

배후지 지하수위를 고려한 인공신경망 기반의 수평정별 취수량 결정 기법

김규범^{1*} · 오동환²

¹대전대학교 건설안전방재공학과, 교수

²(주)인텔리지오, 대리

Determination of the Groundwater Yield of horizontal wells using an artificial neural network model incorporating riverside groundwater level data

Gyoo-Bum Kim^{1*} · Dong-Hwan Oh²

¹Department of Construction Safety and Disaster Prevention, Daejeon University, Associate Professor

²Intellego Co. Ltd., Assistant Coordinator

Abstract

Recently, concern has arisen regarding the lowering of groundwater levels in the hinterland caused by the development of high-capacity radial collector wells in riverbank filtration areas. In this study, groundwater levels are estimated using Modflow software in relation to the water volume pumped by the radial collector well in Anseongcheon Stream. Using the water volume data, an artificial neural network (ANN) model is developed to determine the amount of water that can be withdrawn while minimizing the reduction of groundwater level. We estimate that increasing the pumping rate of the horizontal well HW-6, which is drilled parallel to the stream direction, is necessary to minimize the reduction of groundwater levels in wells OW-7 and OB-11. We also note that the number of input data and the classification of training and test data affect the results of the ANN model. This type of approach, which supplements ANN modeling with observed data, should contribute to the future groundwater management of hinterland areas.

Keywords: riverbank filtration, radial collector well, artificial neural network, groundwater level, numerical model

OPEN ACCESS

*Corresponding author: Gyoo-Bum Kim
E-mail: geowater@dju.kr

Received: 11 September, 2018

Revised: 12 November, 2018

Accepted: 17 November, 2018

© 2018 The Korean Society of Engineering Geology



This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/4.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

초 록

최근들어 방사형 집수정 방식의 대용량 강변여과수 개발에 따른 배후지의 지하수위 강하에 대한 우려가 존재하고 있다. 본 연구에서는 안성천의 방사형 집수정을 대상으로 Modflow를 활용하여 수평정의 취수량에 따른 배후지의 수위 강하를 예측하였으며, 이 데이터를 기반으로 배후지 수위 강하가 최소가 되는 수평정별 취수량을 결정하는 다층퍼셉트론 기반의 인공신경망 모델을 개발하였다. 하천 방향으로 굴착된 수평정 HW-6의 취수량을 높이는 것이 OW-7 및 OB-11 관측정의 지하수위를 높게 유지하는데 필요한 것으로 평가되었다. 또한, 모델 입력 자료의 수 및 훈련과 검증 자료의 분류는 인공신경망 모델 결과에 영향을 미치므로 유의하여야 한다. 향후 현장의 실제 운영 자료와 수치모델의 비교를 통하여 인공신경망 모델을 보완한다면 배후지의 지하수 관리에 기여할 것으로 본다.

주요어: 강변여과, 방사형집수정, 인공신경망, 지하수위, 수치모델

서론

1990년대 후반 이후 국내의 강변여과수 개발이 활발히 추진되었으나, 최근에는 대용량 취수에 따른 배후지의 수위 강하 및 철/망간과 같은 수질 문제로 인하여 개발에 대한 우려의 목소리가 존재하고 있다. 강변여과수 개발은 지표수에 비하여 수질 측면에서 유리하고 수량 측면에서도 풍부한 장점을 갖고 있음에도 불구하고 현장의 다양한 민원 등은 수원 개발의 제약점으로 대두되고 있다.

방사형 집수정 등 강변여과수 시설은 장기간 운영시 하천 바닥층의 클로킹, 우물 자재의 노후화, 수평정 주변 여재의 변화 등 다양한 이유로 인하여 취수량이 변화하게 된다. 이와 같이 장기 운영시 취수량의 변화는 개별 수평정의 취수 능력에도 영향을 미치게 되고 배후지의 지하수위에도 변화가 발생된다. 방사형 집수정의 개발 초기에는 Modflow 등의 수치모델을 활용하여 취수량을 평가하게 되고 이로부터 배후지의 수위 강하량을 진단하게 된다. 그러나, 방사형 집수정의 장기간 운영 이후에는 각 수평정별 취수량 감소의 원인을 파악하는 것이 용이하지 않고 기 구축된 수치모델도 변화된 대수층 환경을 제대로 반영하지 못할 수 있기 때문에 배후지의 수위 강하를 재평가하는 것이 용이하지 않다.

최근에 인공신경망을 활용한 지하수위의 변화 및 분포 예측에 대한 연구가 활발히 이루어져 왔다 (Daliakopoulos et al., 2005; Adamowski and Chan, 2011; Devarajan and Sindhu, 2015; Kisi et al., 2017). 또한 강변여과수의 수질 개선 및 오염원 저감 효과를 인공신경망을 활용하여 평가한 바 있으며 (Sahoo et al., 2005), 강변의 지하수 함양시 장기간의 지하수위 변화를 인공신경망을 활용하여 예측한 바 있으나 (Shamsuddin et al., 2017), 강변여과수 지역에서의 지하수 취수시 배후지의 지하수위 예측에 대한 인공신경망 연구는 거의 수행된 바 없다.

