

화강암 풍화토의 토량 변화율 추정을 위한 인공신경망 적용

Application of Artificial Neural Network to the Estimation of Mass Conversion Rate in Weathered Granite Soils

김 영 수* ¹	Kim, Young-Su	정 성 관* ²	Jung, Sung-Kwan
임 안 식* ³	Lim, An-Shik	김 병 탁* ⁴	Kim, Byung-Tak

Abstract

This study performed field and laboratory tests for weathered granite soils taken in four regions of the country and the mass conversion coefficients C values are predicted by using Back Propagation Neural Network(BPNN) and the application of BPNN is verified. The mass conversion coefficients C values obtained from field and laboratory tests are in the range of 0.7 to 1.2 irrespective of subgrade and base of embankment.

The result of this study proved that, the equation of C value suggested by KOLAND has a possibility to be overestimated under weathered granite soils. Neural network structure, $I_{5-1}H_{30-30}O_1$, including specific gravity, water content, moist unit weight, and percentage of passing 200 sieve and uniformity coefficient shows that its result more frequently reaches to region of local minimum than other neural network structure. The result of BPNN shows that correlation coefficient between test and neural network result is larger than 0.9, which means high correlativity. Especially, the estimated result by neural network, using only 4 parameters such as natural water content, unit weight, and percentage of passing 200 sieve among various factors is available to the estimation of C value and the correlation coefficient is 0.96. The conclusions in this paper are the results obtained from the tests for weathered granite soils taken in the several regions of the country. If there were more test results, the influence of factors on C value and prediction of C value by neural network could be more widely suggested.

요 지

본 연구에서는 전국 4개 지구의 화강암 풍화토를 연구대상으로 현장 및 실내시험을 수행하고 토량 변화율을 노상과 노체에 대하여 결정하였다. 그리고, 본 연구에서는 인공 신경망 중 오류 역전파 학습 알고리즘을 도입하여 토량 변화율 C 값을 추정하고 신경망의 적용성에 대한 검증을 수행하였다. 화강암 풍화토에 대한 실내 및 현장시험 결과에서 얻어진 토량 변화율 C 값은 노상과 노체 구분 없이 최소 0.7에서 최대 1.2정도의 넓은 범위로 나타났다.

토지공사에서 제안하는 C 값의 산정식과 본 연구 결과를 비교한 결과, 토지공사의 산정식에 의한 결과가 과대 평가될 가능성이 큰 것으로 나타났다. 비중, 자연 함수비, 자연상태의 습윤단위중량, #200 통과율 그리고 균등계수의 입력변수를 갖는 $I_{5-1}H_{30-30}O_1$ 의 신경망에서 다른 신경망 구조들보다 낮은 지역 최소점에 수렴하는 결과를 보였다. 본 연구에서 사용한 모든 신경망 구조에서 시험결과와 신경망 결과의 상관계수는 0.9 이상으로 나타나 높은 상관성을 나타내었다. 특히, 인공 신경망에 의한 예측결과는 다양한 영향인자들 중에서 비중, 자연 함수비, 자연상태의 습윤단위중량 그리고 #200 통과율의 4개 변수만으로도 C 값을 예측할 수 있었으며, 상관계수는 0.96으로 나타났다.

*1 정회원, 경북대학교 공과대학 토목공학과 교수

*2 정회원, 경북대학교 농과대학 조경학과 교수

*3 정회원, 경북공영개발단 토목팀장

*4 정회원, 한국해양연구원 연구원

본 연구는 국내 일부지역에서 채취한 화강암 풍화토에 대하여 수행한 결론들로서, 보다 많은 시험결과들이 제공된다면 보다 명확한 토량 변화율에 대한 인자들의 영향성과 신경망을 이용한 변화율의 추정이 광범위하게 이루어질 수 있을 것으로 사료된다.

Keywords : Neural network, Mass conversion rate, Weathered granite soils, Subgrade, Base of embankment

1. 서론

단지조성공사의 시행을 위한 토공설계를 함에 있어서, 자연상태의 흙을 절취하여 도로부에 성토되는 흙의 토량 변화율은 도로공사 다짐 시방기준에 따른 시험방법에 의거 토질조사시 측정된 성과를 설계에 적용할 수 있다. 그러나, 시공장비 및 강우 등으로 자연다짐만 발생하는 부지에 성토되는 흙의 토량 변화율은 품질확보를 위한 다짐 시방기준이 없는 실정이다. 따라서, 통상적으로 절토부의 흙 1m^3 을 절취하여 인위적인 다짐을 가하지 않고 부지에 성토하면 1m^3 의 흙이 되는 것으로 가정하여 설계에 적용하고 있다 (한국토지공사, 1994).

단지조성공사 시공시에는 시험성토를 실시하여 절성토 계획고 조정 및 소요의 품질을 확보하여야 하나 불균질한 토질의 특성 때문에 많은 양의 과부족이 발생하는 불가피한 경우를 제외하고는 시료의 대표성 여부에 대한 논란을 피하기 위하여 설계값을 그대로 적용하고 있는 실정이다. 따라서, 토공사 시행을 위한 설계도서를 작성함에 있어서 절·성토량 배분의 기준이 되는 토량 변화율 C 값의 적용기준을 합리적으로 변경하여 시공시 최대한 절·성토량 균형을 이룰 수 있도록 개선하여야 할 필요성이 있다 (한국토지공사, 1995).

도로공사 현장에 있어 공사 초기단계에서 절토 및 성토부의 잉여토량의 발생은 사토 비용 증가문제를 가져오고 있다. 이러한 잉여토량의 발생은 토량 변화율에 가장 밀접한 관계에 있는 자연 함수비와 #200체 통과율에 대한 고려 없이 설계단계에서 토량 변화율을 일률적으로 적용하고 있기 때문이다.

