



**ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ**

**ΔΙΑΤΜΗΜΑΤΙΚΟ – ΔΙΕΠΙΣΤΗΜΟΝΙΚΟ ΠΡΟΓΡΑΜΜΑ  
ΜΕΤΑΠΤΥΧΙΑΚΩΝ ΣΠΟΥΔΩΝ**

**«ΕΠΙΣΤΗΜΗ ΚΑΙ ΤΕΧΝΟΛΟΓΙΑ ΥΔΑΤΙΚΩΝ ΠΟΡΩΝ»**

**ΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΩΣ  
ΥΠΟΚΑΤΑΣΤΑΤΑ ΜΟΝΤΕΛΑ ΓΙΑ ΤΗΝ  
ΠΡΟΣΟΜΟΙΩΣΗ ΥΒΡΙΔΙΚΙΟΥ  
ΣΥΣΤΗΜΑΤΟΣ ΝΕΡΟΥ ΚΑΙ ΕΝΕΡΓΕΙΑΣ**

**Ιωάννα Ανυφαντή**

**Επιβλέπων: Ανδρέας Ευστρατιάδης, ΕΔΙΠ ΕΜΠ**

**«ΕΠΙΣΤΗΜΗ &  
ΤΕΧΝΟΛΟΓΙΑ  
ΥΔΑΤΙΚΩΝ  
ΠΟΡΩΝ»**

**Αθήνα, Οκτώβριος 2018**



## Πρόλογος

Με την παρούσα διπλωματική εργασία ολοκληρώνεται ο κύκλος σπουδών μου στο μεταπτυχιακό πρόγραμμα «Επιστήμη και Τεχνολογία Υδατικών Πόρων». Επομένως, στο σημείο αυτό θα ήθελα να ευχαριστήσω ορισμένα άτομα τα οποία είχαν καθοριστικό ρόλο κατά τη διάρκεια του παραπάνω προγράμματος.

Πρώτα από όλους, θα ήθελα να ευχαριστήσω τον Δρ. Πολιτικό Μηχανικό Ανδρέα Ευστρατιάδη, ΕΔΙΠ ΕΜΠ, ως επιβλέποντα της παρούσας Διπλωματικής Εργασίας, για την εμπιστοσύνη που μου έδειξε και την ευκαιρία που μου έδωσε να ασχοληθώ με το συγκεκριμένο θέμα.

Θα ήθελα, επίσης, να ευχαριστήσω την κ. Αικατερίνη Νάνου, Επίκουρη Καθηγήτρια ΕΜΠ, και τον κ. Χρήστο Μακρόπουλο, Αναπληρωτή Καθηγητή ΕΜΠ, ως μέλη της εξεταστικής επιτροπής για τη συγκεκριμένη διπλωματική εργασία, αλλά και για το διδακτικό τους έργο κατά τη διάρκεια φοίτησής μου στο μεταπτυχιακό πρόγραμμα.

Ακόμη, θα ήθελα να ευχαριστήσω τον κ. Δημήτρη Κουτσογιάννη, Καθηγητή ΕΜΠ και Κοσμήτορα της Σχολής Πολιτικών Μηχανικών, τον οποίο γνώρισα από τη διδασκαλία του στα μαθήματα του προγράμματος, για την «τροφή για σκέψη», την προτροπή για ενασχόληση αναφορικά με πολλά επιστημονικά θέματα και την ενθάρρυνση που παρέχει.

Θα ήταν μεγάλη μου παράλειψη να μην ευχαριστήσω τον κ. Νίκο Μαμάση, Αναπληρωτή Καθηγητή ΕΜΠ, για την παροχή των απαραίτητων δεδομένων, αλλά και τον Δρ. Παναγιώτη Δημητριάδη, καθώς και τους υποψήφιους διδάκτορες Άνυ Ηλιοπούλου, Γιάννη Τσουκαλά και Διονύση Νικολόπουλο για την ενθάρρυνση και τις εποικοδομητικές παρατηρήσεις τους.

Επίσης, θα ήθελα να ευχαριστήσω τους καθηγητές του προγράμματος που παρακολούθησα για τη δυνατότητα που μου έδωσαν να διευρύνω το πεδίο των γνώσεών μου, καθώς και όλους τους φοιτητές, μέλη της ερευνητικής ομάδας «Ιτιά», για τις ευχάριστες ώρες εργασίας στο κτήριο Π. Σαντορίνη.

Κλείνοντας, το μεγαλύτερο ευχαριστώ οφείλω στην οικογένειά μου, στις φίλες και στους φίλους μου, συνολικά και ξεχωριστά προς τον καθένα, για την εμπιστοσύνη που δείχνουν στο πρόσωπό μου, την υποστήριξη και την ουσιαστική ηθική συμπαράσταση που μου παρέχουν συνεχώς.



## Περιεχόμενα

Πρόλογος.....	3
Περιεχόμενα.....	5
Περίληψη.....	9
Extended abstract.....	11
1. Introduction.....	11
2. Case study.....	12
3. Input Data.....	13
4. Outline of Methodology.....	13
5. Analytical Simulation Models.....	14
6. Results.....	17
7. Conclusions.....	20
<b>1. Εισαγωγή.....</b>	<b>23</b>
<b>1.1 Τοποθέτηση του προβλήματος.....</b>	<b>23</b>
<b>1.2 Διάρθρωση της εργασίας.....</b>	<b>24</b>
2. Η έννοια των υποκατάστατων μοντέλων.....	26
2.1 Γενικά εισαγωγικά στοιχεία.....	26
2.1.1 Αξιολόγηση μεταμοντέλων.....	28
2.2 Υποκατάστατα χαμηλότερης πιστότητας (Lower Fidelity Surrogates).....	30
2.3 Τα υποκατάστατα επιφάνειας απόκρισης (Response Surface Surrogates).....	32
2.4 Εφαρμογές στους υδατικούς πόρους.....	33
3. Νευρωνικά Δίκτυα.....	36
3.1 Ορισμός των τεχνητών νευρωνικών δικτύων.....	36
3.2 Πλαίσιο ανάπτυξης τεχνητών νευρωνικών δικτύων.....	37
3.2.1 Νευρώνες και επίπεδα.....	38
3.2.2 Κατάσταση ενεργοποίησης.....	38
3.2.3 Συνάρτηση εξόδου νευρώνα.....	38
3.2.4 Πρότυπο σύνδεσης.....	39
3.2.5 Κανόνας διάδοσης.....	40
3.2.6 Κανόνας ενεργοποίησης.....	40
3.2.7 Η διαδικασία εκμάθησης – εκπαίδευσης.....	41
3.2.8 Περιβάλλον λειτουργίας νευρωνικών δικτύων.....	44
3.3 Πλεονεκτήματα και μειονεκτήματα νευρωνικών δικτύων.....	45
3.4 Τα τεχνητά νευρωνικά δίκτυα ως υποκατάστατα μοντέλα.....	49

3.5	Τα νευρωνικά δίκτυα στο περιβάλλον MATLAB .....	54
3.5.1	Ο αλγόριθμος Levenberg-Marquardt.....	55
3.5.2	Ο αλγόριθμος Bayesian Regularization .....	56
4.	Προσομοίωση υποθετικού υβριδικού συστήματος της Αστυπάλαιας.....	57
4.1	Βασικά στοιχεία υβριδικών συστημάτων .....	57
4.2	Περιοχή μελέτης.....	60
4.2.1	Υπάρχουσα κατάσταση .....	60
4.2.2	Το υποθετικό υβριδικό σύστημα .....	62
4.3	Μεθοδολογία .....	62
4.3.1	Ευρύτερο μεθοδολογικό πλαίσιο αντιμετώπισης του προβλήματος.....	62
4.3.2	Αναλυτική προσομοίωση του συστήματος.....	67
4.4	Δεδομένα εισόδου .....	73
4.4.1	Εισροές στο σύστημα .....	74
4.4.2	Ζητήσεις.....	76
4.5	Αποτελέσματα .....	77
4.5.1	Αποτελέσματα ιστορικής προσομοίωσης.....	78
4.5.2	Δεδομένα εκπαίδευσης νευρωνικών δικτύων.....	85
5.	Υποκατάστατα αναλυτικού μοντέλου μέσω ANN.....	88
5.1	Τα νευρωνικά δίκτυα για το μοντέλο βροχής-απορροής .....	88
5.2	Τα νευρωνικά δίκτυα για το μοντέλο λειτουργίας του υβριδικού συστήματος ....	90
5.3	Αποτελέσματα εκπαίδευσης νευρωνικών δικτύων .....	92
5.3.1	Νευρωνικά δίκτυα για το μοντέλο βροχής – απορροής .....	92
5.3.2	Νευρωνικά δίκτυα μοντέλου λειτουργίας υβριδικού συστήματος.....	101
5.3.3	Επιλογή τελικού σχήματος και υπολογιστικό κέρδος.....	109
6.	Συμπεράσματα και προτάσεις για μελλοντική έρευνα .....	110
	Βιβλιογραφικές Αναφορές .....	113
	Παράρτημα.....	120
	Μοντέλο βροχής – απορροής .....	120
	Μοντέλο προσομοίωσης λειτουργίας του ταμιευτήρα .....	121
	Αποτελέσματα αναλυτικής προσομοίωσης για παραγωγή δεδομένων αξιολόγησης.....	126
	Αποτελέσματα αξιολόγησης νευρωνικών δικτύων για το υδρολογικό μοντέλο.....	132
	Αποτελέσματα αξιολόγησης νευρωνικών δικτύων για το μοντέλο λειτουργίας του υβριδικού σταθμού .....	139

Διαγράμματα αποτελεσμάτων νευρωνικών δικτύων για την ομάδα Α του υβριδικού συστήματος .....	148
---	-----





## Περίληψη

Ο δυναμικά εξελισσόμενος ενεργειακός τομέας, καθώς και η αυξανόμενη ζήτηση νερού και ενέργειας, καθιστούν επιτακτική την ανάγκη για την ανάπτυξη μεθόδων που είναι ικανές να διαχειριστούν αποτελεσματικά τις δύο παραπάνω ανάγκες. Μια από τις διαθέσιμες τεχνικές για την ταυτόχρονη εκπλήρωση των αναγκών αυτών αποτελεί είναι η αντλησιοταμίευση, που εφαρμόζεται στα υβριδικά συστήματα νερού και ενέργειας. Το γεγονός ότι τα συστήματα αυτά διαχειρίζονται ταυτόχρονα τις ροές νερού και ενέργειας, καθώς και άλλοι παράγοντες όπως, για παράδειγμα, το απαιτούμενο χρονικό βήμα των υπολογισμών, συνθέτουν ένα υπολογιστικά απαιτητικό πρόβλημα προσομοίωσης και βελτιστοποίησης.

Στην παρούσα μεταπτυχιακή εργασία, η πρόκληση αυτή προσεγγίζεται μέσω υποκατάστατης μοντελοποίησης με τη χρήση νευρωνικών δικτύων, που αποσκοπεί στη μείωση του υπολογιστικού χρόνου της προσομοίωσης. Η ανάπτυξη της συγκεκριμένης μεθοδολογίας βασίζεται στην παραγωγή δεδομένων εκπαίδευσης των νευρωνικών δικτύων βάσει ιστορικών δεδομένων, και στην παραγωγή δεδομένων επαλήθευσής τους βάσει συνθετικών χρονοσειρών των αντίστοιχων μεταβλητών από την εφαρμογή ενός αναλυτικού μοντέλου προσομοίωσης των εμπλεκόμενων συστημάτων. Πεδίο εφαρμογής της μεθοδολογίας αποτελεί ένα υποθετικό υβριδικό σύστημα νερού και ενέργειας στο μη διασυνδεδεμένο νησί της Αστυπάλαιας.

Έπειτα από την επαλήθευση των νευρωνικών δικτύων επιλέγονται τα καταλληλότερα για την επιδιωκόμενη χρήση και αξιολογείται βάσει χρονομέτρησης η απόδοσή τους ως υποκατάστατα μοντέλα. Τα αποτελέσματα έδειξαν ότι με τη χρήση των νευρωνικών δικτύων ως υποκατάστατα μοντέλα επιτυγχάνεται σημαντική εξοικονόμηση του υπολογιστικού φόρτου, δίνοντας έναυσμα για τη διερεύνηση της χρήσης τους και σε άλλες εφαρμογές στο μέλλον.



# Neural networks as surrogate models for simulating a hybrid water-energy system

---

## Extended abstract

### 1. Introduction

The dynamically changing energy field, as well as the ever increasing water and energy demand, pose a strong need for developing new methods that are capable of managing them effectively. In the last decades, economy stresses and environmental needs have orientated the energy sector towards the use of renewable energy resources and the reduction of fossil fuel use. In addition, the Directive 2009/28/EC promotes the use of energy from renewable resources making their penetration to the energy mix even more necessary. Due to the unpredictable nature of the stochastic meteorological processes (i.e., solar radiation, wind speed etc.), the renewable energy sources are characterized by inherent uncertainty. This fact results in significant fluctuations of the produced energy, and therefore instability to the energy grid; moreover, it poses an obstacle to the effective penetration of renewable energy resources.

Pumped-storage systems, as components of broader hybrid water - energy systems, are considered as one of the best available techniques for the mitigation of the renewable energy resources uncertainty and the fulfillment of both water and energy demands. These schemes play a key role to the regulation of the energy balance of electric systems, as they provide the means for storing the excess of the produced energy and making it available during the demand peaks. Therefore, most of uncertainties concerning renewable energy production are drastically lessened. What is necessary for the operation of the pumped-hydroelectric-energy-storage is the use of interconnected water storage infrastructures (i.e. tanks, reservoirs) in different altitudes in order to form a scheme aiming at the integrated management of water and energy fluxes, contributing to better meeting the corresponding needs.

The management of pumped – storage systems is implemented through the simulation and optimization of their operational characteristics so that their optimum efficiency is achieved. During the simulation – optimization procedure, synthetic time series accounting for the stochastic regime of the physical system are used, the length of which is long enough to obtain the desirable accuracy for the uncertainty assessments. Given that the meteorological processes as well as energy demand are characterized by significant fluctuations during small time periods, the typical time step of the analysis of hybrid water – energy systems is that of the hour. The complexity of the combined management of water and energy fluxes, the hourly time step of the computations and the long horizon of the time series used introduce

a highly demanding and challenging computational burden to the simulation and optimization procedures.

The present work approaches the aforementioned challenge through the use of artificial neural networks as surrogate models (metamodels) in an attempt to reduce the computational time of the simulation procedure. Simulation through surrogate modeling refers to the development and use of models that are faster in computations and surrogate/substitute the slower analytical simulation models by imitating their behavior without being so computationally “expensive” as them. In the literature, many applications of surrogate modeling in water resources can be found, meanwhile a limited number of them refer to reservoir management applications. Generally, in many of them, the role of the surrogate model is held by neural networks. However, there was not found any application of artificial neural networks (ANNs) concerning reservoir management.

In the current work, ANNs are used for the simulation of the response surface of the energy balance as it is reformed after the pump – storage procedure of the system. The results showed that, through the use of neural networks as surrogate models, a significant amount of the computational effort and time can be saved, thus triggering the investigation of their use in further applications.

## 2. Case study

This methodology is applied to a hypothetical hybrid water-energy system situated at the non-connected Aegean island of Astypalaia in Greece. The present work assumes that the existing infrastructure of the Livadi reservoir, which is used for drinking water supply and irrigation, also produces hydroelectric energy through a hypothetical power station at the end of the abstraction tube. The system is integrated with a hypothetical upstream tank, as well as with photovoltaic panels and wind farms of installed capacity equal to 0.5 and 1.0 MW, respectively. The tank is connected with the reservoir through a penstock with a reversible pump-turbine that can either produce hydroelectric energy or consume energy via pumping. At each time step, only one of the two operational modes is allowed. This allows for regulating the energy balance and enabling the infrastructure to serve multipurpose uses, i.e. water supply for domestic use, irrigation of four basic cultivations (orchards, arable land, vegetables and vineyards) and energy production.

The system is assumed to have the following characteristic values: maximum dam height, which is also the maximum operational height of the reservoir, 32 m, overall and storage capacity of the reservoir 1,050,000 m<sup>3</sup> and 875,000 m<sup>3</sup> respectively, reservoir area 105,000 m<sup>2</sup>, flow capacity of the turbine 1,000 m<sup>3</sup>/h, performance capacity of the turbine 0.85. Additionally, the tank is situated at 200 m altitude higher than the reservoir and is of 50,000 m<sup>3</sup> storage capacity. The reversible turbine

is of 1,500 m<sup>3</sup>/h flow capacity and their efficiencies are 0.85 for energy production and 0.80 for pumping.

### 3. Input Data

As explained next, for the modelling of the hybrid water-energy system we used both historical and synthetic data, of 7 and 100 years length, respectively, provided by recent research studies in the same area.