본 연구에서는 지하수 수치모델을 활용하여 도출된 수평정의 취수량 조건별 배후지의 지하수위 자료를 토대로 인공신경망 기법을 활용한 배후지 지하수위 예측을 수행하였으며, 이를 활용하여 배후지의 지하수위 강하를 최소화할 수 있는 각 수평정의 취수량을 결정하는 방안을 제시하고자 하였다.

연구지역

연구지역은 경기도 안성시 안성천 중류지역으로서 기반암은 선캠브리아기의 흑운모 편마암과 이를 관입한 쥐라기의 흑운모 화강암이 분포하고 있으며, 충적층의 두께가 6.0~9.9 m 정도로서 하부로부터 풍화토, 자갈질 모래, 실트질 모래, 점토질 실트로 구성되어 있다 (Fig. 1; Kim et al., 2016). 연구지역의 연평균 강우량은 평택시 진위면사무소내 관측소의 과거 10년 평균 강우량인 1,268 mm이며, 지하수 함양률은 약 13.54%로서 172 mm/y에 해당한다(MOCT, 2007).

7개의 수평정을 갖는 1기의 방사형 집수정이 설치되어 있으며, 수평정의 평균 길이는 약 37.7 m, 수평정의 구경은 20 cm에 해당한다(Table 1). 지층 분포를 보면, 상부로부터 약 4 m는 실트와 점토가 우세한 실트질 모래, 약 6 m까지는 투수

Table 1. Specifications of the radial collector well and hydraulic features of the aquifer

Site	Number of horizontal well	Average length of horizontal well (m)	Thickness of aquifer (m)	Diameter of horizontal well (m)	Height to horizontal well from bottom (m)	Average hydraulic conductivity (m/d)	Average transmissivity (m ² /d)
Anseong	7	37.7	6.0	0.2	0.8	41.22	289.0

성이 좋은 자갈섞인 모래층이 분포하며 하부는 풍화암이 존재한다.

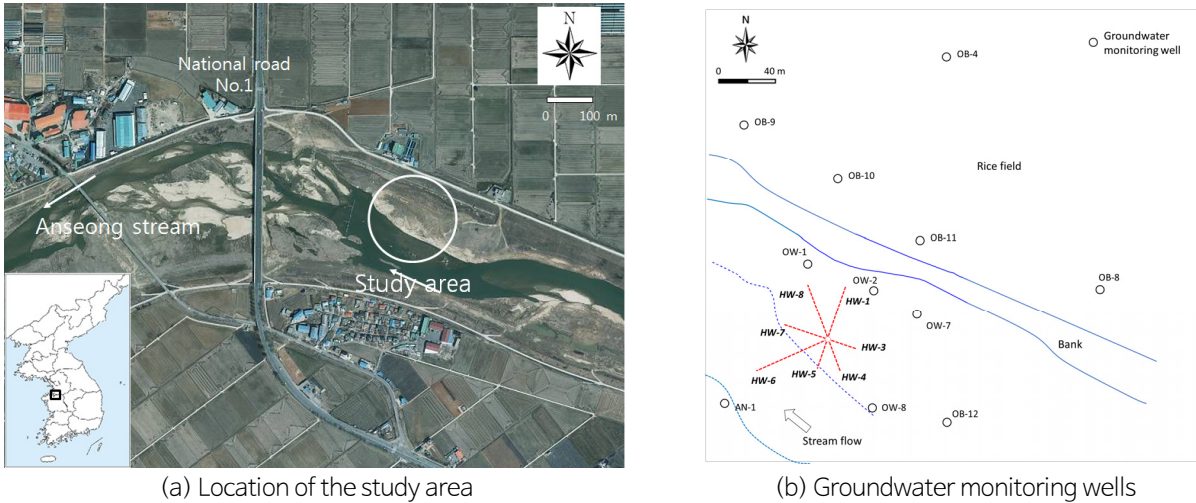


Fig. 1. (a) Location of the study area and (b) location of the radial collector well and groundwater-monitoring wells (adapted from Kim et al., 2016).

수치모델 분석

방사형 집수정의 수평정별 취수량 조건을 적용하여 배후지의 지하수위를 예측하기 위하여 Modflow를 활용한 지하수 모델링을 수행하였다. 지층의 수직 분포는 3개의 layer로 구성하였는데 하부로부터 연암, 풍화암, 충적층 등이며, 지층별 수리전도도는 기존 양수시험 및 투수시험 결과를 활용하여 구역화 하였다. 하상 구간의 충적층은 $9.00 \times 10^{-2} \sim 1.00 \times 10^{-3}$ cm/sec, 주변의 충적층은 9.90×10^{-3} cm/sec, 풍화암은 7.00×10^{-4} cm/sec, 연암은 3.60×10^{-5} cm/sec를 적용하였다 (Fig. 2). 모델 영역은 방사형 집수정이 포함되도록 1.2×1.2 km로 설정하였으며, 전반적인 격자 크기는 10×10 m, 방사형 집수정 인근은 2×2 m로 조밀하게 구성하였다.