이에 본 연구에서는 기존 건설표준 품셈에서 분류하고 있지 않으며 국내에 널리 분포하고 있는 화강암 풍화토에 대하여 토공설계시 적용하고 있는 토량 변화율을 단위중량 비교방법에 의하여 제안하고자 한다. 그리고, 본 연구를 위하여 전국 4개 대상지구에서 채취한 화강암 풍화토 시료에 대하여 실내시험을 실시한 결과에 근거하여 시료의 물성치들이 토량 변화율에 미치는 영향과 상

관성을 비교 분석하고자 한다. 한국토지공사에서 제안한 C값 산정식과 본 연구결과를 비교 분석하여 수정 실험식을 제안하고자 한다. 다양한 시료에서 얻어지는 지반 물성치에 의하여 토량 변화율이 민감하게 변화하는 문제에 대하여 최근 인간의 신경세포 구조를 응용한 인공 신경망을 지반 공학분야에 적용하고 있는 실정이므로, 본 연구에서도 지반의 기본 물성치를 이용하여 토량 변화율을 인공 신경망에 의하여 예측하고 그 적용성을 검증하고자 한다.

2. 토량 변화율에 대한 기존 규정

본 연구와 관련하여 일본의 적용기준과 건설교통부에서 제시하는 기준 그리고 한국토지공사에서 제시하는 기준들을 요약하면 표 1과 같다. 표에서와 같이 건설교통부에서 제시하는 토량 변화율은 점토, 토사, 모래, 자갈의 경우에서 일본의 기준과 동일하며 암석의 경우는 단위중량이 클수록 다소 큰 값을 적용하고 있다. 그러나, 한국토지공사의 경우, 지금까지의 자료에 근거한 토량 변화율을 각 지반종류별로 제안하고는 있으나, 이들 값은 한국토지공사 연구 보고서에서도 언급한 바와 같이 신뢰성에 다소 문제가 있는 것으로 사료된다. 이는 C와 L 값들이 지반종류별 그리고 원 지반에서 함유하고 있는 세립분 (#200 통과율)의 정도에 따라 크게 변화할 수 있기 때문이다. 또한, 국내에 널리 분포하고 있는 풍화토에 대한 명확한 토량 변화율의 값들을 아직 건설교통부 표준품셈에서 기준을 마련하지 못하고 있다.

한국토지공사에서는 완공된 34개 사업지구를 대상으로 절토부와 성토부 부지에서 무작위로 3 ~ 40개소를 선정하여 토사에 대한 토량 변화율을 결정하고 이를 근거로 절토부 토질의 물성치 즉, 습윤 단위중량, 자연함수비, 비중, #200 통과율 등과 관련지어 토량 변화율을 결정할 수 있는 실험식을 다음과 같이 제안한 바 있다 (한국토지공사, 1996).

표 1. 토랑 변화를 적용기준 비교표

구분	γ_t (t/m ³)	L 값 호트리진시료의 채적 (cm ³) 자연상태의 채적 (cm ³)			C 값 다거진시료의 채적 (cm ³) 자연상태의 채적 (cm ³)		
		건교부 표준품셈 (전인식, 1997)	일본품셈	한국토지 공사	건교부 표준품셈 (전인식, 1997)	일본품셈	한국토지 공사
점토	1.6	1.25~1.45	1.20~1.45	1.30	0.85~0.95	0.85~0.95	0.90
토사	1.7	1.20~1.30	1.20~1.30	1.25	0.85~0.90	0.85~0.95	0.875
모래	1.6	1.10~1.20	1.10~1.20	1.15	0.85~0.95	0.85~0.95	0.90
자갈	1.7	1.10~1.20	1.10~1.20	1.15	1.10~1.05	0.85~1.05	1.075
풍화암	2.0	-	-	1.30	-	-	1.10
연암	2.3	1.10~1.50	1.30~1.70	1.40	1.00~1.30	1.00~1.30	1.15
보통암	2.4	1.55~1.70	1.50~1.70	1.625	1.20~1.40	1.20~1.40	1.30
경암	2.6	1.75~2.00	1.65~2.00	1.85	1.30~1.50	1.30~1.50	1.40

매개변수가 한 개일 경우 :

$$C = 0.52 + 0.29356 \gamma_t \quad (1)$$

$$C = 1.22 - 0.0064 \omega_n \quad (2)$$

$$C = 2.78 - 0.625 G_s \quad (3)$$

$$C = 1.16 - 0.00139 \#200 \text{ 통과율} \quad (4)$$

매개변수가 두 개 이상일 경우 :

$$C = 2.30 + 0.15238 \gamma_t - 0.00414 \omega_n - 0.53495 G_s \quad (5)$$

$$C = 2.19 + 0.17546 \gamma_t - 0.00495 \omega_n - 0.51633 G_s + 0.008 \#200 \text{ 통과율} \quad (6)$$

3. 인공 신경망 (artificial neural network)

본 연구에서 사용한 오류 역전파 신경망(EBPNN)은 델타규칙과 거의 유사하고 다수의 층으로 이루어진 다층 퍼셉트론을 학습시킬 수 있는 일반화된 델타규칙을 이용하고 있다. 일반적으로, 오류 역전파 신경망은 입력값과 목표출력으로 이루어진 학습샘플들을 사용하여 샘플입력에 대한 신경망의 출력값과 목표 출력사이의 오차가 최소

로 되도록 규칙에 따라 연결강도를 조정하는 지도학습(supervised learning)이며, 주어진 학습 샘플들을 사용하여 신경망의 성능이 원하는 수준이 될 때까지 연결강도를 조정하는 Off-line 학습을 수행하게 된다(김대수, 1998; 김병탁, 2000a, 2000b, 2001; 임안식, 2000).

그림 1은 일반화된 델타 규칙에서의 오차 역전파 과정을 나타내고 있다. 먼저, 그림 1의 오른쪽에 나타낸 것과 같이 신경망이 주어진 입력 패턴에 동작하여 출력을 했을 때, 출력층 뉴런들의 오차가 구해진다. 출력층 뉴런들의 경우 오차를 구하는 방법은 델타 규칙과 동일하다. 즉, 목적 패턴에서 출력 뉴런의 활성값을 빼 값이 바로 해당 출력 뉴런의 오차가 된다. 그림 1에서 e_5, e_6, e_7 로 나타낸 것이 각 출력 뉴런들의 오차가 된다.