The synthetic data were produced by employing different stochastic methods, depending on the examined process. In particular, the synthetic rainfall data were produced through the Castalia software that preserves the statistical properties of the parent historic data across three temporal scales (daily, monthly, annual) and also reproduces the long-term persistence (Hurst-Kolmogorov dynamics) at the annual and over-annual scale, the periodicity and the intermittent behavior of the process. The water demand data for the two uses (domestic, agricultural) were obtained by the recent work by Papoulakos *et al.* (2017), while the synthetic energy production from the PV panels and the wind farm were derived from the work of Chalakatevaki *et al.* (2017), based on synthetic solar radiation and the wind speed data, estimated by Moschos *et al.* (2017) and Koudouris *et al.* (2017) respectively. These synthetic time series had been produced by employing the methodology by Dimitriadis and Koutsoyiannis (2015a), which is suitable for processes exhibiting double periodicity, and retains the dependence structure through the empirical climacogram of each process (Dimitriadis and Koutsoyiannis, 2015b). Finally, the electric energy demand data were estimated by Mavroyeorgos *et al.* (2017).

### 4. Outline of Methodology

The representation of the aforementioned system was employed through two approaches, herein referred to as analytical and surrogate.

The analytical approach involved two detailed simulation models, i.e. a conceptual rainfall-runoff scheme, driven by daily rainfall and mean daily temperature data, for estimating the inflows to the reservoir and the actual evapotranspiration, and a reservoir operation model, running at hourly time step, using as inputs the inflows, and the water and energy demands, for estimating the water and energy balance components (outflows, storages, energy surplus and deficits). A detailed description of the computational procedure is given in next section.

The second approach involved the use of ANNs as surrogates of the two analytical models. We have tested several structures, by changing the inputs, the number of neurons and the outputs. An example is given in Figure 1. The general structure of all neural networks was that of the multi – layer perceptrons with one hidden layer and was determined after several trial and error procedures. Different settings with respect to input and output data were also tested.



**Figure 1:** Example of ANN structure, comprising a sigmoid hidden layer and a linear output layer of two neurons.

Key assumption of the methodology was the use of historical data of 7 years length for the construction and training of the artificial neural networks, and synthetic data of 100 years length for their structural validation. The two input data sets (historical and synthetic) were introduced separately to the analytical simulation models, to provide the outputs of interest. Next, the historical input data were used as inputs for the artificial neural networks, while the corresponding output data of the simulation models were the target data according to which the ANNs were trained. Finally, the synthetic data were used to validate the efficiency of the constructed ANNs according to the NSE efficiency coefficient. After the validation procedure, the most suitable neural network structures were further evaluated, in terms of computational performance.

## 5. Analytical Simulation Models

Two detailed simulation models were used for the current analysis, a conceptual rainfall – runoff model and the model that represents the water and energy fluxes across the hybrid system. The first one uses as inputs daily rainfall, mean daily temperature and daily extraterrestrial radiation data for the estimation of actual evapotranspiration, runoff, and underground losses through a soil moisture accounting scheme. Temperature data were used also for water demand estimation. A more detailed description of this model can be found at Papoulakos *et al.* (2017). The outputs of the rainfall – runoff model were then disaggregated from the daily time step to hourly and served as inputs for the second model.

In Figure 2 we show a schematic diagram of the component and associated fluxes of the reservoir operation model. Initially, it is necessary to make certain assumptions concerning the hierarchy of the different uses as well as for the way in which they are expressed in the simulation routine. Therefore, water for domestic use is ranked first; energy production is second and for irrigation is last amongst priorities. Inputs of the model are the net inflows in the reservoir, the water demand for domestic and agricultural use and the energy balance as it comes for the difference between the energy demand and the energy produced from the renewable resources (solar and wind energy).



is the minimum among the water demand for irrigation, the reserve and the remaining flow capacity. In this case, there is not possibility of covering any deficit from the tank's reserve, as irrigational use is of last priority for the system. Therefore, the dynamic energy potential is preserved in as high level as possible in order to be available in peak demand periods.

When abstractions are completed, we check the current reserve. In case the storage capacity is exceeded, water is pumped upwards to the tank. The pumped volume is the minimum among the excess, the flow capacity and the available storage capacity of the tank. For clarification, if there is an excess of water, there is no need for using the tank's reserve for domestic use and therefore with the expression above, the one – way flow in the tube connecting the tank and the reservoir is ensured, within the same time step. Then, in case that there is remaining excess volume, an amount of it, that is equal to the remaining flow capacity of the abstraction tube, is conducted out of the reservoir in order take full advantage of its energy potential. Further remaining water excess, if any, is driven out through the spillway.

For the simulation procedure, it is assumed that after the completion of the above water fluxes, the energy produced or consumed because of them update the initial energy balance. Further water fluxes are estimated, driven by the current energy balance conditions, deficits or excesses.

In case of energy deficit, there is production of energy by employing the reversible turbine. The volume that outflows off the tank is estimated as the minimum among the equivalent water demand for the production of the energy deficit, the flow capacity, the reserve in the tank and the available storage capacity of the reservoir. Due to this restriction, one – way flow is ensured within the same time step, as if an outflow upwards to the tank had taken place previously in order to avoid spilling, the current available storage capacity of the reservoir would be zero.

In case of energy excess, the water amount needed for pumping is estimated. Practically, the excess of energy is stored as potential energy because of the new position of the water amount. The volume that is finally pumped is the minimum among the equivalent volume estimated, the flow capacity, the available water in the reservoir and the available storage capacity of the tank.

Finally, the energy consumed or produced is estimated and the final revision of the energy balance takes place. Outputs of the model are the values of the energy excess and deficit, the water fluxes and storage in the tank and the reservoir at the end of the time step. The storage values at the end of each previous time step are initial conditions at the beginning of their next one.



## 6. Results

For the neural network surrogate of the rainfall – runoff model, the trials executed can be classified in four different groups. The **first** group contains the ANNs of the first attempt and served only for determining the structure, the data division (amount of training, testing and validation data) as well as the training algorithm. The **second** one includes neural networks in which the hidden layer size was increasing by one neuron each time for 100 repetitions. The inputs of these networks are the same as these of the rainfall – runoff model and result to a multiple output, a vector containing the estimated values of runoff, actual evapotranspiration and soil moisture. The **third** group is made up from ANNs that have the same inputs as these of the second one, but they are of one single output, estimating separately the runoff, the actual evapotranspiration and the soil moisture. For each one of the three variables 50 different repetitions were made, increasing the hidden layer size by one neuron. In the **fourth** group, in each repetition the hidden layer size is kept the same (15 neurons) but the rainfall data are introduced multiple times; in every repetition the rainfall lag is increased by one phase each time. The trials were made for a multiple output, as in the second group, and for the single output of the runoff as well. The best NSEs of the validation procedure are summarized in Table 1 according to the variable they refer to.

**Table 1:** NSEs during validation for the rainfall – runoff surrogate.

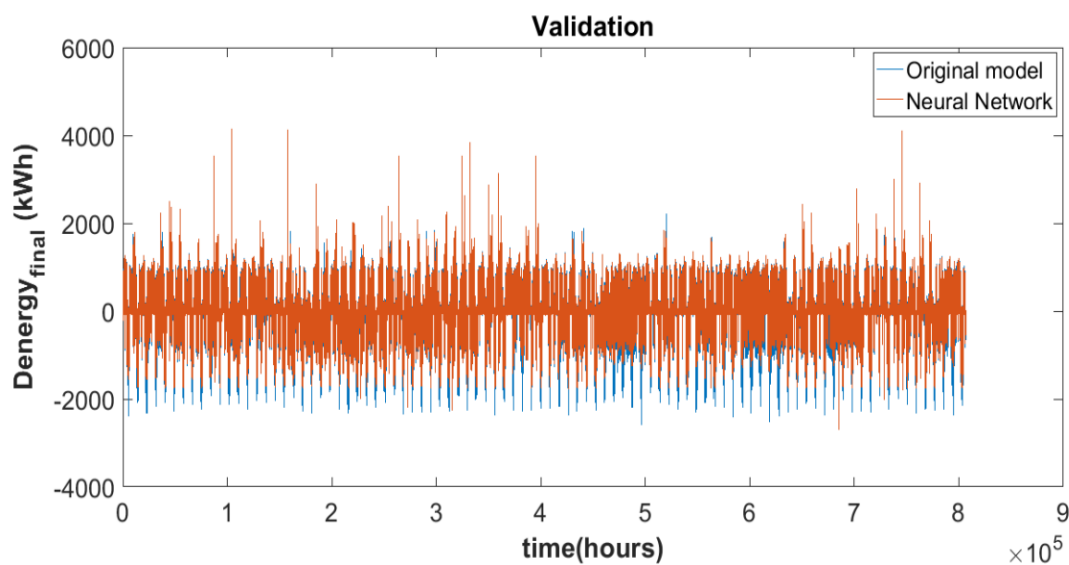
	Q	ET	S
NSE	0.56	0.64	0.60
Found in group	2	3	4a

As it can be seen from the table above, the NSE for all the three examined variables is quite good for the evapotranspiration and the soil moisture. However, for the runoff, that is going to be further used as input of the hybrid system simulation model, the efficiency coefficient value is not quite satisfactory for this purpose. Therefore, although the neural networks could definitely be a surrogate to substitute the rainfall – runoff model, in this work, they were not finally employed as such models and the original rainfall – runoff model was used to estimate the hybrid system simulation model inputs.

With regard to the neural network surrogate of the water – energy hybrid system simulation model, the trials performed can be classified in three different groups. These of the **first** group were trained with target data the water fluxes in the penstocks, but as the procedure turned out to be highly time demanding and resulted in poor estimations (negative NSE values), the specific approach was set aside and the work focused on simulating the final energy balance time series.


The neural networks of the **second** group simulate the final energy balance either overall or by simulating the deficit and the excess of energy separately. In the first case, the training was performed for 93 repetitions by increasing the hidden layer size by one neuron in each one. In the second one, the number of the hidden neurons was kept the same in every repetition and equal to 10, and the training was repeated for 150 times for the deficits and 143 for the surpluses. None of the trained neural networks in this group estimated well enough the values of the final energy demand. Even though that for the training procedure the best NSE values were quite good, 0.71 in the first case and 0.77 for the deficits in the second case, the highest corresponding values at the validation stage was 0.39 and 0.45 respectively. What is more, the surpluses simulated in the second case do not give good results, as in training the highest NSE value is 0.33 and in validation equal to 0.32. All of the NSE values are lower than the acceptable threshold of 0.50.

Finally, the **third** group of this category's neural networks estimate the final energy balance overall, but they need as extra input variables the stored water in the tank and the reservoir. In this case, two different structures were tried, that of the MLP (50 different repetitions of the training procedure) and that of the NARX (non-linear autoregressive with external (exogenous) input) neural network (one repetition). In this group, the values of the efficiency coefficient are generally higher than these of the previous ones. There are some negative values of the NSE, as in the previous groups, but most of them are higher than 0.90. For the MLP networks, the highest value is equal to 0.96 in training and 0.91 in validation. The final energy balance as estimated by the original simulation model and the MLP surrogate for the validation data set is presented in Figure 3.



**Figure 3:** Final energy balance of MLP neural network.

For the NARX neural network the highest NSEs are 0.92 for training and 0.84 for validation. The results of the NARX neural network for the validation data set against the estimation from the original model are presented in Figure 4.



**Figure 4:** Final energy balance of NARX neural network.

In both cases, these values are highly encouraging. If NARX networks are used, a preprocessing of the data is needed. This procedure could be quite time demanding and therefore, in combination with the fact that in validation the NSE value was lower than the corresponding of the MLP network, does not make the NARX the best choice for the purposes of the current work. As a result, the neural network that was finally selected to surrogate the response surface of the final energy balance was the MLP neural network that presented NSE equal to 0.91 during validation. This network, along with the original rain – runoff model and the simpler models for estimating the irrigation demands and the potential evapotranspiration, consist the final modeling scheme that was used in this work.

The selected neural network and the original simulation model were performed one more time in order to estimate the efficiency in terms of time saving amount. The results showed that the original model needed 14.4 s, while the neural network surrogate model needed only 0.3 s, which means 97.9% of the computational time was saved.

## 7. Conclusions

First of all, it is important to remark that the neural networks were constructed in the basis of having the same input data as the analytical models. So the periodic function of the solar radiation was taken into account. Its use, along with the use of rain lag, may be one of the reasons for the low NSE values of the corresponding neural networks for runoff estimation. As reported in the literature, the repetition of information may result in over – trained neural networks. However, the neural networks for evapotranspiration and soil moisture present higher NSE values than these for runoff metamodeling, even though they employ the same input variables. Runoff seems to be benefited more, when estimated by the multiple output neural networks, as its best NSE value is found in this group. Although the efficiency coefficient values of the neural networks estimating the rainfall – runoff model outputs are generally acceptable, for the present application are not considered sufficient enough, as they are intended to be used as inputs to the next model, which is of certain efficiency as well.

The water – energy hybrid system simulation model is more demanding, due to the complexity of the system. The regulation of the energy balance that takes place through the system is reflected to the total reserve of water and its distribution to the different storage facilities. Therefore, it is more difficult to have satisfactory enough estimations by using the same input data as for the original model. The use of water storage time series had an important contribution to the increase of the efficiency of the neural networks for the final energy balance estimation. Even when the deficits and surpluses of energy were separately simulated, it was not possible to have so satisfactory results as these of neural networks employing the current storage information. As the system simulated is more complicated, additional information is needed.

For the original model, the simulation had duration of 14s. This run may not seem to be so time demanding to turn to surrogate models. However, this value could be much higher in case of a more extended system with a great number of hydraulic works and power plants or in case of using even longer time series for achieving better accuracy in the system's efficiency estimation. What is more, this time duration would be even more critical when multiple simulation repetitions are needed (i.e. for optimization, sensitivity analysis, uncertainty estimation). Therefore, through validation on time basis, it is clear that the use of artificial neural networks significantly contributes to computational time reduction. As the time saving results seem to be promising through this procedure, a new target is set; that of exploring the possibilities of neural networks as surrogate models for integrated management of water – energy hybrid systems for optimization purposes.





# 1. Εισαγωγή

## 1.1 Τοποθέτηση του προβλήματος

Ο χώρος της ενέργειας ανέκαθεν αποτελούσε ένα δυναμικά και σημαντικά εξελισσόμενο τομέα, αποτελώντας ένα πεδίο στο οποίο αντικατοπτρίζονται οι κοινωνικές και οικονομικές συνθήκες, ενώ κατά τις τελευταίες δεκαετίες αναδεικνύονται επίσης ποικίλα περιβαλλοντικά ζητήματα. Ταυτόχρονα, το νερό αποτελεί ένα φυσικό αγαθό απαραίτητο για τη ζωή και τις ανθρώπινες δραστηριότητες, το οποίο και αυτό χαρακτηρίζεται από κοινωνικοοικονομικές και περιβαλλοντικές προεκτάσεις. Με την αύξηση του πληθυσμού, καθώς και των κατά κεφαλήν αναγκών, οι συνολικές ανάγκες για τη ζήτηση ενέργειας και νερού χαρακτηρίζονται από αυξητική τάση δημιουργώντας έτσι την ανάγκη εξεύρεσης λειτουργικών συστημάτων για την καλύτερη δυνατή ικανοποίηση και των δύο προαναφερθεισών αναγκών.

Τις τελευταίες δεκαετίες, τόσο οι οικονομικές πιέσεις όσο και οι περιβαλλοντικές ανάγκες έχουν στρέψει τον ενεργειακό τομέα προς τις ανανεώσιμες πηγές ενέργειας και τη μείωση της χρήσης ορυκτών καυσίμων. Ταυτόχρονα, με την έκδοση της Οδηγίας 2009/28/ΕΚ τίθενται *«υποχρεωτικοί εθνικοί στόχοι για το συνολικό μερίδιο ενέργειας από ανανεώσιμες πηγές στην ακαθάριστη τελική κατανάλωση ενέργειας και το μερίδιο ενέργειας από ανανεώσιμες πηγές στις μεταφορές»*, καθιστώντας έτσι ακόμα πιο επιτακτική τη διείδυση των ανανεώσιμων πηγών ενέργειας στο ενεργειακό μείγμα μιας χώρας. Οι ανανεώσιμες πηγές ενέργειας χαρακτηρίζονται από μεγάλη αβεβαιότητα καθώς εξαρτώνται από τις στοχαστικές μετεωρολογικές μεταβλητές (π.χ. ηλιακή ακτινοβολία, ταχύτητα ανέμου), οι οποίες δεν είναι προβλέψιμες. Το γεγονός αυτό έχει ως αποτέλεσμα την πρόκληση αστάθειας στο ηλεκτρικό δίκτυο, δυσχεραίνοντας τον προαναφερθέντα στόχο για διείδυση των ΑΠΕ στην παραγωγή ενέργειας.

Η βέλτιστη διαθέσιμη τεχνική για την αντιμετώπιση των αβεβαιοτήτων και την καλύτερη ενσωμάτωση των ΑΠΕ σε ένα δίκτυο είναι αυτή της αντλησιοταμίευσης. Η συγκεκριμένη διάταξη δίνει τη δυνατότητα αποθήκευσης της ενέργειας, αναρρυθμίζοντας, κατ' αυτό τον τρόπο, το ενεργειακό ισοζύγιο και περιορίζοντας δραστικά τις αβεβαιότητες. Απαραίτητη προϋπόθεση για τη λειτουργία της είναι η ύπαρξη συνδεδεμένων διατάξεων αποθήκευσης νερού (π.χ. ταμιευτήρων) σε διαφορετικά υψόμετρα, δημιουργώντας έτσι κατάλληλες συνθήκες για την ολοκληρωμένη διαχείριση τόσο των ενεργειακών όσο και των υδατικών ροών, και τελικά συμβάλλοντας στην καλύτερη ικανοποίηση των αντίστοιχων αναγκών.

