagem do comprimento do túnel onde estão instalados. Segundo a análise os recalques aumentam nas regiões localizadas próximo ao início e final do túnel. Vale ressaltar que nessas regiões é comum que tenha ocorrido algum tipo de escavação prévia (poço de acesso, por exemplo) tornando o maciço mais deformável e propiciando maiores deslocamentos.

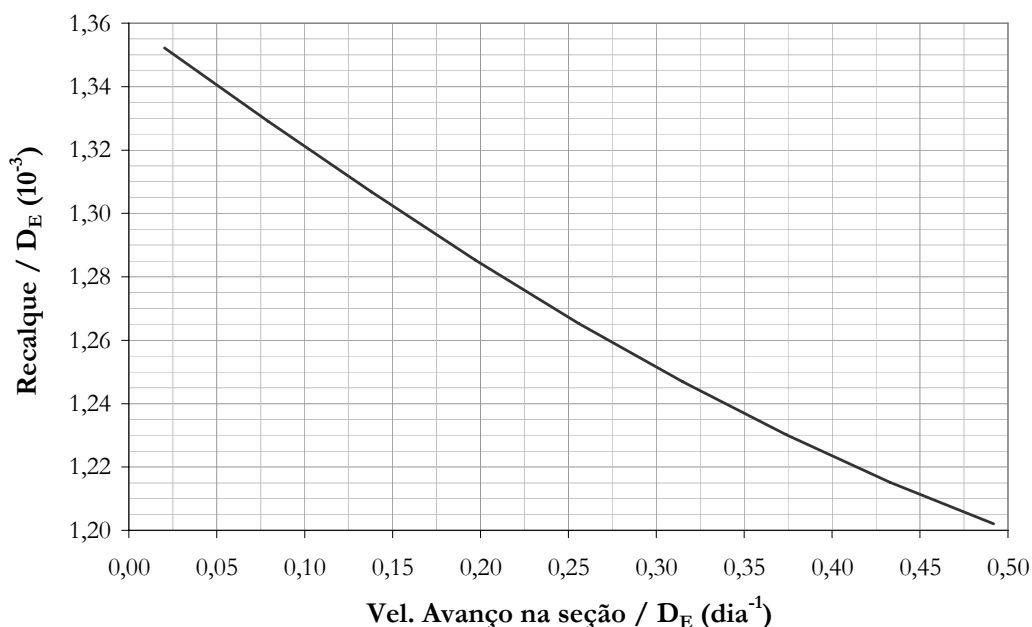
A influência da granulometria do material é apresentada na Figura 6.24. Nesse caso, compara-se a porcentagem de argila e a porcentagem de areia presentes na seção escavada. Para cada uma dessas porcentagens gerou-se uma curva de influência. Tanto para a argila quanto para a areia o gráfico está de acordo com o esperado. No caso da argila, o aumento da porcentagem propicia uma queda do nível de recalque.



**Figura 6.23** – Análise da influência da granulometria no nível de recalque

Para as areias, ocorre o aumento dos níveis de recalque com o aumento da porcentagem da mesma. Observa-se ainda que a variação da porcentagem de areia na seção provoca uma variação bem mais significativa no nível de recalque. Esse comportamento está de acordo com a geologia local, pois devido ao elevado nível d'água