델타 규칙의 경우, 구한 출력층 오차를 사용하여 바로 가속 가중치를 조절하지만, 일반화된 델타 규칙에서는 이 오차를 한번 더 가공하여 각각의 출력층 뉴런에 대해 델타(δ)를 구한다. 뉴런의 오차로부터 출력층 뉴런들의 델타(δ_j)를 구하는 식은 다음과 같다.

$$\delta_j = f'(net_j) \cdot e_j \\ = \frac{\partial f(net_j)}{\partial net_j} \cdot e_j = a_j(1 - a_j) \cdot (t_j - a_j) \quad (7)$$

여기서, $f'(net_j)$ 는 출력층 뉴런 j 의 활성함수의 미분값, e_j 는 출력층 뉴런 j 의 에러, t_j 는 출력층 뉴런 j 에 대응하는 목적 패턴의 성분, 그리고 a_j 는 출력층 뉴런 j 의 활성값이다.

이상과 같이 출력층 뉴런들의 델타가 구해지면, 이 델타를 아래층 뉴런들로 역전파하는 과정이 진행된다. 이 때 은닉층 뉴런의 델타(δ_i)는 다음 식을 이용하여 구할 수 있다.

$$\delta_i = f'(net_i) \cdot e_i \\ = \frac{\partial f(net_i)}{\partial net_i} \cdot e_i = a_i(1 - a_i) \cdot e_i \quad (8)$$

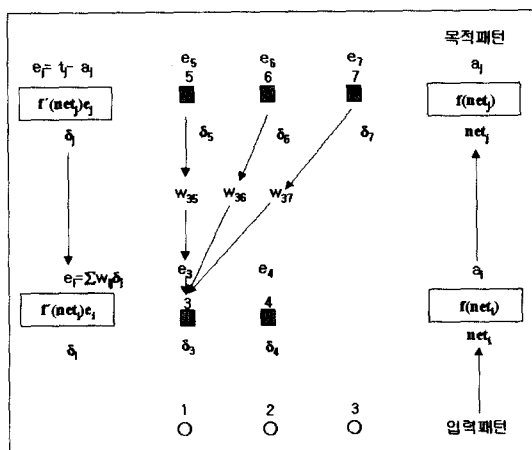


그림 1. 오류 역전파 알고리즘의 개념도

여기서, $f'(net_i)$ 는 은닉층 뉴런 i 의 활성화함수의 미분 값, e_i 는 은닉층 뉴런 i 의 오차, 그리고 a_i 는 은닉층 뉴런 i 의 활성화값이다.

오류 역전파 신경망은 출력값과 목표값의 오차를 줄이기 위하여 입력층에 입력되는 각 패턴에 따라 뉴런들 사이의 연결 가중치를 조절하게 되며 이는 다음 식에 의해 이루어진다.

$$w(new)_{ij} = w(old)_{ij} + \eta \delta_j a_i \quad (9)$$

여기서, $w(new)_{ij}$ 는 뉴런 i, j 사이의 조절된 후의 연결 가중치, $w(old)_{ij}$ 는 뉴런 i, j 사이의 조절되기 전의 연결 가중치, η 는 학습률, δ_j 는 뉴런 j 의 델타, 그리고 a_i 는 뉴런 i 의 활성화값이다.

일반적으로, 신경망에서 적용하고 있는 활성화함수는 선형함수, 계단함수, 선형포화함수, 시그모이드 함수, 그리고 Gaussian 함수로 정리할 수 있으나, 본 연구에서 신경망의 활성화함수는 미분 가능하고 비선형적인 시그모이드 함수를 사용한다. 신경망의 연결 가중치 조절식에 관성을 줌으로써 학습 시간을 단축하고 학습 성능의 향상을 위하여 고안된 모멘텀은 현재의 연결 가중치와 그 이전 연결 가중치의 차에 의해 계산된다. 모멘텀은 신경망의 연결 가중치 조절 과정에 추가되며, 이 모멘텀이 추가됨으로써 일반화된 델타 규칙에 의한 연결 가중치를 조절하는 식 (3)은 다음 식과 같이 변하게 된다.

$$w(new)_{ij} = w(old)_{ij} + \eta \delta_j a_i + \beta \Delta w_{ij}(old) \quad (10)$$

β 는 학습률 η 와 유사한 역할을 하는 것으로 모멘텀의 크기를 제어하기 위한 상수이다. β 는 0에서 1사이의 값이며, 일반적으로 0.7 ~ 0.9 정도의 값이 사용된다.

바이어스 (bias)는 입력층 뉴런을 제외한 모든 뉴런이 가지는 특성으로서 마치 언제나 출력이 1인 가상의 뉴런을 달고 있는 연결 가중치처럼 취급된다. 따라서, 바이어스는 뉴런의 활성화에 참여할 뿐만 아니라 다른 연결 가중치들과 마찬가지로 학습에 의해 조절된다. 바이어스의 학습 역시 마치 그것이 언제나 출력이 1인 가상의 뉴런을 달고 있는 연결 가중치와 같이 이루어진다.

일반화된 델타 규칙에서 학습 완료 정도를 나타내는 시스템 오차 (system error, E_p)는 다음 식에서와 같이 출력 패턴과 목적 패턴과의 차이에 의해 계산할 수 있다.

$$E_p = \frac{1}{2} \sum_{i=1}^n (o_{p,i} - t_{p,i})^2 \quad (11)$$

여기서, $o_{p,i}$ 는 입력 패턴 p 에 대한 출력층 i 번째 뉴런의 실제 출력값이고 $t_{p,i}$ 는 목적 패턴 p 의 i 번째 성분이다.