Η διαχείριση των συστημάτων αντλησιοταμίευσης γίνεται μέσω της προσομοίωσης τους και της βελτιστοποίησης των λειτουργικών τους παραμέτρων, με σκοπό την καλύτερη δυνατή απόδοσή τους. Προκειμένου να γίνει με καλή ακρίβεια η εκτίμηση της αβεβαιότητας χρησιμοποιούνται μεγάλου μήκους συνθετικές χρονοσειρές για

όλες τις τυχαίες μεταβλητές του συστήματος. Ακόμη, δεδομένου ότι τόσο οι μετεωρολογικές διεργασίες όσο και η ζήτηση ενέργειας παρουσιάζουν σημαντικές διακυμάνσεις ακόμα και σε πολύ μικρές χρονικές κλίμακες, το τυπικό χρονικό βήμα της ανάλυσης τέτοιων συστημάτων είναι αυτό της ώρας. Όλα τα παραπάνω σε συνδυασμό με την εγγενή πολυπλοκότητα των υβριδικών συστημάτων αντλησιοταμίευσης καθιστούν την προσομοίωσή τους μεγάλη υπολογιστική πρόκληση.

Στην παρούσα εργασία επιχειρείται να αντιμετωπιστεί η παραπάνω πρόκληση με τη χρήση τεχνητών νευρωνικών δικτύων ως υποκατάστατα μοντέλα για την προσομοίωση του συστήματος, με σκοπό το μετριασμό του υπολογιστικού φόρτου. Πιο συγκεκριμένα, τα νευρωνικά δίκτυα χρησιμοποιούνται για την προσομοίωση του ενεργειακού ισοζυγίου έπειτα από την αναρρύθμισή του μέσω μιας διάταξης αντλησιοταμίευσης. Πεδίο ανάπτυξης και εφαρμογής της παραπάνω προσέγγισης αποτελεί ένα υποθετικό υβριδικό σύστημα νερού και ενέργειας στο μη διασυνδεδεμένο νησί της Αστυπάλαιας.

## 1.2 Διάρθρωση της εργασίας

Η εργασία, μαζί με το παρόν εισαγωγικό **Κεφάλαιο 1**, αποτελείται συνολικά από 6 κεφάλαια και την ενότητα του Παραρτήματος.

Στο **Κεφάλαιο 2** αναλύεται η έννοια της υποκατάστατης μοντελοποίησης και παρουσιάζονται οι βασικές πτυχές της. Ακόμη, δίνονται περισσότερες πληροφορίες αναφορικά με τις δύο βασικές κατηγορίες υποκατάστατων μοντέλων και γίνεται ξεχωριστή αναφορά σε εφαρμογές υδατικών πόρων.

Το **Κεφάλαιο 3** αφορά τα τεχνητά νευρωνικά δίκτυα. Μαζί με τον ορισμό τους παρέχεται το βασικό πλαίσιο ανάπτυξης προσομοιώσεων με χρήση τεχνητών νευρωνικών δικτύων και αναλύονται ορισμένα από τα πλεονεκτήματα και τα μειονεκτήματά τους. Επιπρόσθετα, γίνεται αναφορά για τη χρήση των νευρωνικών δικτύων ως υποκατάστατα μοντέλα καθώς και για τον τρόπο ανάπτυξής τους στο περιβάλλον της MATLAB.

Στο **Κεφάλαιο 4** αναλύεται το υποθετικό υβριδικό σύστημα για την περιοχή μελέτης που εξετάζεται. Πιο συγκεκριμένα, μετά από μια σύντομη εισαγωγή για τα υβριδικά συστήματα δίνονται όλες οι απαραίτητες πληροφορίες που αφορούν στο μεθοδολογικό πλαίσιο βάσει του οποίου αντιμετωπίζεται το πρόβλημα που τίθεται στην εργασία και τα δεδομένα που χρησιμοποιήθηκαν, αναλύεται η προσομοίωση του εξεταζόμενου συστήματος και δίνονται τα αποτελέσματα που προέκυψαν βάσει αυτής.



Στο **Κεφάλαιο 5** αναλύονται οι δοκιμές που έγιναν ώστε να καταρτιστεί ένα κατάλληλο σχήμα υποκατάστατης προσομοίωσης μέσω νευρωνικών δικτύων και δίνονται τα αντίστοιχα αποτελέσματα.

Στο **Κεφάλαιο 6** αναπτύσσονται τα συμπεράσματα που προέκυψαν από την παρούσα εργασία και γίνονται προτάσεις για περαιτέρω έρευνα.

Τέλος, στο **Παράρτημα** δίνονται οι αλγόριθμοι της αναλυτικής προσομοίωσης του εξεταζόμενου συστήματος, τα αποτελέσματα όλων των νευρωνικών δικτύων που εξετάστηκαν σε κατάλληλα διαμορφωμένους πίνακες, καθώς και ορισμένα από τα δεδομένα που χρησιμοποιήθηκαν, σε μορφή διαγραμμάτων.

## 2. Η έννοια των υποκατάστατων μοντέλων

### 2.1 Γενικά εισαγωγικά στοιχεία

Η προσομοίωση μέσω υποκατάστατων μοντέλων αναφέρεται στην ανάπτυξη και τη χρήση μοντέλων, τα οποία είναι υπολογιστικά ταχύτερα και υποκαθιστούν τα πολύ πιο αργά αρχικά μοντέλα προσομοίωσης. Πιο συγκεκριμένα, τα υποκατάστατα μοντέλα (surrogate models) είναι μοντέλα που προσεγγίζουν – μοντελοποιούν πολύπλοκα αναλυτικά μοντέλα προσομοίωσης, μιμούμενα την συμπεριφορά τους, χωρίς όμως να είναι το ίδιο απαιτητικά σε υπολογιστικό φόρτο. Συνεπώς, όταν η χρήση του αρχικού αναλυτικού μοντέλου είναι υπολογιστικά ακριβή, προτιμάται η χρήση του αντίστοιχου υποκατάστατου μοντέλου έναντι αυτής. Οι τύποι των προβλημάτων που προσεγγίζονται μέσω προσομοίωσης μπορεί να αφορούν την πρόγνωση, τη βελτιστοποίηση, τη διαχείριση συστημάτων, την ανάλυση ευαισθησίας, την ανάλυση αβεβαιότητας, καθώς και τη βαθμονόμηση και την ανάλυση ευαισθησίας σε παραμέτρους των μοντέλων. Αξιόλογη έρευνα και ανασκόπηση αναφορικά με τα υποκατάστατα μοντέλα έχουν κάνει οι Razavi *et al.* (2012a) η οποία αποτελεί την κύρια βιβλιογραφική πηγή για το παρόν κεφάλαιο.

Η ένταση του υπολογιστικού φόρτου των μοντέλων προσομοίωσης έγκειται τόσο στο γεγονός ότι τα σύγχρονα μοντέλα προσομοίωσης τείνουν να αναπαριστούν αυστηρά και με μεγάλη λεπτομέρεια την επιστημονική γνώση για τον πραγματικό κόσμο (Mugunthan *et al.*, 2005; Zhang *et al.*, 2009; Keating *et al.*, 2010) όσο και στο ότι πολλές εφαρμογές προσομοιώσεων στο χώρο της μηχανικής απαιτούν σημαντικά μεγάλο αριθμό επαναλήψεων, καθιστώντας έτσι τον υπολογιστικό «προϋπολογισμό» (budget, όρος που συχνά χρησιμοποιείται στη βιβλιογραφία) απαγορευτικά μεγάλο. Επομένως, το κυριότερο κίνητρο για την ανάπτυξη υποκατάστατων μοντέλων, όπως καταγράφεται βιβλιογραφικά, είναι η καλύτερη εκμετάλλευση του διαθέσιμου, συχνά περιορισμένου υπολογιστικού χρόνου. Ταυτόχρονα, ο υπολογιστικός φόρτος θα πρέπει να είναι τέτοιος ώστε να δικαιολογεί το κόστος μετακίνησης προς περαιτέρω απλοποιήσεις, καθώς το γεγονός αυτό είναι πιθανό να οδηγήσει σε μειωμένης ακρίβειας αναλύσεις (Razavi *et al.*, 2012).

Υπάρχουν δύο ευρείες κατηγορίες μοντελοποίησης με υποκατάστατα μοντέλα: η μοντελοποίηση της επιφάνειας απόκρισης (response surface modeling) και η μοντελοποίηση «χαμηλότερης πιστότητας» (lower-fidelity modeling). Τα «υποκατάστατα της επιφάνειας απόκρισης» χρησιμοποιούν συναρτήσεις οι οποίες λαμβάνουν υπόψη τα δεδομένα ώστε να προσεγγίσουν εμπειρικά την απόκριση του αρχικού μοντέλου (data-driven function approximation techniques). Στα υποκατάστατα μοντέλα αυτής της κατηγορίας αναφέρονται και οι όροι «μεταμοντέλα» (Blanning, 1975; Kleijnen, 2009) και «προσομοίωση μοντέλου

(model emulation)» (O'Hagan, 2006), καθώς αποτελούν «μοντέλα των μοντέλων». Επίσης, στη βιβλιογραφία συναντάται και ο όρος «proxy models» (Bieker *et al.*, 2007). Σε αντίθεση με τα υποκατάστατα της επιφάνειας απόκρισης, τα υποκατάστατα χαμηλότερης πιστότητας είναι φυσικά (physically-based) μοντέλα προσομοίωσης, αλλά λιγότερο λεπτομερή σε σχέση με τα αντίστοιχα αρχικά μοντέλα, τα οποία τυπικά θεωρούνται υψηλής πιστότητας. Τα χαμηλότερης πιστότητας μοντέλα είναι απλοποιημένα μοντέλα προσομοίωσης, τα οποία διατηρούν τις κυριότερες λειτουργίες που έχουν προσομοιωθεί στο αρχικό μοντέλο (Kennedy and O'Hagan, 2000; Forrester *et al.*, 2007).

Κατά τη χρήση υποκατάστατων μοντέλων, ο στόχος είναι η προσέγγιση των αποκρίσεων του συνήθως υπολογιστικά απαιτητικού αρχικού μοντέλου για τις διάφορες τιμές συγκεκριμένων μεταβλητών. Η μορφή της επιφάνειας που αναπαριστά την απόκριση του μοντέλου αναφορικά με τις μεταβλητές αυτές αποτελεί την επιφάνεια απόκρισης. Για την πλειονότητα των υπάρχοντων τεχνικών αναφορικά με τα υποκατάστατα επιφάνειας απόκρισης, πρέπει διαφορετικές επιφάνειες απόκρισης να προσαρμοστούν σε κάθε απόκριση του μοντέλου. Εξαιρεση σε αυτό αποτελεί η τεχνική των νευρωνικών δικτύων, μέσω της οποίας καθίσταται δυνατή η προσαρμογή σε πολλαπλές αποκρίσεις του μοντέλου. Τα μοντέλα χαμηλότερης πιστότητας, δεδομένου ότι διατηρούν κάποια φυσικά χαρακτηριστικά του αρχικού μοντέλου, θα μπορούσαν να προσεγγίσουν πολλαπλές αποκρίσεις.

Σε ένα συμβατικό πλαίσιο προσομοίωσης – βελτιστοποίησης όλες οι συνιστώσες, ήτοι το αρχικό μοντέλο και οι αλγόριθμοι αναζήτησης ή δειγματοληψίας, είναι άμεσα συνδεδεμένες μεταξύ τους. Ωστόσο, όταν οι παραπάνω αναλύσεις γίνονται με χρήση υποκατάστατων μοντέλων εμπλέκονται τρεις επιπλέον νέες συνιστώσες: α) ο σχεδιασμός του πειράματος (Design of Experiment - DoE), β) το υποκατάστατο της επιφάνειας απόκρισης και γ) το χαμηλότερης πιστότητας υποκατάστατο, κατά περίπτωση. Στο πλαίσιο αυτό η διαδικασία συνήθως ξεκινά με το σχεδιασμό του πειράματος ώστε να δημιουργηθεί ένα δείγμα με το οποίο εκπαιδεύεται ή στο οποίο προσαρμόζεται μια επιφάνεια απόκρισης ή ένα χαμηλότερης πιστότητας μοντέλο. Έπειτα, ο δειγματολήπτης/αλγόριθμος εύρεσης πραγματοποιεί κατ'επανάληψη τα «τρεξίματα» του αρχικού – υπολογιστικά ακριβού μοντέλου ή και του υποκατάστατου μοντέλου και συλλέγει τις αντίστοιχες αποκρίσεις. Κατά την ανάλυση αυτή, το υποκατάστατο μοντέλο μπορεί να είναι στατικό ή να επικαιροποιείται δυναμικά. Κάθε τιμή που προκύπτει από το αρχικό μοντέλο και που χρησιμοποιείται για την προσαρμογή του υποκατάστατου μοντέλου αναφέρεται ως θέση σχεδιασμού (design site).

Οι υπολογιστικές προσομοιώσεις μπορεί να είναι αρκετά σύνθετες και περιλαμβάνουν πολλές μεταβλητές οι οποίες έχουν πολύπλοκες συσχετίσεις μεταξύ τους. Ο σχεδιασμός του πειράματος (DoE) χρησιμοποιεί διάφορες τεχνικές πλήρωσης του χώρου, ώστε να αναπαραστήσει τη συμπεριφορά του υποκείμενου συστήματος σε περιορισμένο εύρος τιμών των μεταβλητών. Καθώς η μορφή της επιφάνειας απόκρισης δεν είναι συνήθως γνωστή εκ των προτέρων, ο σχεδιασμός του πειράματος θεωρεί συνήθως μια ομοιόμορφη κατανομή των θέσεων σχεδιασμού. Για το σχεδιασμό του πειράματος υπάρχουν αρκετές διαθέσιμες μεθοδολογίες, όπως για παράδειγμα ο ολικός παραγοντικός σχεδιασμός (Gutmann, 2001), ο παραγοντικός σχεδιασμός σε κλάσματα, ο κεντρικός συνθετικός σχεδιασμός (Montgomery, 2008), η δειγματοληψία (απλή και συμμετρική) μέσω λατινικού υπερκύβου (McKay *et al.*, 1979; Ye *et al.*, 2000), οι οποίες αποτελούν τις περισσότερο χρησιμοποιούμενες. Η διαστατικότητα του προβλήματος παίζει σημαντικό ρόλο στην επιλογή της κατάλληλης μεθόδου σχεδιασμού του πειράματος, καθώς το αρχικό μέγεθος του σχεδιασμού του πειράματος μπορεί να διαφέρει σημαντικά συναρτήσει των δύο προαναφερόμενων παραγόντων. Η έρευνα για το σχεδιασμό του πειράματος που προορίζεται για χρήση σε υποκατάστατα μοντέλα επικεντρώνεται κυρίως στον καθορισμό του βέλτιστου τύπου και μεγέθους των ήδη υπάρχοντων σχεδιασμών πειράματος για συγκεκριμένο πρόβλημα ή στην ανάπτυξη νέων και αποτελεσματικών σχεδιασμών.

Ο σχεδιασμός και η επιλογή ενός υποκατάστατου μοντέλου επηρεάζεται από τα ιδιαίτερα χαρακτηριστικά του προβλήματος. Τα πιο κρίσιμα από αυτά είναι ο τύπος της ανάλυσης στον οποίο αποσκοπεί η χρήση του υποκατάστατου μοντέλου, οι περιορισμοί του διαθέσιμου υπολογιστικού «προϋπολογισμού», η διαστατικότητα του προβλήματος, η ανάγκη για προσέγγιση μίας ή περισσότερων εξόδων του αρχικού μοντέλου (single-output ή multi-output surrogates). Η διαθεσιμότητα των ειδικών (model experts) και των προγραμματιστών των αρχικών μοντέλων έχει μεγάλη σημασία, ειδικότερα όταν χρησιμοποιούνται υποκατάστατα χαμηλότερης πιστότητας, καθώς είναι σε θέση να παρέχουν την απαραίτητη γνώση και καλύτερη εποπτεία στις συσχετίσεις μεταξύ των σφαλμάτων του αρχικού και του υποκατάστατου μοντέλου. Εξίσου κρίσιμη είναι η απαιτούμενη ακρίβεια του υποκατάστατου μοντέλου, δηλαδή εάν θεωρείται απαραίτητο να προβλέπει τα αποτελέσματα του αρχικού μοντέλου τόσο με μεγάλη ακρίβεια όσο και σε όλες τις θέσεις σχεδιασμού. Όλα τα παραπάνω πρέπει να ληφθούν υπόψη ώστε η εφαρμογή ενός υποκατάστατου μοντέλου να είναι επιτυχής.