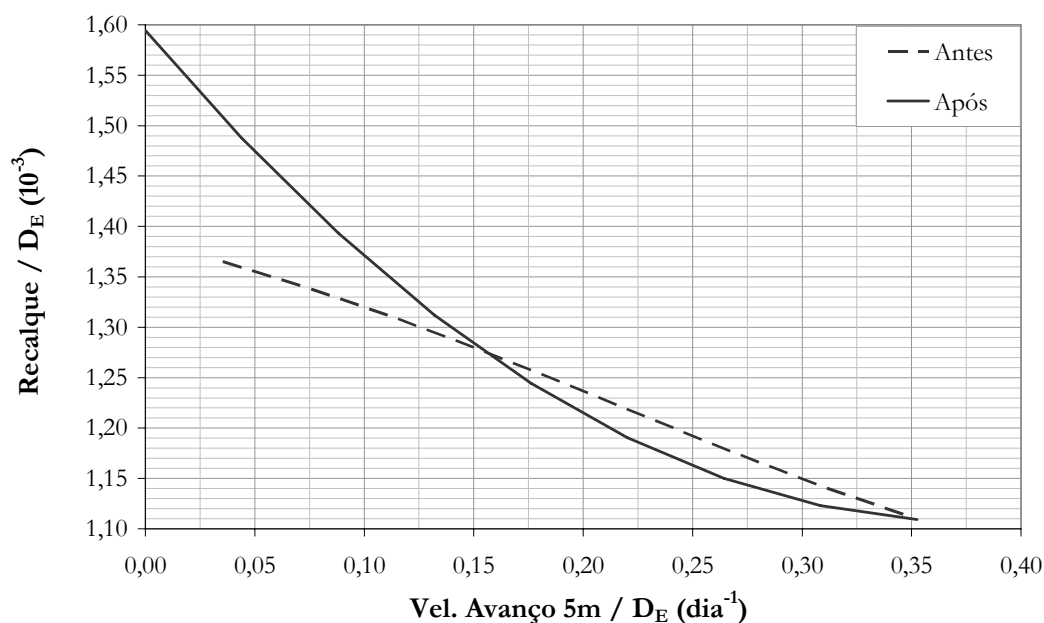
nessa região as lentes de areia podem propiciar um grande carreamento de material elevando de sobremaneira o recalque ocorrido.



**Figura 6.24** – Análise de sensibilidade da velocidade de avanço na seção.

Um dos objetos de estudo dessa análise corresponde à influência da velocidade de escavação nos níveis de recalque ocorrido. Na Figura 6.25 observa-se a influência da velocidade de escavação no trecho a seção instrumentada, ou seja, justamente quando a escavação está passando abaixo da seção instrumentada. Observa-se que o aumento da velocidade de escavação provoca uma redução nos níveis de recalque, como era esperado.

Para as velocidades de escavação antes e após a seção instrumentada, o comportamento esperado é de que o nível de recalque decresça com o aumento da velocidade de escavação, assim como ocorre com a velocidade de escavação na seção. A Figura 6.26 apresenta a influência da velocidade de avanço nos 5 metros antes e após a seção demonstrando o comportamento esperado e ratificando que os recalques são influenciados não somente pela velocidade de escavação na seção, mas antes e depois também.



**Figura 6.25** – Análise da influência da velocidade de escavação para 5 m antes e após.

Pode-se considerar que as análises de sensibilidade realizadas se mostraram coerentes e atingiram boa qualidade. As operações realizadas no tratamento dos dados, novamente mostraram sua eficácia, visto que, em comparação com a análise anterior as previsões agora foram mais condizentes com o esperado.

### 6.3.6. Verificação da eficácia dos procedimentos

Após a observação da significativa redução do erro obtido com as novas configurações, procurou-se determinar qual das modificações surtiu maior efeito. Considera-se que a adição de novos parâmetros de treinamento relacionados ao método construtivo da obra é fator importante para a melhoria das previsões. Sendo assim, as duas principais modificações a serem observadas são: a adimensionalização dos dados; e o aumento da flexibilidade do erro máximo no ajuste durante o treinamento.

Para isso, realizou-se mais 3 análises variando as características, de forma que se fizesse análises com dados adimensionalizados e não adimensionalizados, variando o erro utilizado. Para o conjunto de teste foram utilizadas 4 seções de cada trecho escolhidas aleatoriamente totalizando 16 seções de teste. Os dados restantes foram utilizados para o treinamento.

**Tabela 6.16** – Erros obtidos nas novas análises para determinação da influência dos parâmetros.

Parâmetros Adimensionalizado	MSE	Treinamento		Teste	
		R	Erro %	R	Erro %
Sim	0,01	0,982	9,76	0,818	32,11
Não	0,01	0,983	12,55	0,674	44,92
Sim	0,001	0,998	4,09	0,911	26,96
Não	0,001	0,998	5,16	0,893	43,27

A Tabela 6.16 apresenta os resultados obtidos para os conjuntos de treinamento e teste com a variação dos parâmetros. Pode-se observar que ao contrário do esperado, o erro de 0,001 obteve melhores ajustes para os dados de treinamento e teste para os dados adimensionalizados ou não. Sendo assim, pode-se concluir que a quantidade de dados foi suficiente para que uma menor flexibilidade no erro máximo do treinamento não propiciasse um ajuste excessivo e conseqüentemente a perda de capacidade de generalização da rede.