4. 실내 및 현장실험

4.1 실험종류

본 연구에서는 4개 연구대상지구에 대하여 토량 변화율(C, L)을 실내 및 현장시험에 근거하여 결정하였다. 연구 대상지구의 위치는 그림 2와 같으며, 각 연구대상지구 에 대한 현장 및 실내시험의 실시개소는 오창 과학산업단지의 13개소, 대전 노은지구의 10개소, 광주 유통산업단지의 10개소 그리고 안동 정상지구의 6개소로 총 39개소이다.

토량 변화율에 대한 인자들의 영향성 파악을 위하여 본 연구에서는 각 시험개소에서 입도시험(KSF 2302-92), 비중시험을 침도 1.5m, 3.0m, 4.5m, 6.0m의 시료에 대하여 실시하고 토량 변화율 C 를 결정하기 위하여 노상은 A 다짐 방법 그리고 노체는 D 다짐방법으로 다짐시험 (KSF2312-91)을 침도 1.5m ~ 6.0m에 대하여 실시하였으며, 현장 밀도시험(KSF 2311- 91)과 호트리진 시료의 단위중량 시험을 각각 실시하였다. 토량 변화율은 시험대상위치에서 동일한 체적에 대한 중량의 비로서 결정하였다. 대상지역의 풍화토 입자는 깊이가 깊어짐에 따라 조립분이 많아지




그림 2. 연구대상지

표 2. 각종 실내 및 현장시험의 결과와 토량 변화율의 범위


대상지구명	비중	함수비 (%)	최대입경 (mm)	D ₆₀ (mm)	D ₃₀ (mm)	D ₁₀ (mm)	C _u	C _o	# 200 통과율 (%)	다짐 건조중량 (t/m ³)		γ ₁ (t/m ³)	C 값		L 값
										A 다짐	D 다짐		노상	노체	
대전노은지구	2.62	10.25	2.0	0.092	0.0082	0.0006	91	0.2	17.19	1.75	1.875	1.387	0.82	0.85	1.21
	-2.68	-17.77	-13.2	-0.82	-0.13	-0.0017	-612	-36.1	-56.85	-1.895	-2.010	-1.803	-0.97	-1.14	-1.29
안동정상지구	2.67	5.17	9.5	0.97	0.35	0.0011	28	3.6	11.89	1.93	2.045	1.785	0.92	1.03	1.19
	-2.69	-9.24	-13.0	-1.50	-0.50	-0.05	-1273	-125.7	-14.49	-1.98	-2.105	-2.101	-1.06	-1.18	-1.35
오창과학산업지구	2.64	8.86	4.75	0.38	0.045	0.0003	31	1.5	13.76	1.863	1.955	1.491	0.79	0.87	1.11
	-2.73	-18.11	-9.5	-0.87	-0.25	-0.026	-538	-28.4	-31.47	-1.96	-2.055	-2.046	-1.06	-1.17	-1.43
광주유통산업지구	2.64	9.73	4.75	0.022	0.0079	0.0009	28	0.1	11.22	1.775	1.835	1.515	0.81	0.89	1.23
	-2.74	-20.7	-9.5	-0.98	-0.30	-0.035	-460	-27.3	-38.81	-1.915	-1.995	-1.859	-1.01	-1.10	-1.35

며 입자의 모양은 각진 것이 많았다. 그리고, 입도분류는 SM이 주를 이루었다.


4.2 실험결과

본 연구에서 토량 변화율 C와 L에 대한 영향인자는 비중(G_s), 함수비(ω_n), #200 통과율, 균등계수(C_u), 곡률계수(C_g), 유효입경(D_{10}), 최대 입경, D_{30} , D_{60} , 자연상태의 습윤

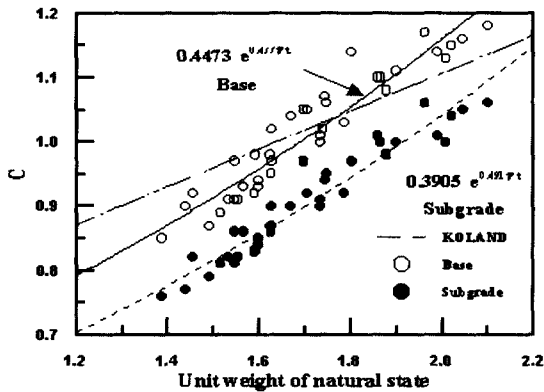
단위중량(γ_1)으로 총 10개의 인자를 고려하였으며, 각 연구대상지구에서 채취한 시료에 대한 각종 실내 및 현장시험을 수행하고 영향인자들의 값과 다짐 건조밀도 그리고 노체와 노상의 토량 변화율 C 및 L값의 범위를 각 대상지구에서 전체 시험심도(G.L. -1.5~ -6.0m)에 대하여 요약하면 표 2와 같다. 그리고, 본 연구에서는 노상과 노체부의 다짐도는 토지공사의 기준에 근거하여 각각 D 다짐법의 95%과 A 다짐법의 90%를 적용하였다.



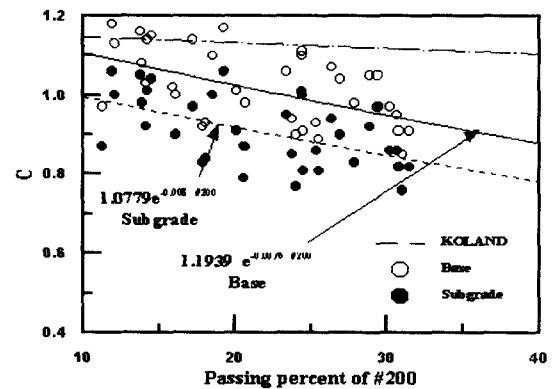
(a) 비중과의 관계



(b) 함수비와의 관계



(c) 자연상태의 습윤단위중량과의 관계



(d) #200 통과율과의 관계

그림 3. 노상과 노체에서 각 영향인자들에 대한 토량 변화율 C의 변화




그림 4. 한국토지공사의 제안식과 시험결과와의 비교

5. 토량 변화율의 상관성 검토

토량 변화율에 영향을 미치는 다양한 인자들과의 상관성을 표 2에서 요약한바와 같이 지반 물성치에 대하여 검토하면, 최대입경, D_{60} , D_{30} , D_{10} , 곡률계수 그리고 균등계수에 의한 토량 변화율의 변화는 상당히 이산분포를 나타내어 본 연구의 토량 변화율의 분석에는 포함하지 않았다. 따라서, 토량 변화율 C의 변화를 비중(G_s), 자연 함수비(ω_n), 자연상태의 습윤단위중량(γ_t), #200 통과율에 따라 나타내면 그림 3과 같다.