### **2.1.1 Αξιολόγηση μεταμοντέλων**

Η αξιολόγηση μιας ανάλυσης μέσω υποκατάστατων μοντέλων γίνεται μέσω της αποδοτικότητας (υπολογιστική επίδοση) και της αποτελεσματικότητάς τους (ακρίβειας) σε σύγκριση με άλλα εναλλακτικά εργαλεία, χωρίς τη χρήση υποκατάστατων μοντέλων. Αυτό συμβαίνει κυρίως διότι η υπολογιστική απόδοση

είναι το κυριότερο κίνητρο της έρευνας και εφαρμογής των υποκατάστατων μοντέλων. Οι αναλύσεις αυτές, τυπικά θυσιάζουν την ακρίβεια υπέρ της απόδοσης, καθώς χρησιμοποιούν προσεγγιστικά μοντέλα, λιγότερο ακριβή από τα αρχικά, ώστε να επιτευχθούν με αποδοτικότερο τρόπο οι στόχοι της ανάλυσης. Επομένως, υπάρχει πάντα το ρίσκο τα υποκατάστατα μοντέλα να δίνουν παραπλανητικά αποτελέσματα. Το ρίσκο αυτό είναι μεγαλύτερο όταν η επιφάνεια απόκρισης του αρχικού μοντέλου είναι περίπλοκη, ενώ είναι μικρότερο για απλές επιφάνειες απόκρισης. Επιπλέον, για την αξιολόγηση παίζει σημαντικό ρόλο η σωστή επιλογή της διαδικασίας που αποτελεί το σημείο αναφοράς και σύγκρισης. Πιο συγκεκριμένα, το αρχικό μοντέλο θα πρέπει να έχει τουλάχιστον τον ίδιο αριθμό προσομοιώσεων με τον αριθμό των προσομοιώσεων που χρησιμοποιούνται κατά την μοντελοποίηση με υποκατάστατα.

Ένα ουσιαστικό μέτρο που θα μπορούσε να χρησιμοποιηθεί για την αξιολόγηση της αποτελεσματικότητας του υποκατάστατου μοντέλου έναντι του αρχικού είναι η εξοικονόμηση του υπολογιστικού φόρτου, το οποίο θα μπορούσε να υπολογιστεί απλά ως το ποσοστό του χρόνου που εξοικονομείται από το υποκατάστατο μοντέλο σε σχέση με το χρόνο που χρειάζεται το αρχικό μοντέλο για την εκτέλεση της ίδιας ανάλυσης, ήτοι:

$$\text{Εξοικονόμηση (\%)} = \frac{t - t_s}{t} * 100$$

όπου  $t$  είναι ο υπολογιστικός «προϋπολογισμός» ή ο απαιτούμενος χρόνος για την επίτευξη μιας επιθυμητής λύσης μέσω του αρχικού μοντέλου και  $t_s$  είναι ο αντίστοιχος υπολογιστικός «προϋπολογισμός» ή απαιτούμενος χρόνος μέσω του υποκατάστατου για την επίτευξη ίδιας ποιότητας λύση. Ο υπολογιστικός «προϋπολογισμός» μπορεί να ποσοτικοποιηθεί ως ο συνολικός χρόνος που καταγράφεται στη CPU ή ως ο αριθμός των επαναλήψεων της αρχικής συνάρτησης. Σύμφωνα με τη βιβλιογραφία, η υπολογιστική εξοικονόμηση που επιτυγχάνεται με τη χρήση υποκατάστατων μοντέλων διαφέρει σημαντικά, με εύρος που κυμαίνεται μεταξύ 97% (Zou *et al.*, 2007) και 20% (Zhang *et al.*, 2009) του χρόνου της CPU. Προφανώς, οι συγκρίσεις σε όρους CPU πρέπει να γίνονται στον ίδιο υπολογιστή ή σε υπολογιστή με ίδια τεχνικά χαρακτηριστικά (μνήμη, επεξεργαστής, λειτουργικό σύστημα).

Σε κάθε ανάλυση με χρήση υποκατάστατων μοντέλων, ο διαθέσιμος υπολογιστικός «προϋπολογισμός» χωρίζεται σε τρία κύρια μέρη: α) τον «προϋπολογισμό» ή το χρόνο που απαιτείται για το τρέξιμο του μοντέλου, β) τον «προϋπολογισμό» ή το χρόνο που απαιτείται για την ανάπτυξη, το τρέξιμο και την επικαιροποίηση του υποκατάστατου μοντέλου (metamodeling time) και γ) τον «προϋπολογισμό» ή το χρόνο που χρειάζεται ο αναλυτής ώστε να δημιουργήσει το κατάλληλο πλαίσιο για τη μοντελοποίηση μέσω υποκατάστατων (analyst time). Τα μέρη  $\beta$  και  $\gamma$  θα πρέπει

να καταναλώνουν μικρό μέρος του διαθέσιμου «προϋπολογισμού», αφήνοντας το μεγαλύτερο μέρος για το μέρος **α**. Ο χρόνος ανάπτυξης και εφαρμογής του υποκατάστατου θα πρέπει να λαμβάνεται και αυτός υπόψη για την αξιολόγηση της αποδοτικότητας των μεταμοντέλων. Οι χρόνοι αυτοί ίσως είναι μικρότεροι για τα μοντέλα χαμηλότερης πιστότητας σε σχέση με τα υποκατάστατα της επιφάνειας απόκρισης και επομένως θα ήταν άτοπο να γίνει κάποια σύγκριση βάσει του απαιτούμενου αριθμού επαναλήψεων της αρχικής συνάρτησης, όπως γίνεται συνήθως με τα υποκατάστατα της επιφάνειας απόκρισης. Τέλος, όταν ένα υποκατάστατο μοντέλο αναπτύσσεται προκειμένου να εφαρμοστεί σε επαναλαμβανόμενες εφαρμογές, τότε μειώνεται η σημασία του χρόνου του αναλυτή.

Ειδικότερα, για εφαρμογές βελτιστοποίησης, ο Razavi *et al.* (2012b) εισάγουν ένα πλαίσιο συγκριτικής αξιολόγησης για αλγορίθμους βελτιστοποίησης ενισχυμένους με υποκατάστατα μοντέλα, όπου η αξιολόγηση για την επιτυχία ή την αποτυχία των τεχνικών υποκατάστατης μοντελοποίησης γίνεται βάσει του «προϋπολογισμού». Σε συνθήκες με αρκετά περιορισμένο «προϋπολογισμό», τα υποκατάστατα μοντέλα φαίνεται να είναι αρκετά ωφέλιμα, ενώ όταν ο «προϋπολογισμός» δεν είναι τόσο αυστηρός τα υποκατάστατα μοντέλα μπορεί να μην είναι εξίσου βοηθητικά. Αντιθέτως, σε τέτοιες συνθήκες θα μπορούσαν να αποτελέσουν εμπόδιο και να οδηγήσουν σε παραπλανητικά συμπεράσματα. Παράλληλα, ισοδύναμες ή και καλύτερες λύσεις μπορούν να επιτευχθούν από τους αρχικούς αλγορίθμους (Razavi *et al.*, 2012b). Επομένως, η επιτυχία των αλγορίθμων αυτών είναι συνάρτηση του βαθμού πολυπλοκότητας της αρχικής επιφάνειας απόκρισης και του διαθέσιμου υπολογιστικού «προϋπολογισμού».

Οποιοδήποτε συμπέρασμα για την αποδοτικότητα ενός αλγορίθμου με υποκατάστατα μοντέλα πρέπει να βασίζεται στην εκτέλεση πολλαπλών επαναλήψεων, καθώς κάθε απλή εφαρμογή ενός τέτοιου αλγορίθμου, όπως και με κάθε άλλο στοχαστικό αλγόριθμο, είναι μια απλή παρατήρηση της επίδοσης από ένα στατιστικό πληθυσμό επιδόσεων. Παρά το προφανές υπολογιστικό φορτίο των πολλαπλών επαναλήψεων, αυτός είναι ο μόνος τρόπος για την επίτευξη έγκυρων αριθμητικών αξιολογήσεων και συγκρίσεων.

## **2.2 Υποκατάστατα χαμηλότερης πιστότητας (Lower Fidelity Surrogates)**

Τα μοντέλα χαμηλότερης πιστότητας, τα οποία συναντώνται και με τον όρο «αδρά» (coarse), είναι φυσικά υποκατάστατα μοντέλα, τα οποία αποτελούν μια οικονομικότερη εναλλακτική των μοντέλων προσομοίωσης και είναι λιγότερο πιστά στο εκάστοτε εξεταζόμενο σύστημα. Για κάθε πραγματικό πρόβλημα, μπορούν να υπάρξουν αρκετά μοντέλα προσομοίωσης με διαφορετικά επίπεδα πιστότητας –

διαφορετική ακρίβεια. Για παράδειγμα, ένα αριθμητικό μοντέλο με πολύ μικρό χρονικό βήμα θα μπορούσε να θεωρηθεί μοντέλο υψηλής πιστότητας και το αντίστοιχο χαμηλότερης πιστότητας μοντέλο να είναι ένα με μεγαλύτερο χρονικό βήμα. Τα μοντέλα υψηλής πιστότητας, τα οποία αποκαλούνται «λεπτομερή» (fine), είναι αυτά με τη μεγαλύτερη ακρίβεια και επομένως είναι προτιμότερα από τους χρήστες. Καθώς τα μοντέλα υψηλής πιστότητας είναι, τυπικά, πιο «βαριά» υπολογιστικά, υπάρχουν κάποιες προσεγγίσεις, οι οποίες κάνουν αποδοτική χρήση των μοντέλων αυτών, σε συνδυασμό με μοντέλα χαμηλότερης πιστότητας για την ενίσχυση της συνολικής υπολογιστικής απόδοσης. Οι στρατηγικές αυτές, όταν εφαρμόζονται σε πλαίσια βελτιστοποίησης, συναντώνται και με τους όρους «πολλαπλής πιστότητας» ή «μεταβλητής πιστότητας» (multi-fidelity ή variable-fidelity optimization) (Madsen and Langthjem, 2001; Leary *et al.*, 2003; Gano *et al.*, 2006; Forrester *et al.*, 2007; Sun *et al.*, 2010).

Τα υποκατάστατα χαμηλότερης πιστότητας εμφανίζουν δύο άμεσα πλεονεκτήματα: α) αναμένεται να προσομοιώνουν καλύτερα τις ανεξερεύνητες περιοχές του χώρου των μεταβλητών, π.χ. περιοχές μακριά από τα προηγουμένως εκτιμημένα μέσω του ακριβούς μοντέλου σημεία, και επομένως μπορούν να αποδίδουν πιο αξιόπιστα κατά την επέκτασή τους, και β) αποφεύγουν ή ελαχιστοποιούν τα προβλήματα που σχετίζονται με τα πολυδιάστατα προβλήματα, καθώς χρησιμοποιούν τη σχετική με τον τομέα γνώση. Το κυριότερο συμπέρασμα για τη χρήση τέτοιων μοντέλων είναι ότι τα υψηλής και χαμηλότερης πιστότητας μοντέλα έχουν κοινά βασικά χαρακτηριστικά και κατά κάποιο τρόπο υπάρχει συσχέτιση μεταξύ τους (Kennedy and O'Hagan, 2000). Επομένως, η απόκριση των χαμηλότερης πιστότητας μοντέλων για συγκεκριμένα δεδομένα εισόδου αναμένεται να είναι λογικώς κοντά με αυτή των υψηλής πιστότητας για τα ίδια δεδομένα. Αυτή η εγγύτητα δίνει τη δυνατότητα στα χαμηλότερης πιστότητας μοντέλα να προλέγουν σχετικά αξιόπιστα την επίδοση ενός υψηλής πιστότητας μοντέλου στις ανεξερεύνητες περιοχές του δειγματικού χώρου. Στην περίπτωση που παραβιάζεται η παραπάνω συνθήκη, τότε η εφαρμογή των υποκατάστατων μοντέλων δεν θα ήταν λειτουργική και τα αντίστοιχα οφέλη θα ήταν ελάχιστα.

Με την εφαρμογή μοντέλων χαμηλότερης πιστότητας υπάρχουν αρκετοί τρόποι ώστε να μειωθεί ο αριθμός των εκτιμήσεων – επαναλήψεων των αρχικών μοντέλων. Οι άμεσοι τρόποι περιλαμβάνουν τη χρήση μοντέλων χαμηλότερης πιστότητας αρχικά για τη μείωση του εφικτού χώρου των μεταβλητών ή και για την αναγνώριση ασήμαντων μεταβλητών ώστε να μειωθεί η διαστατικότητα του προβλήματος (Madsen and Langthjem, 2001). Οι περισσότερες μελέτες που χρησιμοποιούν τέτοιου είδους υποκατάστατα μοντέλα αφορούν την ανάπτυξη στρατηγικών βελτιστοποίησης όπου μοντέλα χαμηλής και υψηλής πιστότητας επιλέγονται κατάλληλα ώστε να αξιολογηθούν κατά την βελτιστοποίηση (Leary *et al.*, 2003; Gano *et al.*, 2006; Huang *et al.*, 2006; Forrester *et al.*, 2007; Viana *et al.*, 2009).

Επίσης, υπάρχουν εφαρμογές μοντέλων χαμηλής πιστότητας για ανάλυση αβεβαιότητας (Kennedy and O'Hagan, 2000; Allaire, 2009). Παρόλο που τα μοντέλα αυτά χρησιμοποιούνται ευρέως στην επιστημονική κοινότητα, στο χώρο των υδατικών πόρων η δημοτικότητά τους έχει μόλις αρχίσει να κερδίζει χώρο, και δεν συναντάται σε μεγάλο αριθμό εφαρμογών.

### 2.3 Τα υποκατάστατα επιφάνειας απόκρισης (Response Surface Surrogates)

Η προσομοίωση μέσω υποκατάστατων της επιφάνειας απόκρισης ως πεδίο έρευνας σε διάφορες επιστήμες ξεκίνησε περίπου πριν εξήντα χρόνια και αναπτύσσεται ενεργά κυρίως από τη δεκαετία του 1990 (Simpson *et al.*, 2008). Η πρώτη γενιά αυτού του είδους των υποκατάστατων, με εμπνευστές τους Box και Wilson (1951), βασιζόταν σε μεγάλο βαθμό σε πολυώνυμα (κυρίως δευτέρου βαθμού) και αποτελούν τη βάση της μεθοδολογίας για τα υποκατάστατα επιφάνειας απόκρισης. Τα υποκατάστατα επιφάνειας απόκρισης δεν προσομοιώνουν κανένα εσωτερικό λειτουργικό μέρος των αρχικών μοντέλων προσομοίωσης, αλλά προσεγγίζουν τις σχέσεις μεταξύ των μεταβλητών τους, π.χ. τις παραμέτρους ή και τις μεταβλητές που επηρεάζουν τις εισόδους τους μοντέλου. Με άλλα λόγια ένα υποκατάστατο επιφάνειας απόκρισης είναι μια προσέγγιση ή ένα μοντέλο της επιφάνειας απόκρισης του αρχικού μοντέλου, δηλαδή αποτελεί «μοντέλο του μοντέλου».

Η έρευνα πάνω στην προσομοίωση μέσω υποκατάστατων επιφάνειας απόκρισης μπορεί να χωριστεί σε τρεις κύριες κατηγορίες: α) την αναγνώριση και ανάπτυξη πειραματικού σχεδιασμού για την αποτελεσματική προσέγγιση, β) την ανάπτυξη και εφαρμογή τεχνικών προσέγγισης μέσω συναρτήσεων, ως υποκατάστατα και γ) την ανάπτυξη πλαισίου για την χρήση των υποκατάστατων. Στα πλαίσια των υδατικών πόρων, η έρευνα αυτή επικεντρώνεται στη δεύτερη και την τρίτη κατηγορία.

Τα υποκατάστατα επιφάνειας απόκρισης προσεγγίζουν την επιφάνεια απόκρισης του αρχικού μοντέλου με κατάλληλη προσαρμογή σε ήδη εκτιμημένες θέσεις σχεδιασμού. Για την επίτευξη του στόχου αυτού έχουν αναπτυχθεί και εφαρμοστεί ως υποκατάστατα μοντέλα διάφορες τεχνικές προσέγγισης. Οι τεχνικές αυτές περιλαμβάνουν πολυώνυμα, τη μέθοδο Krigging, η οποία αναφέρεται μερικές φορές και ως «σχεδιασμός και ανάλυση υπολογιστικών πειραμάτων (DACE) στα πλαίσια υποκατάστατης μοντελοποίησης», μεθόδους πλησιέστερου γείτονα (k-nearest neighbors, kNN), τεχνητά νευρωνικά δίκτυα (ANN), ακτινικές συναρτήσεις (radial basis functions – RBF), μηχανές διανυσμάτων υποστήριξης (support vector machines – SVM), πολυμεταβλητές προσαρμοστικές παρεμβολές παλινδρόμησης (multivariate adaptive regression splines – MARS), πολυδιάστατα παραστατικά μοντέλα (high-dimensional model representation), δένδροποιημένες Γκαουσιανές διαδικασίες, Γκαουσιανούς εξομοιωτές, μοντέλα εξομάλυνσης splines ANOVA και κατάλληλη ορθογωνική αποδόμηση. Από τις παραπάνω μεθόδους, τα ANN και οι



RBF αποτελούν τις μεθόδους που χρησιμοποιούνται συχνότερα για υποκατάστατη μοντελοποίηση (Razavi *et al.*, 2012a).