No que concerne à adimensionalidade dos dados percebeu-se uma melhoria significativa nos ajustes quando os mesmos eram adimensionalizados. Tanto para o conjunto de treinamento quanto para o conjunto de teste. A queda do erro percentual foi de 28,5% quando o critério de ajuste foi de 0,01 para MSE. Para o MSE de 0,001 os resultados são ainda melhores obtendo uma redução de até 37,7%. Isso demonstra que além das melhorias provenientes no novo conjunto de dados, o uso dos valores adimensionalizados também proporcionou significativas melhorias. Com isso, a

adimensionalização cumpre o objetivo inicial possibilitando uma melhor comparação e ajuste, para obras com construções independentes e parâmetros diferenciados. Além disso, tal ferramenta também possibilitaria a utilização de obras diferentes em uma mesma análise, com possibilidade de melhores ajustes.

### 6.3.7. Conclusões e Comentários

A possibilidade de variação de alguns procedimentos e utilização de novas informações do tipo de tratamento realizado no trecho Sumaré – Vila Madalena abriu margem para a realização de uma nova análise visando melhores ajustes. As principais alterações na nova análise compreendem: adimensionalização dos parâmetros utilizados; fixação do termo *momentum*, e não variação do mesmo; criação de cenários com somente 1 camada intermediária; novos parâmetros de entrada relativos ao tipo de tratamento realizado durante a construção; alteração do erro utilizado como critério de parada passando de 0,001 para 0,01.

Com essas alterações foram determinados 70 cenários para treinamento e otimizando a topologia que alcançasse o melhor ajuste, principalmente no que concerne aos dados de teste. Com a utilização da validação cruzada observou-se que os melhores resultados foram atingidos com uma topologia de 2 camadas intermediárias, sendo 12 neurônios na primeira camada e 6 neurônios na segunda. A taxa de aprendizado foi de 0,7.

Para essa configuração os erros percentuais obtidos foram de 13,97% para os dados de treinamento e de 42,46% para os dados de teste. Com relação ao coeficiente de correlação os valores foram de 0,9821 para o treinamento e de 0,6808 para os dados de

---

teste. Se comparados com os erros obtidos na análise anterior (35,76% para o treinamento e 60,7 % para os dados de teste) pode-se observar que a re-análise obteve um melhor ajuste da rede tanto para os dados de treinamento quanto para os dados de teste.

Para ratificar a qualidade da re-análise algumas seções do túnel foram separadas para teste, enquanto a rede foi treinada para os outras seções. Dessa análise foram obtidos coeficientes de correlação de 0,9821 para o treinamento e 0,8178 para a fase de testes. Shi et al. (1998) também realizou previsões desse tipo nos túneis do Metrô de Brasília, treinando a rede com os dados contidos nas primeiros 6km de obra e testando com os últimos 500m, e obteve coeficientes de correlação de 0,832 e 0,575 para essa análise. A comparação entre os resultados demonstra a eficácia da análise realizada.

Em seguida realizaram-se as análises de sensibilidade para verificar a influência de alguns parâmetros no nível de recalque. Para alguns parâmetros a influência já é conhecida e esperada. Para os outros parâmetros, as curvas obtidas também refletem o comportamento imaginado e ratificam a ocorrência dos mesmos. Um exemplo dessa última situação são as análises de sensibilidade realizadas para as velocidades de avanço antes e após a seção instrumentada, demonstrando a considerável influência desses parâmetros na variação do recalque ocorrido.