그림 3에서는 식(1) ~ (4)와 같이 한국토지공사에서 제안하는 실험식을 함께 나타내어 비교하였다. 그림에서와 같이, 본 연구에서 수행한 화강암 풍화토에 대한 각 지반 물성치(G_s , ω_n , γ_t , #200 통과율)와 토량 변화율(C)의 관계를 시험결과에 근거하여 회귀분석한 결과, 지수함수의 형태로 제안할 수가 있었으며 함수식은 각 그림내에 기재하였다. 화강암 풍화토의 토량 변화율 C는 노상, 노체에 구분없이 최소 0.7에서 최대 1.2정도의 넓은 범위로 나타나고 있다. 이는 건설교통부 표준품셈에서 제시하는 토량 변화율 C값들보다 최소값에서는 작은 값을 그리고 최대값에서는 큰 값을 보이고 있다. 또한, 건설교통부 표준품셈에서 제시하는 변화율 C는 자연상태 단위중량에 따라 기준을 마련하였으나, 이들 값은 본 연구의 대상시료인 화강암 풍화토의 결과와 큰 차이를 보이고 있으며 성토부 노상과 노체의 다짐도를 고려한 토량 변화율의 값이 차이를 보임에 따라 지반의 종류에 의한 변화율의 획일적인 기준 제시는 현장에 적용하기에 적합하지 않을 것으로 사료된다.

본 연구결과에 근거하여 토량 변화율과 각 지반 물성치들(G_s , ω_n , γ_t , #200 통과율)의 상관성을 검토한 결과, 자

연상태의 습윤단위중량과의 결정계수(R^2)가 0.90 이상으로 가장 높은 상관성을 보였으며 비중과의 결정계수는 0.1 이하로서 가장 낮은 상관성을 나타내었다. 또한, 자연 함수비와 #200 통과율과의 결정계수는 각각 0.27정도로 나타났다.

토량 변화율은 지반의 다양한 매개변수에 의하여 영향을 받고 있는 것으로 알려져 있다. 따라서, 한 개의 지반 매개변수에 의하여 토량 변화율을 결정하는 것은 상당한 불확실성을 갖고 있기 때문에 본 연구에서는 식(5)와 (6)에서처럼 한국토지공사에서 두개 이상의 매개변수를 근거로 제안하고 있는 산정식에 근거한 추정결과와 본 연구대상지구의 시험결과를 비교하면 그림 4와 같이 나타났다.

그림에서와 같이, 한국토지공사에서 제안하는 토량 변화율이 시험결과보다 과대 평가될 가능성이 크며, 토량 변화율 산정식에 포함된 매개변수가 많을수록 시험결과에 근접하는 결과를 보여주고 있다.

따라서, 본 연구에서는 실내 및 현장시험 결과에 근거하여 한국토지공사의 제안식에 의한 C 값을 보정할 수 있는 실험식을 다음과 같이 제안할 수 있었다.

매개변수가 3개인 경우:

$$C(\text{시험}) = 2.0 \times C \text{ 값(한국토지공사)} - 1.2 \quad (12)$$

매개변수가 4개인 경우:

$$C(\text{시험}) = 2.44 \times C \text{ 값(한국토지공사)} - 1.73 \quad (13)$$

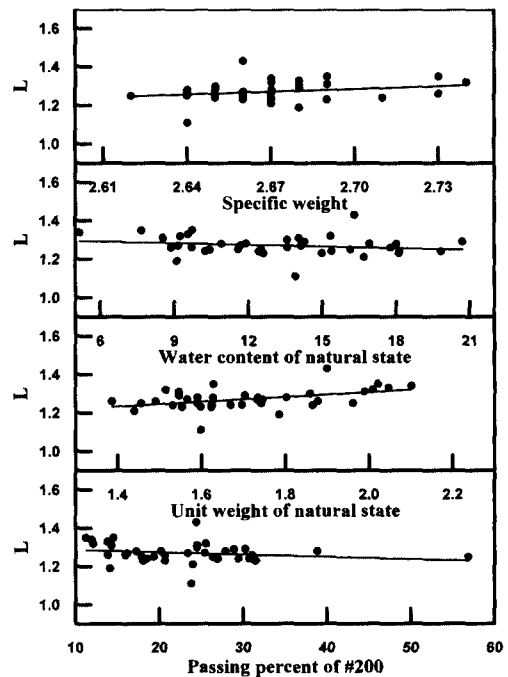


그림 5. 물성치에 따른 토량 변화율 L의 변화

표 3. 신경망의 입력층 변수

신경망 구조	입력 변수	은닉층 뉴런 수		학습률 η	모멘텀 β
		H ₁	H ₂		
$I^{(1)}_3 H^{(2)}_{30-30} O^{(3)}_1$	G_s, γ_t, ω_n	30	30	0.9	0.9
$I_4 H_{30-30} O_1$	$G_s, \gamma_t, \omega_n, \#200$ 통과율				
$I_{5-1} H_{30-30} O_1$	$G_s, \gamma_t, \omega_n, \#200$ 통과율, C_u				
$I_{5-2} H_{30-30} O_1$	$G_s, \gamma_t, \omega_n, \#200$ 통과율, C_g				
$I_6 H_{30-30} O_1$	$G_s, \gamma_t, \omega_n, \#200$ 통과율, C_g, D_{10}				
$I_7 H_{30-30} O_1$	$G_s, \gamma_t, \omega_n, \#200$ 통과율, C_g, D_{10} , 최대입경				
$I_{10} H_{30-30} O_1$	$G_s, \gamma_t, \omega_n, \#200$ 통과율, C_g, D_{10}, D_{30} , 최대입경, D_{60}, C_u				

*) I, H, O 는 각각 신경망 구조의 입력층(Input), 은닉층(Hidden), 그리고 출력층(Output)을 의미한다.