Τις περισσότερες φορές, τα μοντέλα προσέγγισης λειτουργούν ως υποκατάστατα των υποκείμενων συναρτήσεων, οι οποίες αναπαριστούν τα αρχικά μοντέλα σε όλο το εύρος των δεδομένων εισόδου. Σε μερικές μελέτες, ωστόσο, το μοντέλο προσέγγισης προσαρμόζεται τοπικά μόνο σε ένα υποσύνολο των θέσεων σχεδιασμού, οι οποίες βρίσκονται σε κοντινή γειτνίαση με το σημείο ενδιαφέροντος στο χώρο εξερεύνησης. Οι πληροφορίες που χρησιμοποιούνται για την προσαρμογή των μεταμοντέλων είναι οι τιμές απόκρισης της αρχικής συνάρτησης στις θέσεις σχεδιασμού, ενώ κάποιες μελέτες στοχεύουν να συμπεριλάβουν και την ευαισθησία (πληροφορία κλίσης) της αρχικής συνάρτησης σε αντιστοιχία με τις μεταβλητές, για την ενίσχυση της ακρίβειας του μεταμοντέλου (gradient-enhanced response surface surrogates). Πρακτικά, τέτοιες μέθοδοι έχουν σοβαρούς περιορισμούς, καθώς στα περισσότερα προβλήματα εφαρμογής υποκατάστατων επιφάνειας απόκρισης οι παράγωγοι δεν είναι άμεσα διαθέσιμοι και πρέπει να προσεγγίζονται βάσει αριθμητικών μεθόδων, οι οποίες απαιτούν την εκτίμηση της αρχικής συνάρτησης σε επιπλέον σημεία. Το επιπλέον υπολογιστικό φορτίο μπορεί να είναι απαγορευτικά μεγάλο όταν το πλήθος των διαστάσεων του χώρου των μεταβλητών είναι αρκετά αυξημένο, ενώ οι επιπλέον αυτοί υπολογισμοί θα μπορούσαν να διατεθούν για εκτιμήσεις της αρχικής συνάρτησης σε καλύτερα επιλεγμένες θέσεις. Συνεπώς, η επιλογή μιας κατάλληλης συνάρτησης προσαρμογής για μια δεδομένη ανάλυση με μεταμοντέλα απαιτεί προσεκτικό προβληματισμό, καθώς η λογική πίσω από την ανάπτυξη κάθε μεθοδολογίας, και το επίπεδο πρακτικότητάς διαφέρει σημαντικά, ανάλογα με το εξεταζόμενο πρόβλημα.

## 2.4 Εφαρμογές στους υδατικούς πόρους

Αναφορικά με τα προβλήματα υδατικών πόρων, η εφαρμογή υποκατάστατων μοντέλων γίνεται ολοένα και πιο δημοφιλής τα τελευταία είκοσι χρόνια, όπως διαφαίνεται μέσα από την επιστημονική βιβλιογραφία από το 1990 και έπειτα (Viana and Haftka, 2008). Γενικότερα, τα πεδία όπου έχει εφαρμοστεί η χρήση των υποκατάστατων μοντέλων περιλαμβάνουν τη βαθμονόμηση μοντέλων με εξελικτικούς αλγορίθμους, τη διαχειριστική ή σχεδιαστική βελτιστοποίηση με εξελικτικούς αλγορίθμους, μεθόδους ολικής ανάλυσης ευαισθησίας, αλγορίθμους πολυστοχικής βελτιστοποίησης, καθώς και τις συνήθεις αναλύσεις ευαισθησίας ή αβεβαιότητας Monte Carlo. Από τη χρήση των υποκατάστατων μοντέλων είναι δυνατό να επωφελούνται πολλές επαναληπτικές διαδικασίες. Τα οφέλη αυτά, ωστόσο θεωρούνται εν δυνάμει, καθώς οι αναλύσεις μέσω υποκατάστατων μοντέλων αποτελούν μόνο προσεγγίσεις των αρχικών αναλύσεων, ενώ το αντίστοιχο σφάλμα είναι αρκετά δύσκολο να προσεγγιστεί χωρίς την εκτέλεση της προσομοίωσης από το αρχικό μοντέλο (Razavi *et al.*, 2012a). Για παράδειγμα, δεν υπάρχει κάποια εγγύηση ότι το αποτέλεσμα που προκύπτει για την ανάλυση

ευαισθησίας στις παραμέτρους ενός μοντέλου θα είναι το ίδιο για το αρχικό και το υποκατάστατο μοντέλο.

Οι ερευνητικές προσπάθειες για τη χρήση μεταμοντέλων στον τομέα των υδατικών πόρων επικεντρώνονται κυρίως στην ανάπτυξη πλαισίων για τη χρήση τους. Από τους Razavi *et al.* (2012) κατηγοριοποιούνται οι διαθέσιμες αναλύσεις που γίνονται με χρήση μεταμοντέλων σε τέσσερα γενικότερα πλαίσια εφαρμογής: α) το βασικό επαναληπτικό πλαίσιο, β) το προσαρμοστικό – αναδρομικό πλαίσιο, γ) το εξελικτικό πλαίσιο με ενσωμάτωση μεταμοντέλου και δ) το πλαίσιο εκτίμησης της αβεβαιότητας. Τα δύο πρώτα είναι πλαίσια πολλαπλού σκοπού, τα οποία είναι εφαρμόσιμα σε όλες τις δειγματοληπτικές και ευρετικές αναλύσεις, το τρίτο εφαρμόζεται μόνο σε αλγορίθμους εξελικτικής βελτιστοποίησης και το τελευταίο χρησιμοποιείται κυρίως για ευρετικές αναλύσεις, αλλά μπορεί να εφαρμοστεί και σε ορισμένες δειγματοληπτικές μελέτες. Περισσότερες λεπτομέρειες για τα παραπάνω πλαίσια, καθώς και για μια πιο ολοκληρωμένη πληροφόρηση και συγκριτική αξιολόγηση αναφορικά με τις συναρτήσεις προσαρμογής των υποκατάστατων επιφάνειας απόκρισης και τα μοντέλα χαμηλότερης πιστότητας προτείνεται η αναδρομή στη σχετική βιβλιογραφία (Razavi *et al.*, 2012a).

Τα μεταμοντέλα χρησιμοποιούνται ευρέως σε διάφορα προβλήματα περιβαλλοντικής μοντελοποίησης. Σύμφωνα με τη βιβλιογραφία που καταγράφεται από την προαναφερθείσα πηγή, το 45% περίπου των μελετών επικεντρώνεται στην αυτόματη βαθμονόμηση μοντέλων. Οι περισσότερες μελέτες αυτόματης βαθμονόμησης με χρήση υποκατάστατων μοντέλων περιλαμβάνουν υποκατάστατα μοντέλα συνδυαστικά με αλγορίθμους βελτιστοποίησης. Σε τέσσερις μελέτες έχει γίνει χρήση μεταμοντέλων με αλγορίθμους ανάλυσης αβεβαιότητας για βαθμονόμηση μοντέλων (Khu and Werner, 2003; Mugunthan and Shoemaker, 2006; Zhang *et al.*, 2009) και για αλυσίδες Markov με Monte Carlo (Bliznyuk *et al.*, 2008), τρεις μελέτες (Schultz *et al.*, 2004; 2006; Borgonono *et al.*, 2012) χρησιμοποιούν επίσης υποκατάστατα μοντέλα για την επιτάχυνση της δειγματοληψίας Monte-Carlo. Δέκα μελέτες κάνουν χρήση τέτοιων μοντέλων για βελτιστοποίηση προβλημάτων υπόγειων υδάτων και κυρίως για την αποκατάσταση υπόγειων υδροφορέων, τέσσερις μελέτες έχουν εφαρμοστεί για το σχεδιασμό και τη βελτιστοποίηση συστημάτων υδροδότησης, ενώ μία μόνο μελέτη (Borgonono *et al.*, 2012) γίνεται για ανάλυση ευαισθησίας. Σε πέντε μελέτες (Liong *et al.*, 2001; Bau and Mayer, 2006; Behzadian *et al.*, 2009; di Pierro *et al.*, 2009; Castelletti *et al.* 2010) τα υποκατάστατα χρησιμοποιούνται στα πλαίσια πολυστοχικής βελτιστοποίησης. Σημαντικό είναι να αναφερθεί ότι οι περισσότερες μελέτες προσαρμόζουν τα μεταμοντέλα σε συνεχείς μεταβλητές. Πέντε μελέτες (Broad *et al.*, 2005; Bau and Mayer, 2006; Behzadian *et al.*, 2009; Broad *et al.*, 2010; Castelletti *et al.*, 2010) εφαρμόζουν υποκατάστατα μοντέλα σε προβλήματα ακέραιης βελτιστοποίησης (στα οποία η προσαρμογή γίνεται σε διακριτές μεταβλητές), ενώ σε τρεις ακόμη

(Yan and Minsker, 2006; 2011; Hemker *et al.*, 2008) η εφαρμογή αφορά μεικτή βελτιστοποίηση (κάποιες από τις μεταβλητές είναι διακριτές). Τέλος, σε μία έρευνα (Shrestha *et al.*, 2009) γίνεται χρήση νευρωνικών δικτύων ως υποκατάστατο μοντέλο για την πλήρη αντικατάσταση των «βαρέων» πειραμάτων δειγματοληψίας Monte Carlo. Στη συγκεκριμένη προσέγγιση, τα νευρωνικά δίκτυα χρησιμοποιούνται για να προσομοιώσουν την προγνωστική αβεβαιότητα ενός υδρολογικού μοντέλου. Στη μελέτη αυτή, το υποκατάστατο δεν ακολουθεί τη γενική μεθοδολογία μοντελοποίησης των υποκατάστατων επιφάνειας απόκρισης, κατά την οποία το μεταμοντέλο προσεγγίζει τις παραμέτρους του μοντέλου ή άλλες μεταβλητές σε σχέση με την απόκριση του συστήματος, αλλά αντί αυτού το μοντέλο νευρωνικού δικτύου «χαρτογραφεί» την παρατηρημένη βροχόπτωση και απορροή του προηγούμενου χρονικού βήματος σε σχέση με την προγνωστική αβεβαιότητα στο επόμενο χρονικό βήμα.

Τα παραπάνω δεδομένα αφορούν σε μελέτες που είχαν δημοσιευθεί από το 2000 μέχρι και το 2012. Όπως προκύπτει από την εξέταση των διαθέσιμων στοιχείων, μέχρι το 2012, δεν φαίνεται να υπάρχει κάποια εφαρμογή με υποκατάστατα μοντέλα σε διαχείριση ταμιευτήρων. Μια πιο πρόσφατη αναζήτηση επικεντρωμένη στο συγκεκριμένο πρόβλημα έδωσε ως αποτέλεσμα μια αρκετά περιορισμένη λίστα ερευνών. Πιο συγκεκριμένα, η πρώτη από αυτές τις τέσσερις περισσότερο σχετικές έρευνες που βρέθηκαν αφορά την ενίσχυση του εξελικτικού αλγορίθμου ανόπτησης-απλόκου με υποκατάστατα μοντέλα, του οποίου η επίδοση συγκριτικά με άλλους αλγορίθμους εξετάζεται, μεταξύ άλλων, και σε εφαρμογή διαχείρισης ταμιευτήρων (Tsoukalas *et al.*, 2016). Οι υπόλοιπες τρεις αφορούν τη βελτιστοποίηση των κανόνων λειτουργίας συστημάτων ταμιευτήρων είτε για υδροηλεκτρική παραγωγή (Tsoukalas and Makropoulos, 2014; Zhang *et al.*, 2016) είτε για τη διαχείριση πλημμυρικών γεγονότων (Castro-Gama *et al.*, 2014), παρουσιάζοντας πολύ ικανοποιητικά αποτελέσματα σε όλες τις εφαρμογές.

### 3. Νευρωνικά Δίκτυα

Τα πρώτα νευρωνικά μοντέλα είναι αποτέλεσμα της θεμελιώδους έρευνας των W.S. McCulloch και W.A. Pitts αναφορικά με τη θεωρία της νευρωνικής υπολογιστικής κατά τα τέλη της δεκαετίας του 1940, η οποία είχε ξεκινήσει να αναπτύσσεται στα τέλη του 19<sup>ου</sup> και τις αρχές του 20<sup>ου</sup> αιώνα μετά τις εξελίξεις στην πληροφορική και την νευροεπιστήμη (de Vos, 2003) . Στη συνέχεια, αναπτύχθηκε η θεωρία για τις τεχνικές των τεχνητών νευρωνικών δικτύων και η πρόοδος που σημειώθηκε οδήγησε στην κατασκευή των πρώτων νευρωνικών υπολογιστών (υπολογιστές των οποίων οι επεξεργαστές λειτουργούν με πρότυπο τα νευρωνικά δίκτυα) τη δεκαετία του 1960. Όμως, διάφοροι περιορισμοί που εντοπίστηκαν, όπως η έλλειψη των υπολογιστικών πόρων και οι ανεπιτυχείς, μέχρι τότε, προσπάθειες για την ανάπτυξη τεχνικών που θα μπορούσαν να επιλύσουν προβλήματα μεγάλης κλίμακας, οδήγησε σε περιορισμένο αριθμό ερευνών στο συγκεκριμένο πεδίο μέχρι τα μέσα της δεκαετίας του 1980, οπότε και αυξήθηκε ξανά το ενδιαφέρον για τη νευρωνική υπολογιστική, κυρίως από τον J.J. Hopfield.

Κατά τα επόμενα χρόνια, πολλοί από τους προηγούμενους περιορισμούς των τεχνητών νευρωνικών δικτύων είχαν ξεπεραστεί και έτσι η εφαρμογή τους ήταν επιτυχής σε πολλά προβλήματα. Από τις τεχνικές που ήρθαν ξανά στο προσκήνιο, η πιο πρωτοποριακή ήταν αυτή της προς τα πίσω διάδοσης (backpropagation), γεγονός που σε συνδυασμό με την αύξηση των υπολογιστικών πόρων οδήγησε στην εκρηκτική ανάπτυξη των τεχνητών νευρωνικών δικτύων. Τα τεχνητά νευρωνικά δίκτυα χρησιμοποιούνται κυρίως για τη μοντελοποίηση των πολύπλοκων σχέσεων σε συνθήκες όπου η γνώση για το εξεταζόμενο σύστημα δεν είναι επαρκής ώστε να τις περιγράψει μέσω συμβατικών αναλυτικών μοντέλων.

#### 3.1 Ορισμός των τεχνητών νευρωνικών δικτύων

Τα νευρωνικά δίκτυα αποτελούν μέρος των δομών επεξεργασίας πληροφοριών στην επιστήμη της νευροϋπολογιστικής. Η νευροϋπολογιστική είναι ένα τεχνολογικό πεδίο που αφορά τα συστήματα επεξεργασίας πληροφοριών, τα οποία αναπτύσσουν αυτόνομα τις λειτουργικές τους ικανότητες ανταποκρινόμενα στο περιβάλλον της πληροφορίας. Τα τεχνητά νευρωνικά δίκτυα είναι μοντέλα που χρησιμοποιούν πυκνές διασυνδέσεις απλών υπολογιστικών στοιχείων, σε συνδυασμό με συγκεκριμένους αλγόριθμους, οι οποίοι προσαρμόζουν τη δομή των δικτύων (και επομένως την απόκρισή τους) στις πληροφορίες που παρέχονται σε αυτά (de Vos, 2003).

Κατά μια μαθηματική έννοια, τα τεχνητά νευρωνικά δίκτυα μπορούν να αποκαλεστούν ως ολικοί εκτιμητές, καθώς είναι συχνά σε θέση να αποκαλύψουν και να εκτιμήσουν τις σχέσεις μεταξύ διαφορετικών τύπων δεδομένων. Ακόμα και αν η υποκείμενη διαδικασία είναι αρκετά περίπλοκη, τα τεχνητά νευρωνικά δίκτυα

μπορούν να την εκτιμήσουν αρκετά καλά, με την προϋπόθεση ότι υπάρχουν επαρκή και κατάλληλα δεδομένα αναφορικά με τη διαδικασία.