모델의 보정은 강변여과수 개발시 4개 수평정(HW3, HW5, HW7, HW8)의 취수량(총 취수량: $4,000 \text{ m}^3/\text{d}$)을 실측한 바 있으며 이 때의 배후지 지하수위 측정 자료를 활용하여 비교 검증하였다 (Fig. 2d). 실측 지하수위를 활용한 모델 보정 결과, RMSE(Root mean square error)가 0.24 m, Normalized RMSE가 7.52%로 나타났으며, 이 때의 4개 수평정별 실제 취수량과 모델 취수량의 차이는 2 ~ $68 \text{ m}^3/\text{d}$ 의 범위내에 있었으며, 0.57 ~ 8.02%의 오차를 나타내었다.

이상 구축된 정류 모델을 활용하여 수평정별 취수량에 변화를 주면서 부정류 모델을 수행하였다. 모델상의 총 취수량은 개략적으로 $4,000 \text{ m}^3/\text{d}$ 및 $5,000 \text{ m}^3/\text{d}$ 이 되도록 설정하였으며, 수평정의 취수량을 조절함에 따른 주변 지하수 관측정의 지하수위를 예측하였다(Table 2).

총 취수량 $4,000 \text{ m}^3/\text{d}$ 및 $5,000 \text{ m}^3/\text{d}$ 에 대하여 각각 5가지 경우를 가정하였으며, 일부 수평정(HW-1, HW-4, HW-6, HW-8)의 경우에는 최대 취수가능량에서부터 0 값까지 범위를 갖도록 취수량을 조정하였다. 각 조건에 대한 지하수위 예측 결과, 제내지에서는 지하수위 평균이 4.2 ~ 6.0 El.m, 제외지에서는 3.2 ~ 4.6 El.m의 범위를 나타내고 있어 취수에 의한 지하수위 강하를 보여주고 있다.

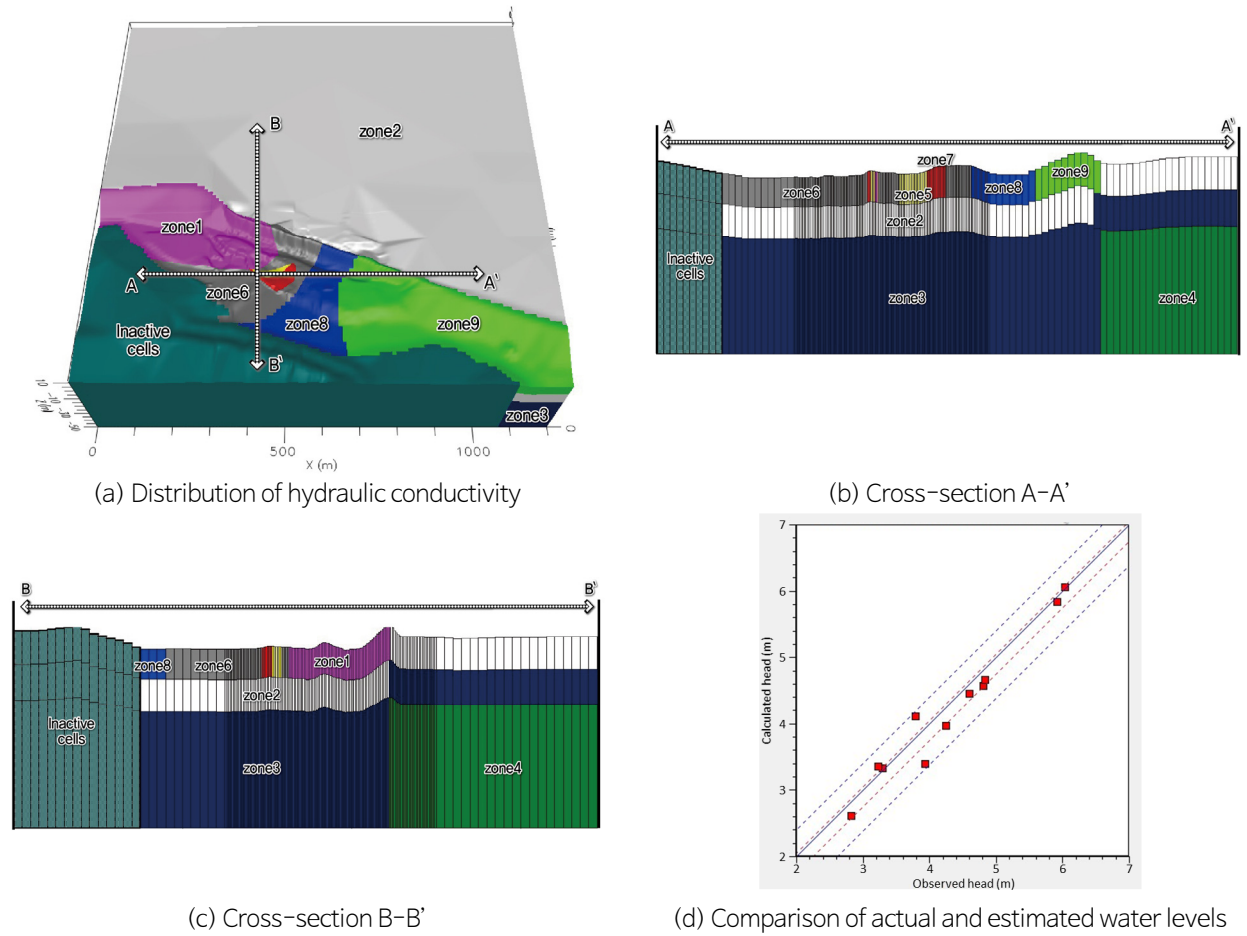


Fig. 2. Design of the numerical model and comparison of actual and estimated water levels.