#### **6.3.8. Conexões e bias da Rede Neural ajustada**

Na Tabela 6.17 observa-se as pesos e *bias* obtidos para o cenário 24 treinado com todos os padrões, e que foram utilizados na análise de sensibilidade. Tais valores foram utilizados para montagem de uma planilha no *software* em Microsoft Excel®, onde o usuário poderá inserir o valor dos parâmetros e obter uma previsão do recalque de acordo

---





## 7. CONCLUSÕES

O estudo realizado demonstrou a aplicabilidade das Redes Neurais Artificiais, para a análise de instrumentação de túneis. Da bibliografia se pode observar que as redes tipo MLP (*Multi Layer Perceptron*) são as mais indicadas para o tratamento desse fenômeno.

Para maior embasamento durante o estudo, foram levantados os principais conceitos referentes às Redes Neurais Artificiais (RNAs), com histórico, definições, características de um neurônio artificial, tipos de aprendizado, e os principais modelos além da aplicabilidade das RNAs. Para a análise de instrumentação de túneis aprofundou-se no estudo das MLPs, observando características de concepção e parâmetros de análise.

O *software* MatLab mostrou-se uma ferramenta adequada para o estudo, pois além do treinamento e teste da rede, o programa permite o tratamento dos dados utilizados. O estudo realizado abordou itens do programa como sua aplicabilidade, e suas potencialidades para o estudo envolvendo as MLPs. Ao final, ratificou-se capacidade dessa ferramenta.

Apresentou-se então uma revisão bibliográfica sobre a utilização das RNAs em Geotecnia e na previsão de recalques em túneis. Nesse último item destacam-se os trabalhos de Shi *et al.* (1998) e Suwansawat (2004) cujas obras de análise foram realizadas com método construtivo sequencial (NATM). O primeiro foi realizado para os túneis do Metrô de Brasília e o segundo para o Metrô de Shangai.

---

A análise realizada para o trecho da Extensão Norte da Linha 1 (Jd. São Paulo – Poço Pedro Cacunda) atingiu erro médio de previsão de 29,6% e 52,2% para recalque máximo e largura da bacia de recalque, respectivamente. A melhor configuração foi com 6 neurônios em cada camada intermediária e taxa de aprendizado de 0,7. Considerando os dados de treinamento, o erro médio obtido nesse modelo foi de 21,8 % e 30,4 % para recalque máximo e largura da bacia de recalque, respectivamente. As análises de sensibilidade representaram os comportamentos esperados.

Os resultados se mostraram coerentes e de boa qualidade, entretanto, a análise desse trecho também alertou para a necessidade de utilização de uma maior quantidade de dados. Por isso partiu-se para a análise do trecho da extensão Oeste da Linha 2 entre as estações Sumaré – Vila Madalena, onde a quantidade de dados era 4 vezes maior. Durante a análise os menores erros foram obtidos com a topologia de 12 neurônios na primeira camada intermediária e 8 neurônios na segunda. Os parâmetros de treinamento foram de 0,5 para a taxa de aprendizado e 0,3 para o *momentum*.

Os erros obtidos da análise foram de 5,44% para os dados de treinamento e 50,16 % para os dados de teste. Os coeficientes de correlação obtidos foram de 0,996 para o treinamento e 0,412 para os dados de teste. Ao se comparar os valores obtidos por Shi *et al.* (1998), em que os autores obtiveram coeficiente de correlação de 0,832 para treinamento e 0,575 para testes, observou-se a possibilidade de um melhor ajuste para os dados de teste impondo uma menor precisão dos dados de treinamento. Além disso, se percebe que mesmo para obras com características tão parecidas, os níveis de recalque obtidos são bastante diferentes. A principal diferença entre as obras foram as diferentes equipes que trabalharam em cada uma.

---

Visando diminuir essa influência dos níveis de recalque diferenciados em cada trecho, lançou-se mão da adimensionalização dos dados no tratamento. Além disso, novas informações de tratamentos de obra utilizados (CCP, drenagem por túnel piloto e drenagem externa) instigaram à realização de uma nova análise do trecho. O critério de parada também foi alterado com o aumento da amplitude do erro de treinamento.

Sendo assim, as principais alterações na nova análise compreenderam: adimensionalização dos parâmetros utilizados; valor único para o termo *momentum*; criação de cenários com somente 1 camada intermediária; novos parâmetros de entrada relativos ao tipo de tratamento realizado durante a construção; alteração do erro utilizado como critério de parada passando de 0,001 para 0,01.