Το 1990 ο Hecht-Nielsen πρότεινε έναν ορισμό για τα τεχνητά νευρωνικά δίκτυα, ο οποίος για καλύτερη κατανόηση δεν παρατίθεται επακριβώς, αλλά αποδίδεται βάσει των κύριων στοιχείων του:

*Ένα νευρωνικό δίκτυο είναι ένα κατανεμημένο σχήμα επεξεργασίας πληροφοριών αποτελούμενο από στοιχεία επεξεργασίας, τα οποία συνδέονται παράλληλα και με τον επιθυμητό τρόπο. Η διασύνδεση γίνεται μέσω καναλιών σημάτων μονής κατεύθυνσης, τα οποία καλούνται κλάδοι. Τα στοιχεία επεξεργασίας μπορούν να διαθέτουν τοπική μνήμη και να διεξάγουν τοπικά λειτουργίες επεξεργασίας της πληροφορίας. Κάθε στοιχείο μεταφέρει το σήμα εξόδου που προκύπτει από το ίδιο. Το σήμα εξόδου του στοιχείου επεξεργασίας μπορεί να είναι οποιουδήποτε μαθηματικού τύπου. Η επεξεργασία της πληροφορίας που γίνεται μέσα σε κάθε στοιχείο επεξεργασίας μπορεί να οριστεί αυθαίρετα, με τον περιορισμό ότι θα πρέπει να είναι εντελώς τοπική. Αυτό σημαίνει ότι θα πρέπει να εξαρτάται μόνο από τις τρέχουσες τιμές των εισερχόμενων σημάτων που φθάνουν στο στοιχείο επεξεργασίας, μέσω των συνδέσεων ενεργοποίησης, και στις τιμές που είναι αποθηκευμένες στην τοπική μνήμη του στοιχείου επεξεργασίας.*

### **3.2 Πλαίσιο ανάπτυξης τεχνητών νευρωνικών δικτύων**

Σύμφωνα με τους Rumelhart *et al.* (1986), για τα μοντέλα παράλληλης κατανεμημένης επεξεργασίας όπως τα τεχνητά νευρωνικά δίκτυα υπάρχουν οκτώ βασικές συνιστώσες:

- 1) Το σύνολο των στοιχείων επεξεργασίας (νευρώνες)
- 2) Η κατάσταση ενεργοποίησης
- 3) Η συνάρτηση εξόδου κάθε νευρώνα
- 4) Το πρότυπο διασύνδεσης μεταξύ των νευρώνων
- 5) Ο κανόνας διάδοσης, για τη διάδοση των προτύπων των δραστηριοτήτων μέσω του δικτύου των συνδέσεων
- 6) Ο κανόνας ενεργοποίησης, για το συνδυασμό των εισόδων σε ένα νευρώνα και της τρέχουσας κατάστασής του, με σκοπό την παραγωγή μιας νέας τιμής του επιπέδου ενεργοποίησης που αφορά τον ίδιο νευρώνα
- 7) Ο κανόνας εκμάθησης – εκπαίδευσης, κατά τον οποίο τα σχήματα σύνδεσης τροποποιούνται βάσει εμπειρίας
- 8) Το περιβάλλον στο οποίο το σύστημα θα πρέπει να λειτουργεί

Στη συνέχεια, αναλύεται κάθε ένα από τα προαναφερθέντα δομικά στοιχεία όπως αντλούνται από τον de Vos (2003).

### 3.2.1 Νευρώνες και επίπεδα

Οι νευρώνες (neurons) είναι τα σχετικά απλά υπολογιστικά στοιχεία που είναι τα βασικά δομικά στοιχεία των τεχνητών νευρωνικών δικτύων. Οι νευρώνες συναντώνται επίσης και με τον όρο των «στοιχείων επεξεργασίας» ή των «κόμβων» και τυπικά κατανέμονται σε επίπεδα (layers). Συμβατικά, οι εισδοχές που δέχονται τα δεδομένα καλούνται μονάδες εισόδου (που αποτελούν το αντίστοιχο επίπεδο – input layer) και το επίπεδο που μεταφέρει τα δεδομένα εκτός του νευρωνικού δικτύου καλείται επίπεδο εξόδου (output layer). Τα εσωτερικά επίπεδα, όπου λαμβάνει χώρα η ενδιάμεση εσωτερική επεξεργασία, τυπικά καλούνται κρυμμένα επίπεδα (hidden layers). Ο αριθμός των μονάδων εισόδου και των νευρώνων εξόδου είναι ίσος με τις μεταβλητές εισόδου και εξόδου αντίστοιχα, ενώ τα κρυμμένα επίπεδα μπορούν να περιέχουν οποιοδήποτε αριθμό νευρώνων. Επίσης, δεν είναι απαραίτητο ότι όλα τα νευρωνικά δίκτυα έχουν κρυμμένα επίπεδα.

### 3.2.2 Κατάσταση ενεργοποίησης

Η κατάσταση του συστήματος σε ένα συγκεκριμένο χρονικό σημείο αναπαριστάται από την κατάσταση ενεργοποίησης των νευρώνων του δικτύου. Εάν θεωρηθεί ένα πλήθος  $N$  νευρώνων, η κατάσταση του συστήματος μπορεί να αναπαρασταθεί από ένα διάνυσμα  $\mathbf{a}(t)$ , με  $N$  πραγματικούς αριθμούς, το οποίο προσδιορίζει την κατάσταση ενεργοποίησης των νευρώνων. Ανάλογα με το μοντέλο του τεχνητού νευρωνικού δικτύου, οι τιμές ενεργοποίησης μπορεί να είναι οποιουδήποτε μαθηματικού τύπου (ακέραιος, πραγματικός, μιγαδικός, Boolean, κλπ.). Συνεχείς τύποι ενεργοποίησης μπορεί να περιορίζονται εντός ενός συγκεκριμένου διαστήματος.

### 3.2.3 Συνάρτηση εξόδου νευρώνα

Οι νευρώνες αλληλεπιδρούν μεταφέροντας σήματα στους γειτονικούς νευρώνες. Η ένταση των σημάτων καθορίζεται από το βαθμό ενεργοποίησής τους. Κάθε νευρώνας διαθέτει μία συνάρτηση εξόδου που καθορίζει την τρέχουσα κατάσταση ενεργοποίησης σε ένα σήμα εξόδου  $\mathbf{o}(t)$ , ως  $\mathbf{o}(t) = f[\mathbf{a}(t)]$ . Αυτή η συνάρτηση εξόδου μπορεί να είναι είτε μια ταυτότητα,  $f(\mathbf{x}) = \mathbf{x}$ , με αποτέλεσμα η τρέχουσα τιμή ενεργοποίησης απλά να μεταφέρεται στους επόμενους νευρώνες, είτε κάποιου είδους συνάρτηση κατωφλίου, με αποτέλεσμα ένας νευρώνας να μην έχει επίδραση σε άλλους νευρώνες εκτός εάν η τιμή ενεργοποίησης υπερβαίνει μια συγκεκριμένη τιμή. Το σετ των τρεχόντων τιμών εξόδου αναπαριστώνται από το διάνυσμα  $\mathbf{o}(t)$ . Η τιμή της συνάρτησης εξόδου μπορεί συχνά να επηρεάζεται από ορισμένα συστηματικά σφάλματα (biases), τα οποία καλούνται συστηματικά σφάλματα νευρώνα. Τα σφάλματα αυτά αποτελούν παραμέτρους του νευρωνικού δικτύου και εκφράζονται από το διάνυσμα  $\mathbf{b}$ . Μια κατάσταση όπου η συνάρτηση εξόδου είναι ίση με συνάρτηση ταυτότητας αναφέρεται ως «κατάσταση όπου δεν χρησιμοποιείται συστηματικό σφάλμα νευρώνα», ενώ ένα συστηματικό σφάλμα ίσο με 0,50 σημαίνει ότι χρησιμοποιείται συνάρτηση κατωφλίου ως συνάρτηση εξόδου,


όπου το σήμα περνάει μέσω του νευρώνα μόνο εάν η τιμή εισόδου υπερβαίνει την τιμή 0,50.

### 3.2.4 Πρότυπο σύνδεσης


Ο τρόπος με τον οποίο συνδέονται οι νευρώνες μεταξύ τους καθορίζει τον τρόπο με τον οποίο ένα νευρωνικό δίκτυο θα αποκριθεί σε μια είσοδο. Οι συνδέσεις μεταξύ των νευρώνων ποικίλουν σε ισχύ. Σε πολλές περιπτώσεις, θεωρείται ότι οι εισερχόμενες τιμές από όλους τους νευρώνες απλά πολλαπλασιάζονται με ένα βάρος και αθροίζονται, ώστε να ληφθεί μια ολική είσοδος στον επόμενο νευρώνα. Στην περίπτωση αυτή, το ολικό πρότυπο σύνδεσης μπορεί να εκφραστεί με τον καθορισμό των βαρών του συστήματος, ενώ δεν είναι απαραίτητο ένας νευρώνας να συνδέεται με όλους τους νευρώνες στο επόμενο επίπεδο. Επομένως, μπορεί να προκύψουν μηδενικές τιμές για τα αντίστοιχα βάρη. Τα βάρη αυτά συχνά εκφράζονται με τη χρήση μητρώων  $\mathbf{W}$ . Σε άλλες περιπτώσεις απαιτούνται περισσότερο περίπλοκα σχήματα σύνδεσης. Ένας δεδομένος νευρώνας μπορεί να δεχτεί εισόδους διαφορετικών ειδών, των οποίων η επίδραση αθροίζεται χωριστά. Στις περιπτώσεις αυτές, είναι καλύτερο να υπάρχουν χωριστά μητρώα σύνδεσης για κάθε τύπο. Οι συνδέσεις μεταξύ των νευρώνων κατατάσσονται συχνά ανάλογα με την κατεύθυνσή τους στη δομή του δικτύου ως:

- Πρόσθιας τροφοδότησης (feedforward) συνδέσεις, οι οποίες είναι συνδέσεις μεταξύ των νευρώνων σε διαδοχικά επίπεδα και κατευθύνονται από την είσοδο προς την έξοδο.
- Πλευρικών συνδέσεων (lateral), οι οποίες είναι συνδέσεις μεταξύ των νευρώνων στο ίδιο επίπεδο.
- Αναδρομικών συνδέσεων (recurrent), οι οποίες είναι συνδέσεις σε νευρώνα προηγούμενου επιπέδου και κατευθύνονται από την έξοδο προς την είσοδο.


Στις Εικόνες 3-1, 3-2 και 3-3 αποτυπώνονται τυπικές σχηματοποιήσεις της κάθε δομής.



Εικόνα 3-1: Συνδέσεις σε νευρωνικό δίκτυο πρόσθιας τροφοδότησης. Πηγή: de Vos (2003).



Εικόνα 3-2: Συνδέσεις σε νευρωνικό δίκτυο πλευρικών συνδέσεων. Πηγή: Gabrielsson and Gabrielsson (2006)



Εικόνα 3-3: Συνδέσεις σε νευρωνικό δίκτυο με αναδρομικές συνδέσεις. Πηγή: de Vos (2003)

### 3.2.5 Κανόνας διάδοσης

Ο κανόνας διάδοσης ενός δικτύου περιγράφει τον τρόπο με τον οποίο υπολογίζεται η καθαρή είσοδος,  $\mathbf{net}(t)$ , ενός νευρώνα από τις εξόδους των γειτονικών νευρώνων. Συνήθως, η είσοδος αυτή είναι το σταθμισμένο άθροισμα των εισόδων στο νευρώνα, δηλαδή οι έξοδοι των προηγούμενων νευρώνων πολλαπλασιασμένες με τα βάρη του αντίστοιχου μητρώου  $\mathbf{W}$ :  $\mathbf{net}(t) = \mathbf{W} \cdot \mathbf{o}(t)$ .

### 3.2.6 Κανόνας ενεργοποίησης

Ο κανόνας ενεργοποίησης, που συχνά καλείται και συνάρτηση μετάβασης, καθορίζει τη νέα τιμή ενεργοποίησης ενός νευρώνα βάσει της καθαρής εισόδου. Στην περίπτωση που χρησιμοποιείται μνήμη στον υπολογισμό περιλαμβάνονται και προηγούμενες τιμές ενεργοποίησης. Η συνάρτηση  $F$ , που λαμβάνει το διάνυσμα



ενεργοποίησης  $a(t)$  και τα διανύσματα  $net(t)$  κάθε διαφορετικού τύπου σύνδεσης, παράγει μια νέα κατάσταση ενεργοποίησης. Η  $F$  ποικίλλει από μια απλή συνάρτηση ταυτότητας,  $a(t) = net(t) = W \cdot o(t)$ , έως παραλλαγές γραμμικών ή και μη γραμμικών συναρτήσεων, όπως οι σιγμοειδείς. Οι πιο κοινές συναρτήσεις μετάβασης είναι:

- Η γραμμική συνάρτηση:

$$a(t + 1) = F(net(t)) = \alpha \cdot net(t)$$

- Η αυστηρού περιορισμού συνάρτηση:

$$a(t + 1) = F(net(t)) = \begin{cases} \alpha & \text{if } net(t) < z \\ \beta & \text{if } net(t) \geq z \end{cases}$$

- Η γραμμική συνάρτηση κορεσμού:

$$a(t + 1) = F(net(t)) = \begin{cases} \alpha & net(t) < z \\ net(t) + \gamma & \text{if } z \leq net(t) \leq y \\ \beta & net(t) > y \end{cases}$$

- Η συνάρτηση Gauss:

$$a(t + 1) = F(net(t)) = \exp\left(\frac{net(t)^2}{a}\right)$$

- Η δυαδική σιγμοειδής συνάρτηση:

$$a(t + 1) = F(net(t)) = \frac{1}{1 + \exp(-\alpha \cdot net(t))}$$

- Η σιγμοειδής συνάρτηση υπερβολικής εφαπτομένης:

$$a(t + 1) = F(net(t)) = \tanh(net(t))$$

### 3.2.7 Η διαδικασία εκμάθησης - εκπαίδευσης

Η διαδικασία εκμάθησης ή εκπαίδευσης ονομάζεται η διαδικασία κατά την οποία ένα τεχνητό νευρωνικό δίκτυο «μαθαίνει» τις σχέσεις που εμπεριέχονται μέσα σε ένα δείγμα των δεδομένων που του εμφανίζονται. Κατά τη διαδικασία αυτή το νευρωνικό δίκτυο προσαρμόζει τις εσωτερικές του παραμέτρους (τα βάρη  $w$  και τα συστηματικά σφάλματα  $b$  του κάθε νευρώνα), έτσι ώστε να παραμετροποιούνται οι σχέσεις μεταξύ των δεδομένων μέσω της δομής του δικτύου.

Ο τρόπος με τον οποίο εκπαιδεύεται το νευρωνικό δίκτυο είναι βασικό χαρακτηριστικό του, αφού οι τιμές των ιδιοτήτων των νευρώνων σχετίζονται άμεσα με τον επιλεγμένο αλγόριθμο. Ο αλγόριθμος που χρησιμοποιείται για τη βελτιστοποίηση των τιμών των βαρών και των συστηματικών σφαλμάτων των νευρώνων αποκαλείται «αλγόριθμος εκπαίδευσης» ή «αλγόριθμος εκμάθησης». Οι αλγόριθμοι αυτοί μπορούν να ταξινομηθούν σε δύο ευρείες κατηγορίες: της επιτηρούμενης (supervised) και της μη επιτηρούμενης (unsupervised) εκπαίδευσης.

Η επιτηρούμενη εκπαίδευση λειτουργεί όταν ο χρήστης (εκπαιδευτής) δίνει στο νευρωνικό δίκτυο τις τιμές εισόδου και τις τιμές επιθυμητής εξόδου – στόχους ή μια ένδειξη για την ορθότητα της εκτίμησης. Το δίκτυο εκτιμά κάποιες τιμές εξόδου, οι

οποίες στη συνέχεια συγκρίνονται με την επιθυμητή έξοδο (ή αξιολογούνται σύμφωνα με την αντίστοιχη ένδειξη). Η σύγκριση αυτή καθοδηγεί το νευρωνικό δίκτυο ώστε να δώσει μια καλή λύση. Η επιτηρούμενη εκπαίδευση έχει ξεκάθαρα σχέση με τις διαδικασίες βαθμονόμησης που χρησιμοποιούνται στις συμβατικές μεθόδους μοντελοποίησης.

Η μη επιτηρούμενη εκπαίδευση αναφέρεται στην περίπτωση που στο νευρωνικό δίκτυο δεν παρουσιάζονται οι επιθυμητές τιμές, αλλά μόνο οι τιμές εισόδου. Το νευρωνικό δίκτυο ομαδοποιεί τα δεδομένα εκπαίδευσης, βασιζόμενο στις ομοιότητες που εξάγει από τα δεδομένα εισόδου. Το νευρωνικό δίκτυο δεν επιβλέπεται αναφορικά με τα αποτελέσματα που υποτίθεται ότι πρέπει να βρει, αλλά αναλαμβάνει να ανακαλύψει τις πιθανές σχέσεις από τα δεδομένα εισόδου και βασιζόμενο σε αυτά να κάνει συγκεκριμένες προβλέψεις των εξόδων.

Οι παραπάνω τύποι εκπαίδευσης μπορούν να διαχωριστούν σε επιμέρους διαφορετικές κατηγορίες όπως φαίνεται στον Πίνακα 3-1. Οι μέθοδοι εκμάθησης σύμφωνα με την επίδοση είναι οι πιο διαδεδομένες για την επιτηρούμενη εκπαίδευση, ενώ για την μη επιτηρούμενη είναι αυτή της ανταγωνιστικής εκμάθησης.

Πίνακας 3-1: Κατηγοριοποίηση των αλγορίθμων εκπαίδευσης. Πηγή: de Vos (2003).

Επιτηρούμενη εκπαίδευση		Μη επιτηρούμενη εκπαίδευση	
Εκμάθηση επίδοσης (Performance learning)	Συμπτωματική εκμάθηση (Coincidence learning)	Ανταγωνιστική εκμάθηση (Competitive learning)	Εκμάθηση με φίλτρο (Filter learning)
Backpropagation	Hebbian learning	Kohonen learning	Grossberg learning
Μέθοδοι βασιζόμενοι σε αλγορίθμους βελτιστοποίησης: <ul style="list-style-type: none"> <li>• Conjugate gradient</li> <li>• (Quasi-) Newton</li> <li>• (Reduced) Levenberg - Marquardt</li> </ul>		Adaptive Resonance Theory (ART)	
Cascade – Correlation			

Στη συνέχεια, γίνεται μια σύντομη αναφορά για την εκμάθηση επίδοσης, καθώς όλες οι μέθοδοι που χρησιμοποιήθηκαν στην παρούσα εργασία ανήκουν σε αυτή την κατηγορία.