Table 2. Simulation results for collector well pumping and the numerically estimated groundwater levels for the monitored wells

(a) Simulation cases of pumping rate

Case	Total pumping rate (m ³ /d)	Simulation condition (m ³ /d)						
		HW-1	HW-3	HW-4	HW-5	HW-6	HW-7	HW-8
1	4,045.1	637.9	301.2	292.2	330.5	1,192.8	577.8	712.7
2	4,031.6	0.0	366.9	341.2	378.7	1,382.8	684.9	877.1
3	4,019.7	683.2	340.3	0.0	355.4	1,266.7	616.3	757.8
4	4,037.8	816.5	389.1	355.7	452.2	300.9	792.9	930.3
5	4,020.6	715.9	330.4	314.9	356.3	1,298.4	643.7	361.1
6	5,011.2	381.6	401.6	353.5	437.6	1,685.2	775.1	976.7
7	5,010.1	1,029.2	504.3	406.3	693.1	0.0	1,157.9	1,219.4
8	5,021.4	979.2	470.8	391.1	607.1	399.9	1,031.6	1,141.7
9	5,002.2	843.9	396.9	349.7	466.7	1,176.7	807.6	960.7
10	5,014.3	994.5	432.7	374.4	471.4	1,846.5	894.8	0.0

Table 2. Simulation results for collector well pumping and the numerically estimated groundwater levels for the monitored wells (Continued)

(b) Estimation of groundwater levels at each monitoring well by using a numerical model.

Case	Estimated groundwater level (El.m)										
	AN-1	OW-1	OW-2	OW-7	OW-8	OB-4	OB-8	OB-9	OB-10	OB-11	OB-12
1	4.4447	3.5495	3.4399	4.1547	4.6808	6.0358	5.6653	4.9936	4.6907	4.3123	4.6664
2	4.4430	3.6814	3.6533	4.2066	4.6946	6.0590	5.6764	5.0212	4.7552	4.3968	4.6800
3	4.4445	3.5484	3.4744	4.1693	4.6873	6.0359	5.6653	4.9928	4.6921	4.3224	4.6701
4	4.4493	3.2876	3.1353	4.0549	4.6498	5.9969	5.6440	4.9464	4.5890	4.1818	4.6396
5	4.4440	3.6402	3.4765	4.1603	4.6808	6.0356	5.6639	5.0001	4.7101	4.3312	4.6666
6	4.4345	3.3048	3.2141	4.0699	4.6492	6.0031	5.6476	4.9525	4.6072	4.2119	4.6414
7	4.4453	2.6771	2.4691	3.7857	4.5764	5.8925	5.5845	4.8266	4.3376	3.8551	4.5732
8	4.4436	2.8401	2.6495	3.8711	4.5972	5.9457	5.6182	4.8761	4.4279	3.9643	4.5938
9	4.4390	3.1074	2.9477	3.9879	4.6270	5.9860	5.6406	4.9249	4.5304	4.1030	4.6204
10	4.4325	3.4558	3.1672	4.0580	4.6439	6.0174	5.6553	4.9711	4.6311	4.2118	4.6373
Ave.	4.4420	3.3092	3.1627	4.0518	4.6487	6.0008	5.6461	4.9505	4.5971	4.1891	4.6389

다층퍼셉트론을 활용한 인공신경망 모델 구축

인공신경망은 시냅스의 결합으로 네트워크를 형성한 뉴런(노드)이 학습을 통하여 시냅스의 결합 세기를 변화시키면서 문제를 풀어가는 모델을 의미하는 것으로서, 함수 추론, 회귀 분석, 시계열 예측, 근사 모델링, 패턴 인식, 클러스터링 등 다양한 분야에 활용되고 있다(Zakaria et al., 2014).

인공신경망은 입력층(Input layer), 은닉층(Hidden layer) 및 출력층(Output layer)으로 구성되어 있으며, 각 층간의 뉴런의 연결강도를 최적의 상태로 적응하는 과정을 말한다(Fig. 3). 본 연구에서는 역전파알고리즘을 이용하는 다층 퍼셉트론(Multilayer perceptron) 신경망 네트워크 기법을 적용하였으며, 입력변수로서 각 수평정별 취수량 및 총취수량을 사용하고 출력변수는 지하수 관측정의 지하수위를 적용하였다. 출력 뉴런에 의하여 절단되는 은닉층의 출력은 아래 식과 같이 각 시냅스의 가중치 (w_{ij})와 노드의 입력자료 (x_j)에 의하여 결정된다.