Foram determinados então 70 cenários, e obtido o melhor ajuste para uma topologia de 2 camadas intermediárias, sendo 12 neurônios na primeira camada e 6 neurônios na segunda. A taxa de aprendizado foi de 0,7. Para essa configuração os erros percentuais obtidos foram de 13,97% para os dados de treinamento e de 42,46% para os dados de teste. Tais valores comparados aos obtidos na análise anterior (35,76% para o treinamento e 60,7 % para os dados de teste) demonstram a melhora no ajuste da rede, principalmente no que se refere aos dados de previsão.

Realizou-se então as análises de sensibilidade para verificar a influência de alguns parâmetros no nível de recalque. Tal análise permitiu observar o comportamento e influência de alguns parâmetros nos níveis de recalque. Entre esses destacam-se as velocidades de escavação antes de após a seção, e não somente sob a seção instrumentada.

Percebida a melhora significativa na previsão, procedeu-se ao estudo da influência de cada parâmetro nessa melhora. Observou-se que a adimensionalização dos dados se mostrou bastante eficiente e que o aumento da amplitude do erro não teve o

---

comportamento esperado. Este último demonstra que a quantidade de dados foi suficiente para uma amplitude menor no erro.

---

## 8. REFERÊNCIAS BIBLIOGRÁFICAS

ADELI, H. (2001) Neural networks in civil engineering: 1989-2000. *Computer-Aided Civil and Infrastructure Engineering*, v.16, p.126-42.

AGRAWAL, G.; FROST, J.D. & CHAMEAU, J.L.A. (1994) Data analysis and modeling using an artificial neural network. *Proc. of 13th International Conference on Soil Mechanics and Foundation Engineering*, New Delhi, v.4, p.1441-1444.

AN, H.; SUN, J.; HU, X. (2004) Study on Intelligent Method of Prediction by Small Samples for Ground Settlement in Shield Tunnelling. *Proceedings of the 30th ITA-AITES World Tunnel Congress*, C38, Singapore

BOCANEGRA, C. W. R. (2001) Procedimentos para tornar mais efetivo o uso das redes neurais artificiais em planejamento de transportes. *Dissertação – Escola de Engenharia de São Carlos da Universidade de São Paulo*;

BRAGA, A.P.; CARVALHO, A.C.P.L.F.; LUDERMIR, T.B. (2000) *Redes Neurais Artificiais – Teoria e Aplicações*. Editora LTC. Rio de Janeiro - RJ.

BREGA, J. R. F. (1996) Utilização de redes neurais artificiais em um sistema de gerencia de pavimentos. 234 p. *Dissertação – Escola de Engenharia de São Carlos da Universidade de São Paulo*.

BRONDINO, N. C. M. (1999) Estudo da influência da acessibilidade no valor de lotes urbanos através do uso de redes neurais. 145 p. *Tese – Escola de Engenharia de São Carlos da Universidade de São Paulo*.

CAI, J.G.; ZHAO, J.; HUDSON, J.A. (1998) Computerization of Rock Engineering Systems Using Neural Networks with an Expert System. *Rock Mechanics and Rock Engineering*, p. 135-152.

CELESTINO, T. B.; GOMES, R.A.M.P.; BORTOLUCCI, A.A. (2000) Errors in ground distortions due to settlement trough adjustment. *Tunneling and Underground Space Technology*, v.15, n.1, pp.97-100;

CELESTINO, T. B.; RUIZ, A.P.T. (1998) Shape of settlement troughs due to tunneling through different types of soft ground., *Felsbau*, v.16, n.2, pp.118-121;