그림 3에서는 노상과 노체의 토량 변화율 C의 변화에 대하여 검토하였으며, 자연상태와 흐트러진 상태의 단위 중량 비인 토량 변화율 L의 변화를 비중, 자연 함수비, #200 통과율 그리고 자연상태의 습윤단위중량에 대하여 나타내면 그림 5와 같다.

그림에서와 같이, 토량 변화율 L과 비중, 자연 함수비, #200 통과율 그리고 자연상태 단위중량의 관계를 검토한 결과, 변화율과 상관성이 큰 것은 자연상태의 습윤단위중량으로 나타났으며 다음은 비중으로 나타났다. 이들 변수와 토량 변화율 L과의 관계를 회귀분석한 결과, 지수 함수 식으로 결정되었으며 회귀식은 그림 5와 함께 나타내었다. 그리고, 자연상태 시료의 #200 통과율과 함수비가 증가할수록 토량 변화율 L의 변화는 감소하는 경향을 보이고 있으며, 그 감소정도는 자연 함수비에서 큰 것으로 나타났다.

6. EBPNN에 의한 토량 변화율 학습

우리나라에서 지반공학적인 문제에 대한 인공 신경망은 1990년대 이후부터 일부 지반공학분야에서만 적용되어 왔으며, 인공 신경망의 학습에 이용된 패턴 수도 수십 개에 불과하다. 그러나, 인공 신경망은 초기에 생물학적인 접근에서 시작하여 최근에는 경제 분야 또는 공학적인 분야에 이르기까지 상당히 많은 응용분야에서 그 적용성을 검증하기 위하여 연구가 수행되고 있다(Nawari et al. 1999; Tasi et al., 1999) 이에 본 연구에서는 인공 신경망의 장점인 병렬처리와 자기 조직화를 이용하여 다양한 지반 조건 및 다짐조건에 의한 토량 변화율 C의 시험결과와 예측결과와의 상관성을 검토하였다.

6.1 신경망 구조

본 연구에서는 토량 변화율 C를 각각 다른 신경망 구조에서 학습과 예측을 수행하였다. 이는 토량 변화율의 예측을 위한 신경망에서 입력변수들의 구성에 따른 시험결과와 예측결과들의 상관성을 검토하고 신경망 해석시 정도 높은 해석을 위한 입력변수의 결정과 한국토지공사에서 제안한 식 (5)와(6) 같은 실험식의 상관성과의 비교 검토를 위하여 다양한 구조의 신경망을 이용하였다.

본 연구에서의 오류 역전과 신경망은 7가지 구조를 사용하였다. 이들 각 신경망 구조에서 사용한 입력변수들을 요약하면 표 3과 같다. 이들 각 신경망 구조에서 공통된 점은 각 신경망에서의 은닉층(hidden layer)은 모두 2개층으로 이루어져 있고, 은닉층의 뉴런수와 학습률은 다양하게 적용하여 최적의 결과를 적용하였으며 신경망 구조는 그림 6과 같다.

신경망 입력층의 입력 변수 값들에 대한 정규화를 위하여 본 연구에서는 다음의 식을 적용하였다. 그리고, 각 신경망에 적용한 입력 값의 범위는 표 4와 같다.



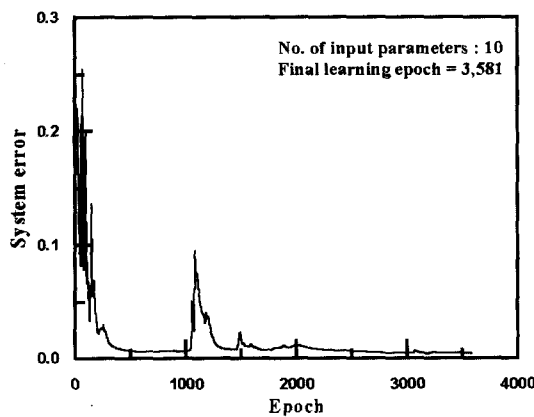


그림 6. 신경망 구조 (I_{any}H₃₀₋₃₀O₁)



(a) $I_6H_{30-30}O_1$ 인 경우



(b) $I_{10}H_{30-30}O_1$ 인 경우

그림 7. 신경망 학습동안의 시스템 오차의 변화

$$x_{norm} = \frac{x + (x_{max} - 9x_{min})/8}{(x_{max} - 9x_{min})/0.8} \quad (14)$$

여기서, x_{norm} 는 정규화한 값이고 x_{max} 와 x_{min} 는 각 입력 변수중 최대값과 최소값이며, x 는 각 입력층 뉴런에서의 입력 값이다.