Fig. 3. Multilayer perceptron concept of an artificial neural network with a hidden layer.

$$t_j = g\left(\sum w_{ij}x_i\right) \quad (1)$$

또한 출력층에서 출력값 (y_k)는 시냅스의 가중치와 은닉층 및 출력층에서의 활성화 함수 (g 및 \bar{g})에 의하여 결정된다.

$$y_k = \bar{g}\left(\sum_{j=0}^n w_{kj} \cdot g\left(\sum_{i=0}^m w_{ij}x_i\right)\right) \quad (2)$$

각 수평정별 취수량은 그 범위가 상이하므로 인공신경망 모델 구축을 위하여 취수량 자료를 정규화 변환을 실시하였으며, 10개의 경우 중에서 70%는 훈련자료, 30%는 검증자료로 활용하였다. 한편, 모든 지하수 관측정을 종속변수로 활용이 가능하나, 본 연구에서는 방사형 집수정의 북동 방향의 지하수위를 파악하는 것을 일차적인 목표로 설정하여 OW-7 및 OB-11을 주변지역 지하수위에 대한 기준 지점으로 설정하여 종속변수로 채택하였다.

모델의 은닉층은 1개로 설정하고 은닉층의 활성화 함수는 쌍곡탄젠트 함수를 적용하였다. 모델 구축 결과 은닉층의 노드는 6개, 출력층의 노드는 2개로 나타났다. 구축된 모델의 학습자료의 오차제곱합(SSE: Sum squared error)은 0.004로 매우 낮으며 검증자료는 0.137로 약간 높아 과적합의 가능성이 존재하나, 10개 모든 자료에 대한 실제값과 예측값의 Pearson 상관계수는 0.01 유의수준하에서 OW-7은 0.997, OB-11은 0.993으로 매우 높아 본 모델을 채택하였다(Fig. 4).

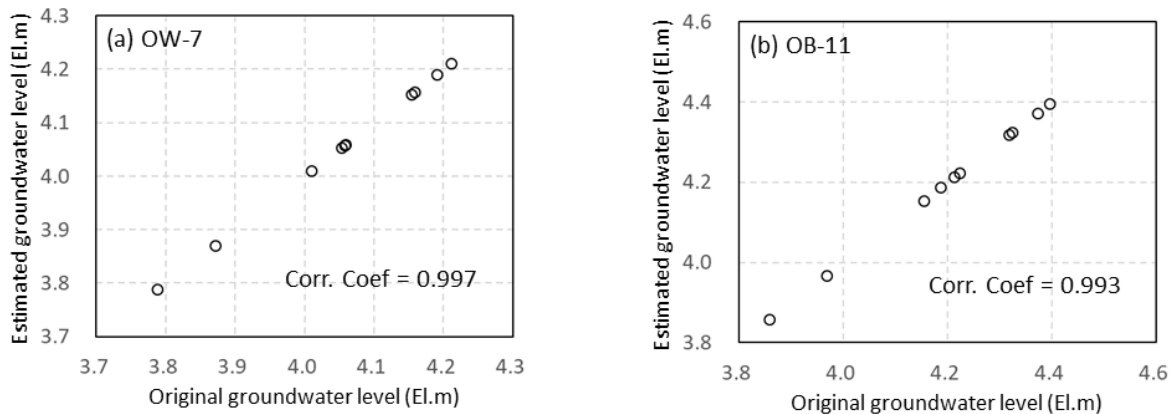


Fig. 4. Scatterplots of original versus estimated groundwater levels at the two monitoring wells.

배후지 수위 영향 최소를 위한 취수량 결정 방안

상기 모델을 기반으로 다양한 수평정 취수조건을 적용하여 주변 관측정인 OW-7 및 OB-11의 지하수위를 높게 유지할 수 있는 경우를 도출하였다. 이를 위하여 각 수평정별 취수 조건을 $0 \text{ m}^3/\text{d}$ 에서부터 최대 취수량까지 무작위 값을 부여하여 입력 자료를 생성하였으며 방사형 집수정의 총취수량이 동일하게 $4,000 \text{ m}^3/\text{d}$ 이 되도록 조정하여 최종적으로 52가지의 수평정 취수 조건에 대하여 2개 지점의 지하수위를 예측해 보았다(Fig. 5).

이들 전체 모사 결과 중에서 지하수위가 높거나 낮은 각각 3개의 경우를 비교해 보았다(Table 3). 2개 관측정의 지하수위가 높은 경우(Case 9, 19, 21)와 낮은 경우(Case 8, 16, 22)를 비교해 보면, 하천 유로 방향으로 굴착되어 있는 HW-6 수평정의 취수량이 2개 관측정의 지하수위에 가장 큰 영향을 미치는 것으로 나타났다. 즉, 총량이 일정하다면, 하천 방향으