Όπως προαναφέρθηκε, όταν ένα νευρωνικό δίκτυο εκπαιδεύεται «με επιτήρηση» προσπαθεί να βρει τις βέλτιστες τιμές για τις εσωτερικές του παραμέτρους συγκρίνοντας τις εκτιμήσεις του με τις επιθυμητές τιμές και στη συνέχεια με αυξομειώνοντας τις τιμές των παραμέτρων ώστε οι εκτιμήσεις του να έχουν το ελάχιστο δυνατό σφάλμα σε σχέση με τις επιθυμητές τιμές. Η σύγκριση αυτή βασίζεται σε μια συνάρτηση επίδοσης, από όπου προκύπτει η ονομασία της μεθόδου. Βέβαια, είναι σημαντικό να αναφερθεί ότι ο όρος «συνάρτηση επίδοσης» είναι κάπως παραπλανητικός, καθώς η συνάρτηση αυτή εκφράζει την τιμή των υπολειπόμενων σφαλμάτων του νευρωνικού δικτύου και στόχος της εκπαίδευσης είναι η ελαχιστοποίησή τους.

Έστω ότι ένα νευρωνικό δίκτυο προσπαθεί να προσεγγίσει μια συγκεκριμένη διαδικασία η οποία χαρακτηρίζεται από ένα πλήθος  $n$  μεταβλητών. Η είσοδος του δικτύου είναι ένα διάνυσμα  $\mathbf{x}$  και τα βάρη του δικτύου σχηματίζουν έναν πίνακα  $\mathbf{W}$ . Η προσέγγιση του δικτύου είναι ένα διάνυσμα  $n$  μεταβλητών, το διάνυσμα  $\mathbf{y} = (y_1, y_2, \dots, y_n)$ , το οποίο είναι μια συνάρτηση των  $\mathbf{x}$  και  $\mathbf{W}$ . Οι πραγματικές – επιθυμητές τιμές αποτελούν ένα διάνυσμα τιμών στόχου  $\mathbf{t} = (t_1, t_2, \dots, t_n)$ . Η διαφορά μεταξύ των  $\mathbf{y}$  και  $\mathbf{t}$  χρησιμοποιείται για τον υπολογισμό του σφάλματος  $E$  της εκτίμησης. Προκειμένου το νευρωνικό δίκτυο να δημιουργήσει το διάνυσμα  $\mathbf{y}$  ώστε οι τιμές του να είναι όσο πιο κοντά γίνεται σε αυτές του  $\mathbf{t}$  εφαρμόζεται ένας αλγόριθμος για την εύρεση των βέλτιστων εσωτερικών παραμέτρων, οι οποίες ελαχιστοποιούν τη συνάρτηση σφάλματος  $E$ . Συνήθως, η συνάρτηση αυτή είναι το μέσο τετραγωνικό σφάλμα (MSE), καθώς χαρακτηρίζεται από συγκεκριμένα πλεονεκτήματα, όπως τη διασφάλιση ότι τα μεγαλύτερα σφάλματα έχουν μεγαλύτερη βαρύτητα από τα μικρότερα αλλά και επειδή λαμβάνει υπόψη τη συχνότητα εμφάνισης συγκεκριμένων τιμών. Η μαθηματική έκφραση του σφάλματος είναι:  $E = \sum_{i=1}^n (t_i - y_i)^2$ , όπου  $n$  είναι ο αριθμός των νευρώνων.

Κριτήρια που παίζουν ρόλο στην επιλογή της συνάρτησης εκτίμησης του σφάλματος αποτελούν η κατανομή των τιμών του και τα χαρακτηριστικά των διεργασιών που προσεγγίζονται. Άλλες συναρτήσεις που μπορούν να χρησιμοποιηθούν είναι το μέσο απόλυτο σφάλμα (στην περίπτωση που η εκτίμηση του μέσου όρου είναι σημαντικότερη από την εκτίμηση της διεργασίας στο πλήρες εύρος της) καθώς και παραλλαγές του μέσου τετραγωνικού σφάλματος, όπως η τετραγωνική του ρίζα.

Το διάνυσμα  $\mathbf{y}$  αποτελεί συνάρτηση των βαρών  $\mathbf{W}$ . Συνεπώς, η συνάρτηση του σφάλματος αποτελεί και αυτή συνάρτηση των βαρών  $\mathbf{W}$  του νευρωνικού δικτύου που αξιολογείται. Για κάθε συνδυασμό βαρών προκύπτει ένα διαφορετικό υπολειπόμενο σφάλμα. Το σφάλμα αποτελεί διάσταση του χώρου του

προβλήματος, η οποία μαζί με τις διαστάσεις των βαρών σχηματίζουν μια συγκεκριμένη επιφάνεια στο χώρο. Στόχος της διαδικασίας εκπαίδευσης είναι εύρεση του κατώτερου σημείου αυτής της επιφάνειας, δηλαδή την εύρεση του τιμών  $\mathbf{W}$  για τις οποίες το υπολειπόμενο σφάλμα είναι το ελάχιστο δυνατό. Η μορφή της επιφάνειας του σφάλματος εξαρτάται από τη συνάρτηση που χρησιμοποιείται για τον υπολογισμό του.

Το σημείο εκκίνησης από όπου ο αλγόριθμος εκπαίδευσης προσπαθεί να βρει το ελάχιστο σφάλμα καθορίζεται από τις αρχικές τιμές των βαρών του νευρωνικού δικτύου κατά την αρχική εκπαίδευση. Τα βάρη αυτά ορίζονται συνήθως σε μικρές τυχαίες τιμές. Στη συνέχεια, οι αλγόριθμοι εκπαίδευσης αναθεωρούν τα βάρη είτε μετά από την επεξεργασία κάθε διαφορετικού δείγματος εκπαίδευσης (step by step training) είτε μόνο μετά από την επεξεργασία ολόκληρου του συνόλου τιμών εκπαίδευσης (διαλείπουσα εκπαίδευση – batch training), όπου η αναθεώρηση γίνεται με την εφαρμογή μιας μέσης διόρθωσης σε κάθε ξεχωριστό δείγμα εκπαίδευσης. Σύμφωνα με τον de Vos (2003), προηγούμενες εφαρμογές έχουν αποδείξει ότι η διαλείπουσα εκπαίδευση είναι καταλληλότερη όταν χρησιμοποιούνται πιο εξεζητημένοι αλγόριθμοι. Για τη διαλείπουσα εκπαίδευση, η συνάρτηση σφάλματος που πρέπει να ελαχιστοποιηθεί είναι:

$$E = \sum_{q=1}^p \sum_{h=1}^n (t_{qh} - y_{qh})^2$$

όπου  $n$  είναι ο αριθμός των νευρώνων και  $p$  ο αριθμός των σειρών εκπαίδευσης.

Αυτού του είδους η εκπαίδευση εισάγει μια επίδραση φιλτραρίσματος στην εκπαίδευση του νευρωνικού δικτύου, η οποία σε μερικές περιπτώσεις μπορεί να είναι ωφέλιμη. Ωστόσο, αυτή η προσέγγιση απαιτεί περισσότερη μνήμη και προσδίδει επιπλέον υπολογιστική πολυπλοκότητα, ενώ γενικά εξαρτάται από την κάθε περίπτωση. Ένας καλός συμβιβασμός μεταξύ των δύο μεθόδων είναι η συσσώρευση των αλλαγών έπειτα από ορισμένα, και όχι όλα, τα δείγματα εκπαίδευσης πριν την αναθεώρηση των βαρών. Τέλος, είναι δυνατόν να υπάρχουν πολλοί διαφορετικοί συνδυασμοί των βαρών  $\mathbf{W}$ , για τους οποίους ελαχιστοποιείται το σφάλμα, και είναι επίσης δύσκολο να προσδιοριστεί εάν μια συγκεκριμένη τιμή αποτελεί τοπικό ή ολικό ελάχιστο.

### 3.2.8 Περιβάλλον λειτουργίας νευρωνικών δικτύων

Το περιβάλλον στο οποίο πρόκειται να εφαρμοστεί το τεχνητό νευρωνικό δίκτυο είναι μια χρονικά μεταβαλλόμενη στοχαστική συνάρτηση στον χώρο των εισερχόμενων στοιχείων. Επομένως, σε κάθε χρονική στιγμή υπάρχει κάποια πιθανότητα ότι οποιαδήποτε από τις πιθανές σειρές εισόδου επηρεάζει τις μονάδες εισόδου. Αυτή η συνάρτηση πιθανότητας μπορεί, γενικά, να εξαρτάται από την ιστορία των εισόδων του συστήματος, καθώς και από τις εξόδους του συστήματος.

### 3.3 Πλεονεκτήματα και μειονεκτήματα νευρωνικών δικτύων

Τα νευρωνικά δίκτυα παρουσιάζουν μεγάλες διαφορές στην επίδοσή τους αναφορικά με το διαφορετικό πλαίσιο σύμφωνα με το οποίο αυτή εξετάζεται. Αρχικά, παρουσιάζουν πολύ υψηλή επίδοση στην ενσωμάτωση με άλλους αλγόριθμους για τη διαμόρφωση υβριδικών μοντέλων. Επιπλέον, παρουσιάζουν υψηλή επίδοση αναφορικά με την ταχύτητα απόκρισης, τη δυνατότητα συμπίεσης (κατάληψη μικρού χώρου στη μνήμη), την αντοχή στην πολυπλοκότητα του προβλήματος και την ανεξαρτητοποίηση από τους εκάστοτε ειδικούς. Ακόμη, υψηλή επίδοση παρουσιάζουν στην ακρίβεια και την προσαρμοστικότητα, αλλά με την προϋπόθεση ότι έχουν χρησιμοποιηθεί κατανοητά και αντιπροσωπευτικά δεδομένα κατά την εφαρμογή και την εκπαίδευσή τους. Μια μέτρια επίδοση καταγράφεται στην δυνατότητα κλιμάκωσης, γεγονός που εξαρτάται και από την πολυπλοκότητα του προβλήματος και τη διαθεσιμότητα των δεδομένων, καθώς επίσης και αναφορικά με ανοχή στο θόρυβο των δεδομένων, πρόβλημα που θα μπορούσε να ξεπεραστεί μέσω της προεπεξεργασίας τους. Αναφορικά με την ταχύτητα ανάπτυξής τους, γενικά παρουσιάζουν μέτρια επίδοση, γεγονός που εξαρτάται και από την κατανόηση των διαδικασιών, την ταχύτητα του υπολογιστή και τον αλγόριθμο εκμάθησης. Τα νευρωνικά δίκτυα φαίνεται να παρουσιάζουν χαμηλή επίδοση κατά την επεξεργασία «αραιών» δεδομένων. Αναφορικά με τη διαύγεια της επεξεργασίας και δυνατότητα επεξήγησης των εσωτερικών λειτουργιών, παρουσιάζεται επίσης χαμηλή επίδοση, είναι όμως δυνατή η χρήση ορισμένων αναλυτικών μαθηματικών μεθόδων για ανάλυση ευαισθησίας και επομένως για έμμεση εξαγωγή κάποιων επεξηγήσεων. Τέλος, παρουσιάζουν χαμηλή επίδοση σε σχέση με τη χρήση των υπολογιστικών πόρων. Ωστόσο, αυτό εξαρτάται από τον όγκο των δεδομένων και το μέγεθος του νευρωνικού δικτύου, ενώ από τη στιγμή που αυτό έχει εκπαιδευτεί απαιτεί πολύ λιγότερους πόρους για την εφαρμογή του.

Ο Zealand *et al.* (1999) καταγράφουν αρκετά πλεονεκτήματα των τεχνητών νευρωνικών δικτύων. Αρχικά, τα νευρωνικά δίκτυα μπορούν να εξάγουν λύσεις σε συγκεκριμένα προβλήματα βάσει των δεδομένων, χωρίς να έχουν πρότερη γνώση των σχέσεων μεταξύ αυτών. Τις σχέσεις αυτές τις συμπεραίνουν εμπειρικά από τα δεδομένα. Αυτό σημαίνει ότι όταν χρησιμοποιούνται σε ένα συγκεκριμένο πεδίο, τότε απαιτείται σχετικά μικρή ειδική γνώση για την ανάπτυξη τέτοιου είδους εφαρμογών, ενώ η αντίστοιχη ειδική γνώση πρέπει σίγουρα να είναι μεγαλύτερη όταν γίνεται χρήση των συμβατικών τεχνικών μοντελοποίησης. Επιπλέον, προκειμένου να έχουν συνεκτικές αποκρίσεις αυτορυθμίζονται, μαθαίνοντας τις ομοιότητες μεταξύ των δεδομένων από τα δοσμένα δείγματα και είναι σε θέση τόσο να εξάγουν τα απαραίτητα χαρακτηριστικά όταν οι είσοδοι περιλαμβάνουν μη σχετικά δεδομένα, όσο και να γενικεύουν από προηγούμενα δείγματα σε νέα, γεγονός χρήσιμο όταν τα πραγματικά δεδομένα περιλαμβάνουν θόρυβο ή είναι

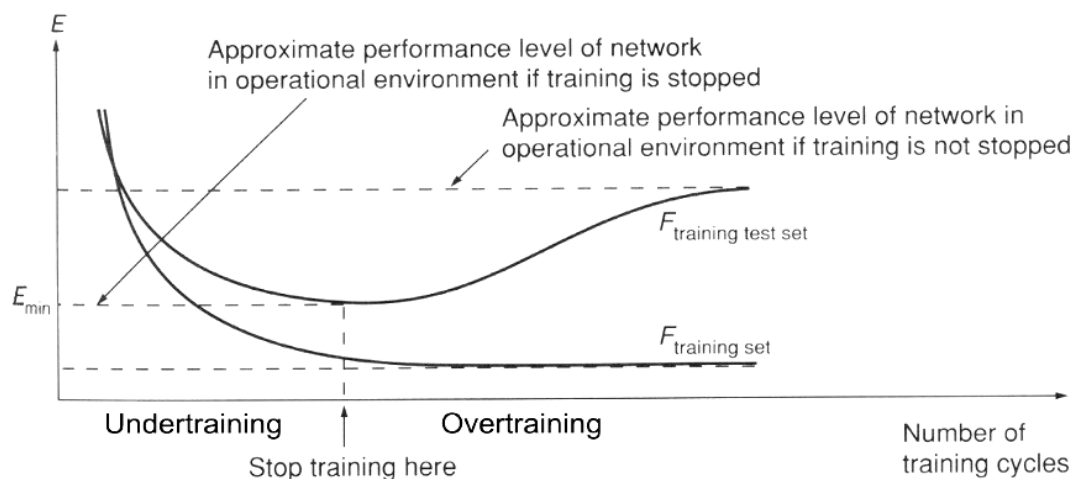
ελλιπή. Τέλος, τα τεχνητά νευρωνικά δίκτυα είναι μη γραμμικά, επομένως είναι σε θέση να επιλύσουν ορισμένα πολύπλοκα προβλήματα με μεγαλύτερη ακρίβεια από τις γραμμικές τεχνικές. Το γεγονός αυτό σε συνδυασμό με το ότι περιλαμβάνουν πολλές πανομοιότυπες και ανεξάρτητες μεταξύ τους διεργασίες, οι οποίες μπορούν να εκτελούνται ταυτόχρονα, τα καθιστούν ένα ισχυρό και υπολογιστικά γρήγορο εργαλείο, σε συνάρτηση, βέβαια, και με την επίδοση του κάθε νευρωνικού δικτύου.

Από την άλλη πλευρά, έχουν καταγραφεί και ορισμένα μειονεκτήματα των συγκεκριμένων εφαρμογών. Κατ' αρχάς, υπάρχει η πιθανότητα αποτυχίας στην παραγωγή μιας ικανοποιητικής λύσης, είτε επειδή μπορεί να μην υπάρχουν οι σχέσεις τις οποίες το νευρωνικό δίκτυο καλείται να μάθει είτε επειδή τα δεδομένα είναι ανεπαρκή σε μέγεθος ή σε ποιότητα. Ακόμη, δεν είναι δυνατή η εκ των προτέρων γνώση του βέλτιστου συνόλου δεδομένων για την εκπαίδευση, της βέλτιστης δομής καθώς και άλλων σχεδιαστικών παραμέτρων. Οι παράμετροι αυτές συνήθως βρίσκονται μέσω διαδικασιών δοκιμής και σφάλματος. Επίσης, τα νευρωνικά δίκτυα δεν παρουσιάζουν αρκετά καλή απόδοση όταν επεκτείνονται σε δεδομένα εκτός του εύρους των δεδομένων εκπαίδευσης και δεν είναι σε θέση να ανταποκριθούν σε σημαντικές αλλαγές στο σύστημα, διότι έχει θεωρηθεί ότι οι σχέσεις σύμφωνα με τις οποίες έχουν εκπαιδευτεί, είναι αυτές που θα εξακολουθούν να υπάρχουν και στο μέλλον. Τέλος, είναι δύσκολο να επιλεγθεί εξ αρχής το βέλτιστο σετ τιμών των εσωτερικών παραμέτρων του δικτύου σε κάθε πρόβλημα. Αν και οι αλγόριθμοι εκπαίδευσης μπορούν να τις εκτιμήσουν ικανοποιητικά, είναι αρκετά δύσκολο να εκτιμηθεί εάν το συγκεκριμένο σύνολο παραμέτρων αποτελεί ολικό ή τοπικό ελάχιστο, πόσο μάλλον όταν πρόκειται και για μια περίπλοκη επιφάνεια σφάλματος. Άλλο πρόβλημα αποτελεί το γεγονός ότι για διαφορετικές χρονικές περιόδους ή για περιόδους όπου κυριαρχούν διαφορετικές διεργασίες που περιγράφονται από τα δεδομένα εκπαίδευσης, θα υπάρχουν πιθανώς διαφορετικά σύνολα παραμέτρων που δίνουν μια καλή προσαρμογή στα δεδομένα δοκιμής για κάθε μια από αυτές τις καταστάσεις και διαφορετικά σύνολα που δίνουν καλές προσαρμογές για τις καταστάσεις αυτές συνολικά. Επομένως, τα διαφορετικά βέλτιστα μπορεί να είναι σε διαφορετικά σημεία του χώρου των παραμέτρων, κάνοντας ακόμα πιο περίπλοκη της διαδικασία της βελτιστοποίησης.