- COUTINHO NETO, B. (2000) Redes neurais artificiais como procedimento para retroanálise de pavimentos flexíveis. 119 p. Dissertação – Escola de Engenharia de São Carlos da Universidade de São Paulo;
- DOMINGUES, L.C.S.; CELESTINO, T.B. FERRARI. O.A (1988) “SACI A system for instrumentation control and follow-up” – 6th Int. Conf. Numerical Meth. In Geomech., Vol 3, pp. 2197-2201. Innsbruck, 1988.
- DYMINSKI, A.S. (2000) Análise de problemas geotécnicos através de redes neurais artificiais. Tese (Doutorado) PUC-Rio, 196p.
- DYMINSKY, A.S. & RIBEIRO, E.P. (1995) Rede neural: uma nova técnica na modelagem de solos residuais. In: GEOJOVEM, 2. PUC-Rio. p.467-475.
- FLOOD, I.; KARTAN, N. (1994a) Neural networks in Civil Engineering I: Principles and understanding. Journal of Computing in Civil Engineering, v.8, n.2, p.131-148.
- FLOOD, I.; KARTAN, N. (1994b) Neural networks in Civil Engineering II: System and application. Journal of Computing in Civil Engineering, v.8, n.2, p.149-162.
- GALO, M. L. B. T. (2000) Aplicação de redes neurais artificiais e sensoriamento remoto na caracterização ambiental do Parque Estadual Morro do Diabo. 205 p. Tese – Escola de Engenharia de São Carlos da Universidade de São Paulo;
- GHABOUSSI, J. (1992) Potencial applications of neuro-biological computational models in geotechnical engineering. International Symposium on Numerical Models in Geomechanics. Rotterdam, Balkema. P.543-555.
- GHABOUSSI, J.; SIDARTA, D.E. (1998) New nested adaptive neural networks (NANN) for constitutive modeling. Computers and Geotechnics, 22(1), p.29-52.
- GOH, A.T.C. (1995) Empirical design in geotechnics using neural networks. Geotechnique, v.45, n.4, p.709-714.
- HASHASH, Y.M.A.; GHABOUSSI, J.; JUNG, S.; MARULANDA C. (2002) Systematic update of a numerical model of a deep excavation using field performance data. Proceedings of 8th International Symposium on Numerical Models in Geomechanics - NUMOG VIII. Italy: Balkema: 517-522
- HACHICH, W. ; NEGRO JR, A. (1990) Retroanálise probabilística: medidas de convergência em túneis. Anais do Seminário sobre Instrumentação de Campo em Geotecnia (SINGEO), 1990, Rio de Janeiro. Anais do Seminário sobre Instrumentação de Campo em Geotecnia (SINGEO 90), Rio de Janeiro, v. 1, p. 269-277.
- HAYKIN, S. (1994) Neural Networks – A comprehensive Foundation. Prentice-Hall.
- HEBB, D. O. (1949) The Organization of Behavior. Wiley.
- HOPFIELD, J. J. (1982) Neural networks and physical systems with emergent collective properties. Proc. Nat. Acad. Sci., 79:2554-8.
-

- JAIN, A.K.; MAO, J. & MOHIUDDIN, K.M. (1996) Artificial Neural Networks: A tutorial. *Computer*, v.29, n.3, p.31-44.
- KOHONEN, T. (1989) *Self-Organization and Associative Memory*. Springer-Verlag, Berlin, 3ª edição, 1989.
- LINS, P. G. C. (2002) *Classificação de maciços rochosos : uma abordagem por redes neurais*. 167 p. Dissertação – Escola de Engenharia de São Carlos da Universidade de São Paulo.
- LIPPMANN, R.P. (1987) An introduction to computing with neural nets. *IEEE ASSP Magazine*, v.4, n.2, p.4-22.
- LOLO, J.A. & ZUQUETTE, L.V. (1996) Perspectiva de utilização de redes neurais artificiais na avaliação do terreno com finalidades geotécnicas. In: CONGRESSO BRASILEIRO DE GEOLOGIA DE ENGENHARIA, 8, Anais. Rio de Janeiro. p. 789-795.
- LOLO, J.A. (2000) *O uso de redes neurais artificiais como mecanismo de indentificação de landforms: princípios, metodologia a avaliação da eficácia*. Tese, UNESP, Ilha Solteira. 119p.
- McCULLOCH, W.S.; PITTS, W. (1943) A logical calculus of the ideas immanent in nervous activity, *Bulletin of Mathematical Biophysics*, vol 5, pp.115-133.
- MINSKY, M.; PAPERT, S. (1969) *Perceptrons: na introduction to computacional geometry*. MIT Press, Massachussets.
- NEGRO, A.; SOZIO L.E.; FERREIRA, A.A. (1992) Túneis. In: *Solos da Cidade de São Paulo* (Eds. Negro et al.), ABMS, pp. 297-328, São Paulo
- PECK, R.B. (1969) Advantages and limitations of the observational method in applied soil mechanics. *Geotechnique*, v.19, n.2, p.171-187.
- RAIA JUNIOR, A. A. (2000) *Acessibilidade e mobilidade na estimativa de um índice de potencial de viagens utilizando Redes Neurais Artificiais e Sistemas de Informações Geográficas*. 201 p. Tese – Escola de Engenharia de São Carlos da Universidade de São Paulo;
- ROCHA, H.C. (1995) *Algumas características dos solos arenosos terciários de São Paulo e suas implicações em obras subterrâneas*. 156p, Dissertação – Escola de Engenharia de São Carlos da Universidade de São Paulo;
- ROCHA, H.C.; HORI, K.; RIBEIRO NETO, F. (1999) Aspectos Construtivos dos Túneis do Metrô Paulistano nos Sedimentos da Bacia de São Paulo, *Anais do 9º Congresso Brasileiro de Geologia de Engenharia*, São Paulo
- RODGHER, S. F. (2002) *Aplicação de redes neurais artificiais para previsão de propriedades dos solos tropicais*. 306 p. Tese – Escola de Engenharia de São Carlos da Universidade de São Paulo;
-