로 굴착되어 있는 수평정에서의 취수 비율이 높은 경우에 주변 2개 관측 지점의 지하수위는 높게 형성되어 지하수위 강하가 상대적으로 적음을 보여준다. 또한, HW-6 수평정의 취수량의 변화 폭이 상대적으로 크기 때문에 지하수위 변화의 폭도 크게 나타난다. 이와 같은 예측 결과는 Modflow에 의한 수치 모델 결과의 7 번 및 8 번의 경우와도 유사한 것으로 보인다(Table 2 참조). 2개 관측정의 지하수위가 낮게 형성되는 경우는 제방측으로 굴착되어 있는 HW-1, HW-3 및 HW-8의 취수 총량이 많은 경우에 나타나는 현상으로 보이나, 이는 대수층의 수리전도도의 분포 등 보다 복잡한 요인에 의하여 결정되는 것으로 보인다. 궁극적으로 연구지역 방사형 집수정을 52가지 경우의 수 중에서 운영 방법을 결정한다면, OW-7 수위를 가장 높게 유지하기 위해서는 19번의 취수 조건, OB-11 수위를 가장 높게 유지하기 위해서는 21번의 취수 조건으로 운영하는 것을 제안할 수 있다.




Fig. 5. Simulation results for 52 cases of the pumping rate of a collector well for the two monitoring wells.

Table 3. Representative cases of groundwater level estimation using the ANN model

Contents	Case No.	HW-1	HW-3	HW-4	HW-5	HW-6	HW-7	HW-8	OW-7	OB-11
Average of 52 cases	-	440.4	297.1	291.3	455.1	1104.0	629.1	783.2	-	-
High level cases	9	390.5	225.3	371.6	79.8	1,385.7	1,065.1	482.2	4.2623	4.4373
	19	372.7	386.6	449.4	162.3	1,002.4	457.9	1,168.8	4.2827	4.4543
	21	239.7	403.9	141.9	113.9	1,343.6	913.2	843.8	4.2395	4.4580
Low level cases	8	485.7	455.5	186.6	792.7	477.3	654.1	948.2	3.8560	3.9766
	16	758.0	161.9	154.6	668.8	685.5	1,271.1	300.2	3.8682	3.9855
	22	408.2	256.5	159.0	735.5	657.3	704.2	1,079.3	3.8871	4.0022

토의

수평정별 취수량 및 총 취수량과 두 지점의 지하수위 관계(특히, HW-6, HW-8 및 총취수량과 OW-7 및 OB-11과의 상관성)를 보면, 각 인자간 선형 관계가 약하여 다중선형회귀 분석에 의해서는 지하수위에 대한 모든 수평정의 영향 모형을 구축할 수 없다(Fig. 6). 이와 같은 경우에 인공신경망 모형이 적절한 해법이 될 수 있다. 다만, 인공신경망 모델은 수학적 수식에 의하여 설명되지 못하는 한계점을 갖고 있기 때문에 그 적용성에 대한 추가적인 검토가 필요하다.

인공신경망의 적용을 위해서는 훈련 및 검증 자료가 많을수록 보다 정확한 예측 모델을 만들 가능성이 높아지는데, 본 연구에서는 10 가지의 수평정 취수 조건을 적용하였으므로 이보다 작은 경우에 대하여 적용성을 진단해 보았다. 이를 위하여 9 가지, 8 가지 및 5 가지의 취수 조건을 생성하여 인공신경망 분석을 실시하였다. Table 2의 조건에서 5번을 제외한 9개 조건인 경우(Case 1), 5번 및 16번을 제외한 8개 조건인 경우(Case 2), 2번, 5번, 13번, 14번, 16번을 제외한 5개 조건

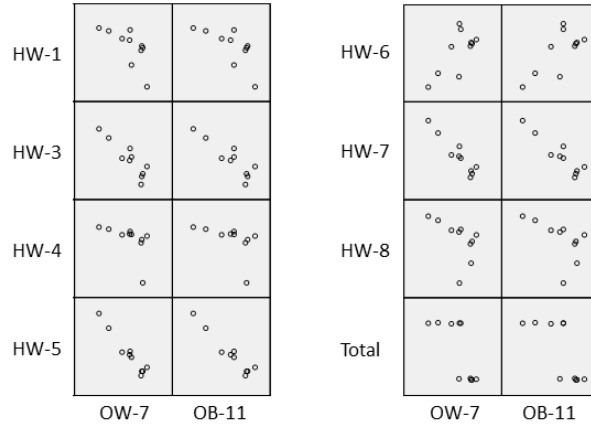


Fig. 6. Scatterplots of horizontal well yields (y-axis) versus groundwater levels (x-axis).

인 경우(Case 3)을 설정하였다.

각 Case별 자료를 활용하여 구축된 인공신경망 모델의 특성 및 구조는 Table 4와 같다. Case 1과 Case 2는 당초 인공신경망 모델의 통계값 및 구조와 비교적 유사한 경향을 보이고 있으나, Case 3은 차이를 나타내고 있다. Case 3의 훈련 및 검증 자료 전체에 대한 Pearson 상관계수가 0.9 이하로 낮아져 모델의 정확성도 떨어졌다. 또한, 입력 및 검증용으로 사용되는 자료의 수가 작은 Case 3의 경우에는 지하수위의 상대적인 차이가 뚜렷하지 않아 표준편차가 작으며 실제 데이터와 상이한 경우가 많이 나타났다(Table 5, Fig. 7). 이는 인공신경망 모델은 훈련 과정에 포함되는 데이터의 영향을 받기 때문인데, 훈련 자료가 작다는 것은 실제 현장의 취수량별 조건의 일부만 반영될 수 있으므로 최적 모델을 도출하는데 한계가 있다.