6.2 인공 신경망 학습결과 검증

신경망 구조에서 0.004의 시스템 오차에 수렴하는 동안

표 5. 신경망 반복 연산횟수

신경망 구조	$I_3H_{30-30}O_1$	$I_4H_{30-30}O_1$	$I_{5-1}H_{30-30}O_1$	$I_{5-2}H_{30-30}O_1$	$I_6H_{30-30}O_1$	$I_7H_{30-30}O_1$	$I_{10}H_{30-30}O_1$
반복 횟수	48,804	46,908	21,594	24,466	82,643	75,472	3,581

표 6. 신경망 구조에 따른 신경망 학습 완료후의 상관계수

신경망 구조	$I_3H_{30-30}O_1$	$I_4H_{30-30}O_1$	$I_{5-1}H_{30-30}O_1$	$I_{5-2}H_{30-30}O_1$	$I_6H_{30-30}O_1$	$I_7H_{30-30}O_1$	$I_{10}H_{30-30}O_1$
상관 계수	0.94	0.96	0.90	0.92	0.93	0.95	0.90

표 4. 입력층 뉴런의 입력값 범위


입력 변수	최소값	최대값	시험 결과값
비중, G_s	2.60	2.65	2.62 ~ 2.64
자연상태 습윤단위중량, γ_t	1.30	2.30	1.387 ~ 2.101
자연 함수비, ω_n	0.	25.	5.17 ~ 20.7
#200 통과율 (%)	0.0	60.0	11.22 ~ 56.85
균중계수, C_u	20.0	1300.0	28.0 ~ 1273.0
곡률계수, C_o	0.0	130.0	0.1 ~ 125.7
유효입경, D_{10}	0.0	0.07	0.0006 ~ 0.05
최대입경	0.0	15.0	2.0 ~ 13.2
D_{30}	0.0	0.7	0.0079 ~ 0.5
D_{60}	0.0	2.0	0.022 ~ 1.5

의 오차변화 과정을 나타내면 그림 7과 같으며, 그림에서는 학습 반복횟수가 최대 및 최소인 신경망 구조의 결과를 나타내었다. 그리고, 최종적으로 시스템 오차에 수렴하는 신경망 반복 학습횟수를 각 신경망 구조에 대하여 나타내면 표 5와 같다. 본 연구에서는 노상과 노체의 구분 없이 총 실내시험의 50%에 대하여 신경망 학습을 수행한 후 나머지 50%의 토량 변화율에 대한 신경망 예측결과와 시험결과를 비교 분석하였다. 50%의 실내 시험결과에 대한 신경망 학습 후의 반복 학습횟수는 표 5에서와 같이 $I_6H_{30-30}O_1$ 의 경우에서 가장 크게 나타났으며, $I_{10}H_{30-30}O_1$ 의 경우에서 가장 작게 나타났다.


그리고, 신경망 학습동안의 시스템 오차 변화를 검토하면, 입력변수의 수가 증가할수록 오류 역전과 신경망의 단점인 지역 최소점에 시스템 오차가 수렴하려고 하는 결과를 보여주고 있으며, 특히 $I_{5-1}H_{30-30}O_1$ 의 경우에서 다른 신경망 구조들보다도 자주 지역 최소점에 수렴한 후 최소점에서 이탈하여 전역 최소점에 수렴하는 것으로 나타났다.

7. 토량 변화율의 예측


신경망에 의한 토량 변화율의 예측은 총 실내시험 결과의 50%에 대한 신경망 학습을 완료한 후 신경망내의 수렴




(a) $I_3H_{30-30}O_1$ 의 경우




(b) $I_4H_{30-30}O_1$ 의 경우




(c) $I_{5-1}H_{30-30}O_1$ 의 경우




(d) $I_{5-2}H_{30-30}O_1$ 의 경우



(e) $I_6H_{30-30}O_1$ 의 경우



(f) $I_7H_{30-30}O_1$ 의 경우



(g) $I_{10}H_{30-30}O_1$ 의 경우

그림 8. 신경망구조에 따른 시험결과와 신경망의 예측 결과 비교

한 연결강도를 이용하여 전혀 학습에 관여하지 않은 새로운 실내시험 데이터를 입력하여 결정되는 신경망의 토량 변화율과 시험결과를 비교 분석하였다.

오류 역전파 학습 알고리즘을 이용하여 학습한 후의 신경망 예측성은 각 신경망 구조에 대하여 예측결과와 시험 결과들의 상관계수 (correlation coefficient, R^2)로 나타내었으며, 그 결과는 다음의 표 6과 같다. 그리고, 신경망에 의한 토량 변화율과 시험결과들의 수렴성을 각 신경망 구조에 따라 나타내면 그림 8과 같다.

표 6에서와 같이, 토량 변화율에 대한 시험결과와 신경망 결과의 상관계수는 본 연구에서 사용한 신경망 구조에 무관하게 모두 0.9 이상으로 나타나 높은 상관성을 보여주고 있다. 이는 매우 다양하고 지반의 구조적 성질에 따라 큰 변화를 나타내어 이론적인 접근이 어려운 토량 변화율의 예측에 신경망의 적용이 가능하다는 것을 나타내고 있으며, 그 예측성 또한 높게 나타나 이 분야에서의 적용성을 입증하였다고 할 수 있다.

그림 8-(b)에서와 같이 신경망 입력변수가 $G_s, \gamma_t, \omega_n, \#200$ 통과율인 $I_4H_{30-30}O_1$ 의 구조에서 가장 큰 상관계수를 나타내고 있다. 그리고, 신경망 입력변수가 $G_s, \gamma_t, \omega_n, C_u, \#200$ 통과율인 $I_{5-1}H_{30-30}O_1$ 의 구조에서는 $I_4H_{30-30}O_1$ 의 구조에 균등계수가 추가되어 예측을 수행하였으나, 예측결과는 그림 8-(c)에서 점선내의 결과와 같이 임의 입력 변수값에 대하여 동일하게 나타나고 있어 토량 변화율에 대한 균등계수의 영향성은 다른 영향인자들에 비하여 낮은 것으로 나타났다. 또한, 입력변수의 수가 증가하여도 신경망 예측결과와 시험결과들의 상관계수는 크게 증가하지 않았으며, 입력변수에 균등계수와 곡률계수가 포함되는 $I_{5-1}H_{30-30}O_1$ 와 $I_{5-2}H_{30-30}O_1$ 의 구조에서는 상관계수가 감소하여 나타났다.