- ROSENBLATT, F. (1958) The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, vol. 65, pp. 386-408.
- RUMELHART, D. E. et al. (1986) Learning representations by back-propagating errors. *Nature*, 323:533-536.
- SHAHIN, M. A.; JAKSA, M. B.; MAIER, H. R. (2001). Artificial neural network applications in geotechnical engineering. *Australian Geomechanics*, v.36, n.1, p.49-62.
- SHI, J.; ORTIGÃO, J.A.R. & Bai, J.J. (1998) Modular Neural Networks for Predicting Settlements during Tunneling. *Journal of Geotechnical and Geoenvironmental Engineering*. Vol.124, N.05, p.389 -395.
- SHI, J.J. (2000) Reducing Prediction Error by Transforming Input Data for Neural Networks. *Journal of Computing in Civil Engineering*, v.14, n.2, p.109-116.
- SILVA, C. A. U. (2003) Um método para estimar observáveis GPS usando redes neurais artificiais. 113 p. Tese – Escola de Engenharia de São Carlos da Universidade de São Paulo;
- SUWANSAWAT, S. (2004) Shield Tunneling Database Management for Ground Movement Evaluation. *Proceedings of World Tunnel Congress and 13th ITA Assembly*, C32, Singapore.
- SUWANSAWAT, S.; EINSTEIN, H.H. (2006) Artificial neural networks for predicting the maximum surface settlement caused by EPB shield tunneling. *Tunnelling and Underground Space Technology*, v.21, n.2, p.133–150;
- TEIXEIRA, F. L. (2003) Modelagem de séries fluviométricas para o semi-árido brasileiro via redes neurais artificiais. 128 p. Dissertação – Escola de Engenharia de São Carlos da Universidade de São Paulo;
- TRONCO, M. L. (1999) Sistema de reconhecimento de imagens, baseado no modelo GSN de rede neural. 244 p. Tese – Escola de Engenharia de São Carlos da Universidade de São Paulo.
- WIDROW, B.; HOFF, M. E. (1960) Adaptive switching circuits. *Institute of Radio Engineers, Western Electronic Show and Convention*.
- YANG Y.; ZHANG Q. (1997a) Analysis for the results of point load testing with artificial neural network. In *Proceedings of the 9th International Conference on Computer Methods and Advance in Geomechanics (IACMAG'97)*, Wuhan, p.607-612.
- YANG Y.; ZHANG Q. (1997b) A hierarchical analysis for rock engineering using artificial neural networks. *Rock Mechanics and Rock Engineering*, 30(4), p.207-222.
- ZHANG Q.; SONG J.; NIE, X. (1991) Application of neural networks to rock mechanics and rock engineering. *International Journal of Rock Mechanics and Mining Science*, v.28, n.6, p.535-540.
-