Table 4. Characteristics and structure of the ANN models for the three cases

Case	Hidden layer			Output layer		SSE	Pearson corr. coef.	
	No. of layer	Activation function	No. of node	Activation function	No. of node		OW-7	OB-11
1	1	Hyperbolic tangent function	6	Identity function	2	0.006	0.997	0.996
2	1	Hyperbolic tangent function	6	Identity function	2	0.004	0.995	0.998
3	1	Hyperbolic tangent function	6	Identity function	2	0.025	0.896	0.897

Table 5. Statistics of estimated groundwater levels at two monitored wells

Case	Wells	Average level (El.m)	Standard deviation (m)
Original model	OW-7	4.10	0.11
	OB-11	4.26	0.14
Case 1	OW-7	4.12	0.11
	OB-11	4.27	0.13
Case 2	OW-7	4.13	0.07
	OB-11	4.29	0.09
Case 3	OW-7	4.16	0.02
	OB-11	4.32	0.03

이상 예측된 지하수위를 도시해 보면, 당초 모델의 예측 결과와 Case 1, Case 2는 비교적 유사한 경향을 보이나, Case 3은 유사성을 설명하기에는 시각적으로 부족해 보인다(Fig. 5 및 Fig. 7 참조). Case 1과 Case 2는 당초 신경망 모델과 유사하게 지하수위의 높고 낮은 경우가 비교적 잘 일치하고 각 경우별로 지하수위 차이도 잘 나타나고 있으나, Case 3은 나머지 경우와 반대로 나타나는 지하수위도 존재하고 있는 등 모델의 적용성이 낮음을 알 수 있다.

인공신경망은 훈련자료의 선택이 중요한데, 충분한 갯수의 수평정별 취수 조건을 확보하였다고 하더라도 훈련 자료를 선택하는 것에 유의하여야 한다. 각 수평정별로 실제 운영조건에 맞는 최저 취수량과 최고 취수량의 범위를 파악하여 이들이 훈련자료의 범위에 반영될 수 있도록 하는 것이 우수한 예측 모델 개발에 도움이 될 것이다. 한편, 훈련 및 검증 자료의 갯수가 제한적인 경우에는 훈련자료에 포함된 수평정별 취수량 조건에 따라 모델 결과가 달라질 수 있으므로 훈련자료 선정에 특히 유의할 필요가 있다.