이와 같이, 토량 변화율에 대한 이론 산정식이 명확히 제시되지 못하고 있는 실정에서 현장 시료에 대한 실내 다짐시험을 수행하지 않고는 토량 변화율을 산정하기가 곤란하다. 그리고, 변화율은 지반의 물리적 특성과 구조에 따라 다양하게 변화하고 있어 다양한 매개변수를 포함하는 이론식의 정립이 어려운 실정이다. 그러나, 최근에 지반공학 분야에 적용하기 시작한 인공 신경망은 매우 다양한 조건들에 대하여 인간의 뇌와 같은 구조로 연산을 수행함에 따라 본 연구에서와 같은 토량 변화율의 예측에 신경망의 장점을 최대한 이용하여 신경망의 예측결과가 시험결과와 잘 일치하는 결론을 얻을 수 있었다. 그리고 본 연구결과에 의하면, 토량 변화율의 예측은 비중, 자연 함수

비, 자연상태의 습윤단위중량 그리고 #200 통과율의 현장 데이터만으로도 가능하였다.

4. 결론

본 연구에서는 전국 4개 지구의 화장암 풍화토를 연구 대상으로 현장 및 실내시험을 수행하고 토량 변화율을 노상과 노체에 대하여 결정하였다. 그리고, 한국토지공사에서 제안하는 토량 변화율의 산정식을 본 연구결과와 비교 분석하였다. 토량 변화율에 영향을 미치는 인자들의 다양성으로 인하여 명확한 산정 이론식이 없는 실정에서 본 연구에서는 인공 신경망중 오류 역전파 학습 알고리즘을 도입하여 토량 변화율 C 값을 추정하고 신경망의 적용성에 대한 검증을 수행하였다.

본 연구에서 수행한 현장 및 실내시험의 결과와 비교분석 결과에 의한 결론은 다음과 같이 얻어졌다.

- (1) 본 연구에서 사용한 화장암 풍화토에 대한 실내 및 현장시험 결과에서 얻어진 토량 변화율 C 값은 노상과 노체 구분 없이 최소 0.7에서 최대 1.2정도로 건설교통부 표준품셈의 단위중량에 근거하여 제시하는 토량 변화율 C 값들의 범위보다 넓게 나타났다. 국내 지반의 단위중량에 근거하여 토량 변화율을 제시하고 있는 표준품셈의 확실적인 기준은 현장에 적용하기에 다소 부적합한 것으로 사료된다.
- (2) 한국토지공사에서 제안하는 C 값 산정식들 중에서 매개변수를 3개 이상 포함하는 실험식과 본 연구결과와 비교한 결과, 한국토지공사의 산정식에 의한 결과가 과대평가될 가능성이 큰 것으로 나타났다. 이에 본 연구에서는 한국토지공사의 산정식을 보완할 수 있는 실험식을 제안하였다.
- (3) 토량 변화율의 추정을 위하여 도입한 인공 신경망의 학습에서 입력변수의 수를 달리하며 신경망 학습을 수행한 결과, 비중, 자연 함수비, 자연상태의 습윤단위중량, #200 통과율 그리고 균등계수의 입력변수를 갖는 $I_{5-1}H_{30-30}O_1$ 의 신경망에서 다른 신경망 구조들보다 낮은 지역 최소점에 수렴하는 결과를 보였다. 그리고, 신경망의 학습 후 학습결과와 시험결과들의 상관계수는 모두 0.98 이상으로 나타났다.
- (4) 본 연구에서 사용한 모든 신경망 구조에서 시험결과와 신경망 예측결과들의 상관계수는 0.9 이상으로 나타나

높은 상관성을 나타내었다. 그러나, 입력변수에 균등 계수가 포함된 $I_{5-1}H_{30-30}O_{1\omega}$ 의 신경망에서는 임의 입력 변수 값들에 대하여 동일한 예측결과(그림 8-c)를 나타내고 있어 C 값에 대한 균등계수의 영향성은 상당히 낮은 것임을 알 수 있었다. 본 연구결과에 의하면, 인공 신경망에 의한 예측결과는 다양한 영향인자들 중에서 비중, 자연 함수비, 자연상태의 습윤단위중량 그리고 #200 통과율의 4개 변수만으로도 C 값을 예측할 수 있음을 알 수 있었으며, 상관계수는 0.96으로 나타났다.

본 연구 결론들은 국내 일부지역에서 채취한 화강암 풍화토에 대하여 수행한 결론들로서, 보다 많은 시험결과들이 제공된다면 보다 명확한 토양 변화율에 대한 인자들의 영향성과 신경망을 이용한 변화율의 추정이 광범위하게 이루어질 수 있을 것으로 사료된다.

참 고 문 헌

1. 김대수 (1998), 신경망 이론과 응용 (I), 하이테크 정보.
2. 김병탁 (2000a), "비균질 사질토 지반에서 말뚝의 수평거동 연구", 박사학위논문, 경북대학교.
3. 김병탁, 김영수, 이우진 (2000b), "인공신경망을 이용한 모형말뚝의 수평변위와 최대 휨모멘트 예측", 한국지반공학회지, 제16권, 제5호, pp. 169-178.
4. 김병탁, 김영수, 정성관 (2001), "인공신경망 학습속도 개선을 위한 Readjusting 기법의 적용", 한국지반공학회지, 제17권, 제1호, pp.47-56
5. 임안식 (2000), "토양변화율 보정방법 연구", 석사학위논문, 경북대학교.
6. 전인식 (1997), "건설표준품셈", 건설연구사.
7. 한국토지공사 (1994), "설계업무편람", 설계 심사처.
8. 한국토지공사 (1996), "단지조성공사 설계 및 적산기준", 설계처.
9. 한국토지공사 토지연구원 (1995), "공사관리 실무요강", 협성문화사.
10. 한국토지공사 (1996), "현장과 부합되는 토양 변화율 조사에 관한 연구", 토지연구원.
11. Nawari, N. O. and Nusairat, J. (1999), "Artificial intelligence techniques for the design and analysis of deep foundations", *Electronic Journal of Geotech. Eng.*, EJGE, Vol.4.
12. Tasi, C.P. and Lee, T.L. (1999), "Back-propagation neural network in tidal-level forecasting", *ASCE*, Vol.125, No.4, pp.195-202.

(접수일자 2000. 10. 16)