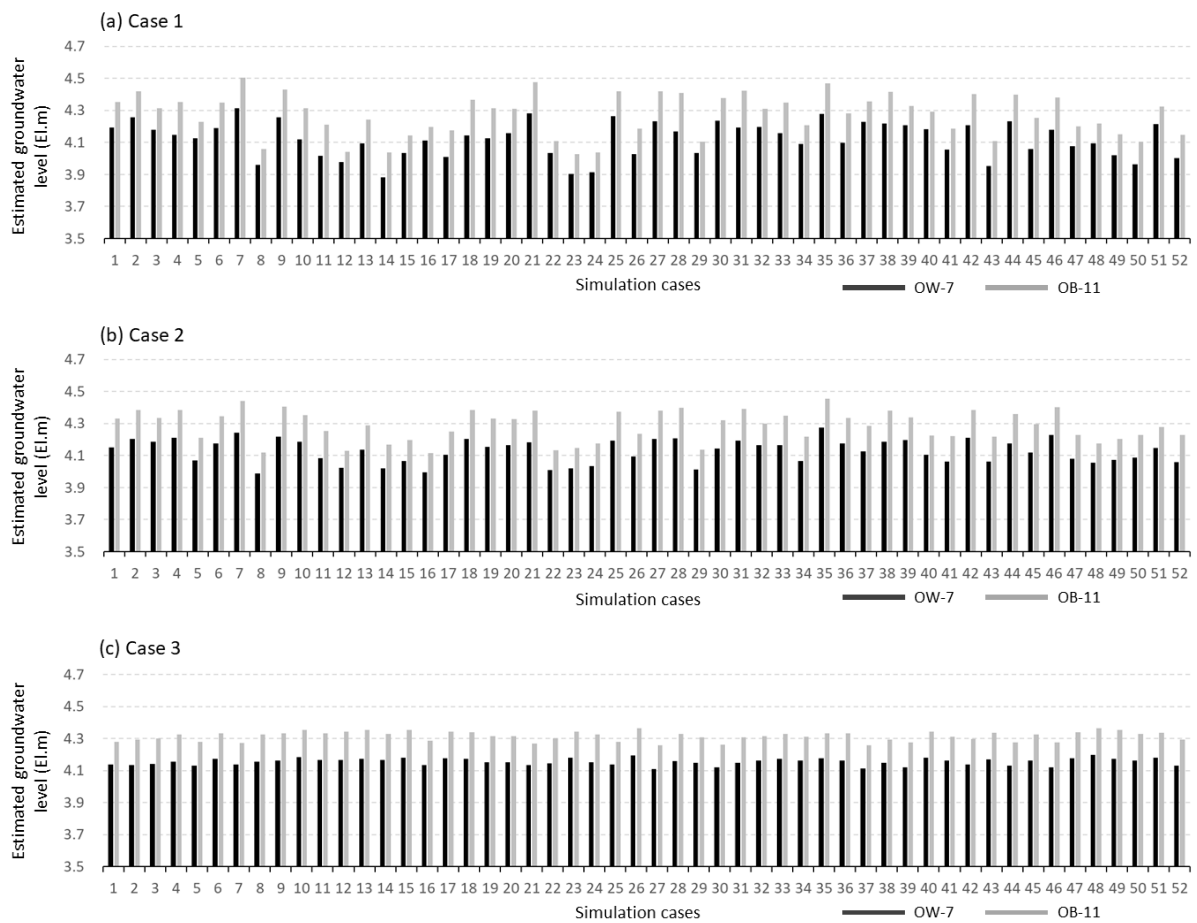


Fig. 7. Estimations of groundwater level at the two monitoring wells for three cases: (1) Case 1, nine data points; (2) Case 2, eight data points; and (3) Case 3, five data points.

결언

다수의 입력변수와 종속변수가 선형 관계를 보이지 않는 경우에는 회귀모델에 의한 모델 구축이 어려우므로 인공신경망을 활용한 모델 개발이 적합하다. 강변여과수 개발과 같이 대수층의 수리전도도가 공간적으로 다양하고, 수평정의 취수

량이 각기 다른 조건을 갖는 경우에는 수평정별 취수량과 주변의 지하수위로부터 인공신경망 모델을 구축한다면, 현장에서 발생하는 취수에 의한 지하수위 강하 등 다양한 문제점을 진단할 수 있을 것이다.

본 연구에서 다층퍼셉트론의 인공신경망을 활용하여 방사형집수정의 취수시 주변지역 지하수위를 예측한 결과, 일정 수량의 훈련 자료를 확보하고 있다면 적용성 높은 인공신경망 모델 개발이 가능할 것으로 평가되었다. 또한, 본 연구는 현장의 수리지질학적 특성이 수치 모델에 충분히 반영되었음을 전제로 수치모델상에서 지하수위를 추출하여 인공신경망 모델의 입력 및 출력 자료로 활용한 것이므로, 향후 실제 현장에서의 운영 자료 및 지하수위 자료를 확보하여 수치모델과 비교하고 추가적인 인공신경망 모델을 개발한다면 현장 특성을 충분히 반영한 모델이 확보될 것이다. 또한, 이를 통하여 배후지의 지하수위 강하 또는 고갈을 억제할 수 있는 수평정별 취수 조건을 찾음으로써 주변 영향을 최소화할 수 있는 수 자원 확보가 가능할 것으로 기대된다.

사사

본 연구는 국토교통부가 출연하고 국토교통과학기술진흥원에서 위탁 시행한 2018년 국토교통기술촉진연구사업의 연구비 지원(과제번호 18CTAP-C130215-02)에 의해 수행되었습니다.

References

- Adamowski, J. and Chan, H.F., 2011, A wavelet neural network conjunction model for groundwater level forecasting, *Journal of Hydrology*, 407(1-4), 28-40.
- Daliakopoulos, I. N., Coulibaly, P., and Tsanis, I. K., 2005, Groundwater level forecasting using artificial neural networks, *Journal of Hydrology*, 309(1-4), 229-240.
- Devarajan, K. and Sindhu, G., 2015, Application of numerical and empirical models for groundwater level forecasting, *International Journal of Research in Engineering and Technology*, 4(11), 127-133.
- Kim, T. H., Lee, C. H., Lee, J. H., Oh, D. H., and Kim, G. B., 2016, Estimation of groundwater yield at a horizontal well using soil characteristics at riverbank filtration site, *Journal of the Geological Society of Korea*, 52(3), 291-301 (in Korean with English abstract).
- Kisi, O., Alizamir, M., and Zounemat-Kermani, M., 2017, Modeling groundwater fluctuaitons by three different evolutionaly neural network techniques using hydroclimatic data, *Natural Hazards*, 87(1), 367-381.
- MOCT (Ministry of Construction and Transportation), 2007, National Master Plan of Groundwater Management, Seoul, Korea.
- Sahoo, G. B., Ray, C., Wang, J. Z., Hubbs, S. T., Song, R., Jasperse, J., and Seymour, D., 2005, Use of artificial neural networks to evaluate the effectiveness of riverbank filtration, *Water Research*, 39(12), 2505-2516.
- Shamsuddin, M. K. N., Kusin, F. M., Sulaiman, W. N. A., Ramli, M. F., Baharuddin, M. F. T., and Adnan, M. S., 2017, Forecasting of groundwater level using artificial neural network by incorporating river recharge and river bank infiltration, *MATEC Web Conference*, 103, DOI: <https://doi.org/10.1051/matecconf/201710304007>.
- Zakaria, M., Al-Shebany, M., and Sarhan, S., 2014, Artificial neural network: a brief review, *International Journal of Engineering Research and Applications*, 4(2), 7-12.