Είναι σημαντικό να αναφερθεί ότι ένας λόγος για τον οποίο τα τεχνητά νευρωνικά δίκτυα αντιμετωπίζονται με σκεπτικισμό είναι η έλλειψη δυνατότητας επεξηγήσεων αναφορικά με ορισμένα πεδία εφαρμογών, καθώς υπάρχει έλλειψη φυσικών σχέσεων και εννοιολογίας στα συγκεκριμένα μοντέλα. Προκειμένου να κερδίσουν μια ευρύτερη αποδοχή, είναι σημαντικό να αποκτήσουν μια ικανότητα επεξήγησης μετά την ολοκλήρωση της εκπαίδευσης. Συνήθως, τα περισσότερα νευρωνικά δίκτυα δεν είναι σε θέση να εξηγήσουν με κατανοητό τρόπο τις βασικές επεξεργασίες, σύμφωνα με τις οποίες φτάνουν σε μια απόφαση.

Δύο ακόμη σημαντικά προβλήματα που αντιμετωπίζονται κατά την εφαρμογή των νευρωνικών δικτύων είναι η υπερεκπαίδευση (overtraining) και η υποπροσαρμογή (underfitting). Η υπερεκπαίδευση είναι συνήθως αποτέλεσμα τριών παραγόντων, χωριστά ή και συνδυαστικά, της χρήσης μιας δομής του νευρωνικού δικτύου που μπορεί να είναι πιο περίπλοκη από τις συσχετίσεις που μοντελοποιούνται, του μεγάλου αριθμού επαναλήψεων εκπαίδευσης του δικτύου και της χρήσης ακατάλληλων συνόλων εκπαίδευσης. Ο πρώτος από τους προαναφερθέντες παράγοντες αποτελεί ουσιαστικά την υπερπαραμετροποίηση που συναντάται και σε όλα τα προβλήματα μοντελοποίησης. Ενώ ο δεύτερος και ο τρίτος αποτελούν λόγους υπερεκπαίδευσης, διότι στο νευρωνικό δίκτυο παρουσιάζονται πολύ όμοιες μεταξύ τους πληροφορίες, με αποτέλεσμα μετά την εκπαίδευση το νευρωνικό δίκτυο να αποτυγχάνει να προσεγγίσει τις σχέσεις των δεδομένων που διαφέρουν έστω και ελάχιστα από τις σχέσεις μεταξύ των δεδομένων εκπαίδευσης. Ουσιαστικά, σε αυτή την περίπτωση το δίκτυο δεν αρκείται στις απαραίτητες σχέσεις, αλλά ανακαλύπτει και άλλες, οι οποίες ωστόσο είναι πλασματικές.

Πιθανή λύση για το πρόβλημα της υπερεκπαίδευσης είναι να διατηρηθεί ξεχωριστά ένα δεύτερο σύνολο δεδομένων, το οποίο ονομάζεται «test data» ή «cross-training data», προκειμένου να χρησιμοποιηθεί για περιοδικό έλεγχο των εκτιμήσεων του νευρωνικού δικτύου σε σχέση με τις εκτιμήσεις των δεδομένων εκπαίδευσης. Το καλύτερο σημείο για τον τερματισμό της εκπαίδευσης είναι όταν το νευρωνικό δίκτυο παρουσιάζει αρκετά καλή απόδοση και στα δύο σύνολα δεδομένων, όπως φαίνεται στην Εικόνα 3-4.



Εικόνα 3-4: Διάγραμμα του σφάλματος σε σχέση με το βήμα επανάληψης της εκπαιδευτικού αλγόριθμου. Πηγή: de Vos (2003)

Ο λόγος για τον οποίο η μέθοδος αυτή οδηγεί σε καλύτερα αποτελέσματα είναι επειδή αντί η αυξομείωση των παραμέτρων να στηρίζεται σε μία μόνο πραγματοποίηση της στοχαστικής μεταβλητής της εξόδου (δεδομένα εκπαίδευσης), λαμβάνει υπόψη και μια δεύτερη πραγματοποίηση για της τιμής αυτής. Επομένως,

με αυτό τον τρόπο, το νευρωνικό δίκτυο θα είναι, θεωρητικά, εγγύτερα στον πραγματικό μέσο της στοχαστικής διαδικασίας. Η χρήση ενός δεύτερου ή ακόμη και τρίτου σετ δεδομένων για τεστ είναι σε θέση να βελτιώσει την ικανότητα γενίκευσης του νευρωνικού δικτύου, όμως απαιτείται μεγάλος όγκος δεδομένων.

Μια δεύτερη λύση για την αποτροπή του συγκεκριμένου φαινομένου είναι η γενίκευση (regularization). Η μέθοδος αυτή περιλαμβάνει την τροποποίηση της συνάρτησης σφάλματος που χρησιμοποιείται στους αλγορίθμους εκπαίδευσης σύμφωνα με την επίδοση. Για παράδειγμα, αν χρησιμοποιείται το μέσο τετραγωνικό σφάλμα, η γενίκευση του δικτύου μπορεί να βελτιωθεί με την προσθήκη ενός όρου, ο οποίος αποτελείται από το μέσο όρο του αθροίσματος των τετραγώνων των παραμέτρων ( $w$  και  $b$ ) του νευρωνικού δικτύου, ήτοι:

$$MSE_{reg} = \gamma \cdot MSE + (1 - \gamma) \cdot MSW \quad (3.1)$$

όπου:

$$MSW = \frac{1}{n} \cdot \sum_{j=1}^n w_j^2$$

Η χρήση της συγκεκριμένης συνάρτησης επίδοσης έχει ως αποτέλεσμα το νευρωνικό δίκτυο να αποκτήσει μικρότερες τιμές για τα βάρη και τα συστηματικά σφάλματα, γεγονός το οποίο οδηγεί το δίκτυο σε ομαλότερες αποκρίσεις και να μην είναι τόσο επιρρεπές στην υπερεκπαίδευση.

Μια τελευταία επισήμανση σχετικά με την υπερεκπαίδευση είναι ότι το αποτέλεσμα της επεξεργασίας, όπως για παράδειγμα τα χαρακτηριστικά της χρονοσειράς που δίνει το καλύτερο δυνατό αποτέλεσμα, είναι άγνωστο. Επομένως, είναι αδύνατον να βγει συμπέρασμα υπερεκπαίδευσης από μια εξαιρετικά ακριβή προσέγγιση που θα έχει προκύψει μόνο από τα δεδομένα εκπαίδευσης. Ακόμη, αν τα μοντέλα νευρωνικών δικτύων δείχνουν καλά αποτελέσματα κατά την εκπαίδευση, αλλά αποτυγχάνουν να δώσουν υψηλή ακρίβεια σε άλλα σύνολα δεδομένων, δεν είναι εύκολο να ειπωθεί αν αυτό συμβαίνει λόγω υπερεκπαίδευσης ή λόγω εσφαλμένης προσέγγισης, καθώς δεν υπάρχει ξεκάθαρη εικόνα για τη συμπεριφορά των νευρωνικών δικτύων. Παρόλα αυτά, η διατήρηση ενός συνόλου δεδομένων για cross training μειώνει την πιθανότητα εμφάνισης υπερεκπαίδευσης και σίγουρα αποτελεί μια καλή επιλογή ακόμα και εάν δεν αναμένεται υπερεκπαίδευσης.

Η υποπροσαρμογή είναι ένα φαινόμενο το οποίο συμβαίνει ως αποτέλεσμα ακατάλληλης εκπαίδευσης ενός νευρωνικού δικτύου. Εάν η εκπαίδευση τερματίζεται πριν το σφάλμα της εκπαίδευσης γίνει το ελάχιστο δυνατό, τότε το νευρωνικό δίκτυο δεν προσεγγίζει κατά το βέλτιστο τρόπο τις σχέσεις μεταξύ των




συγκεκριμένων δεδομένων. Ένας σύνθητος λόγος υποπροσαρμογής είναι ότι η εκπαίδευση τερματίζεται πολύ νωρίς, για παράδειγμα θέτοντας μια μικρή τιμή ως μέγιστο αριθμό επαναλήψεων εκπαίδευσης ή θέτοντας ένα υψηλό στόχο (μικρή τιμή) για το αποδεκτό σφάλμα της εκπαίδευσης, ενώ άλλος λόγος αποτελεί η χρήση μη επαρκούς δείγματος για την εκπαίδευση. Πρακτικά, σχεδόν σε όλα τα νευρωνικά δίκτυα υπάρχει έστω και μια ελάχιστη υποπροσαρμογή, λόγω του γεγονότος ότι ένας αλγόριθμος εκπαίδευσης συχνά αποτυγχάνει να φτάσει το ολικό ελάχιστο μιας πολύπλοκης συνάρτησης σφάλματος, ενώ ακόμη κι αν συμβεί κάτι τέτοιο, τότε πιθανότατα το συγκεκριμένο ολικό ελάχιστο δεν ταυτίζεται με το αντίστοιχο ολικό ελάχιστο που προκύπτει από τη διαδικασία εκπαίδευσης.

### **3.4 Τα τεχνητά νευρωνικά δίκτυα ως υποκατάστατα μοντέλα**

Τα τεχνητά νευρωνικά δίκτυα πρόσθιας τροφοδότησης (feedforward artificial neural networks) είναι αρκετά ευέλικτα εργαλεία, τα οποία χρησιμοποιούνται συχνά για την προσέγγιση συναρτήσεων. Ο πιο δημοφιλής τύπος νευρωνικών δικτύων είναι οι αντιληπτήρες πολλαπλών επιπέδων (multi-layer perceptrons – MLP) και στην ενότητα αυτή με τον όρο (τεχνητά) νευρωνικά δίκτυα ή ANN's για συντομία θα γίνεται αναφορά σε αυτό τον τύπο νευρωνικών δικτύων. Η ανάπτυξη και εφαρμογή των νευρωνικών δικτύων περιλαμβάνει πολλαπλές υποκειμενικές αποφάσεις τις οποίες πρέπει να λάβει ο χρήστης. Ο καθορισμός της βέλτιστης δομής του νευρωνικού δικτύου για ένα συγκεκριμένο πρόβλημα είναι πιθανότατα ο πιο σημαντικός παράγοντας κατά το σχεδιασμό ενός υποκατάστατου μοντέλου βασισμένο σε νευρωνικά δίκτυα. Οι δομικές παράμετροι – αποφάσεις των ANN's περιλαμβάνουν τον αριθμό των «κρυμμένων» επιπέδων (hidden layers), τον αριθμό των νευρώνων σε κάθε επίπεδο και τον τύπο των συναρτήσεων μετάβασης.

Για τον καθορισμό της κατάλληλης δομής, ανάλογα με το εκάστοτε πρόβλημα, έχουν αναπτυχθεί διάφορες μεθοδολογίες, οι οποίες περιλαμβάνουν μεθόδους βασισμένες σε στρατηγικές «growing and/or pruning», μεθόδους βασισμένες στη γεωμετρική ερμηνεία του δικτύου και μεθόδους που βασίζονται σε Bayesian προσεγγίσεις. Ωστόσο, οι μέθοδοι αυτές, κάθε μία από τις οποίες μπορεί να δώσει μια διαφορετική, αλλά εξίσου κατάλληλη λύση, απαιτούν εκτεταμένες αριθμητικές αναλύσεις των δεδομένων εκπαίδευσης, καθώς γενικά προσπαθούν να τεστάρουν συστηματικά διαφορετικές δομές του δικτύου. Παρά την ύπαρξη των μεθοδολογιών αυτών, η προσέγγιση μέσω δοκιμής και σφάλματος για τον καθορισμό του αριθμού των κρυμμένων νευρώνων είναι αυτή που χρησιμοποιείται σε όλα τα ANN's που λειτουργούν ως υποκατάστατα μοντέλα στις μελέτες που αναφέρονται στους Πίνακες 3-2 και 3-3. Εναλλακτικές δομές πέραν των MLP, όπως για παράδειγμα τα γενικευμένης παλινδρόμησης νευρωνικά δίκτυα (GRNN), θα ήταν δυνατό να παρέχουν και άλλους τρόπους για τη μείωση και την εξάλειψη της υποκειμενικότητας της δόμησης ενός νευρωνικού δικτύου.

Τα ANN's με ένα σιγμοειδές κρυμμένο επίπεδο και ένα γραμμικό επίπεδο εξόδου, όπως αυτό που φαίνεται στην Εικόνα 3-5, έχει αποδειχθεί ότι είναι ικανά να προσεγγίσουν οποιαδήποτε συνάρτηση με την επιθυμητή ακρίβεια, δεδομένου ότι πληρούνται οι σχετικές συνθήκες (Hornik *et al.*, 1989; Leshno *et al.*, 1993). Οι όροι «σιγμοειδές» και «γραμμικό» που χαρακτηρίζουν τα επίπεδα αναφέρονται στις αντίστοιχες συναρτήσεις μετάβασης του κάθε επιπέδου. Παρόλο που ένα κρυμμένο επίπεδο είναι αρκετό ώστε το νευρωνικό δίκτυο να προσεγγίσει οποιαδήποτε δοσμένη συνάρτηση, μερικοί ερευνητές διαφωνούν ότι τα νευρωνικά δίκτυα με περισσότερα από ένα κρυμμένα επίπεδα μπορεί να απαιτούν λιγότερους νευρώνες για την προσέγγιση της ίδιας συνάρτησης. Θεωρητικά έχειδειχθεί από τους Tamura and Tateishi (1997) ότι για να είναι ακριβής προσομοιωτής ένα νευρωνικό δίκτυο με δύο κρυμμένα επίπεδα, απαιτείται αρκετά μικρότερος αριθμός κρυμμένων νευρώνων σε σχέση με ένα νευρωνικό δίκτυο με ένα κρυμμένο επίπεδο. Ωστόσο, η ανάπτυξη ενός ακριβούς προσομοιωτή δεν αποτελεί το στόχο των χειριστών των νευρωνικών δικτύων, εκτός από περιπτώσεις όπου χρησιμοποιείται ως υποκατάστατο της επιφάνειας απόκρισης ενός ντετερμινιστικού μοντέλου προσομοίωσης, καθώς τα δεδομένα που χρησιμοποιούνται είναι ευάλωτα στο θόρυβο και ο αριθμός των σετ εισόδων – στόχων είναι αρκετά μεγάλος. Η ανάγκη για ακριβείς προσομοιωτές αποτελεί μια ιδιαίτερη περίπτωση. Επιπλέον, για να είναι ακριβείς προσομοιωτές, απαιτείται η δομή των νευρωνικών δικτύων να είναι υπερβολικά ογκώδης, ενώ τέτοια δίκτυα είναι πιθανό να αστοχήσουν κατά τη γενίκευση και να έχουν χαμηλή απόδοση σε περιοχές των εισόδων χωρίς δεδομένα.



Εικόνα 3-5: ANN με ένα σιγμοειδές κρυμμένο επίπεδο μεγέθους 10 νευρώνων και ένα γραμμικό επίπεδο εξόδου μεγέθους 2 νευρώνων.

Από μια πρακτικότερη άποψη, οι de Villiers and Barnard (1993), μέσω εκτενών αριθμητικών πειραμάτων, δείχνουν ότι νευρωνικά δίκτυα με ένα κρυμμένο επίπεδο είναι ανώτερα από δίκτυα με περισσότερα κρυμμένα επίπεδα ίδιας πολυπλοκότητας, κυρίως λόγω του γεγονότος ότι τα δεύτερα είναι περισσότερο επιρρεπή στο να βρεθούν σε μη επιθυμητά τοπικά ελάχιστα κατά την εκπαίδευσή τους. Οι χρήστες έχουν την τάση να χρησιμοποιούν νευρωνικά δίκτυα ενός κρυμμένου επιπέδου, όπως συμβαίνει και στις 10 από τις 11 εφαρμογές που καταγράφονται στους Πίνακες 3-2 και 3-3.

Τα ANN's ενός κρυμμένου επιπέδου προσεγγίζουν την επιφάνεια απόκρισης με τον συνδυασμό  $m$  σιγμοειδών μονάδων (γραμμών, χώρων, υπερεπιπέδων στο μονοδιάστατο, δισδιάστατο, τρισδιάστατο ή και πολυδιάστατο χώρο του προβλήματος), όπου  $m$  είναι ο αριθμός των κρυμμένων νευρώνων. Ο αριθμός των παραμέτρων (βάρη και συστηματικά σφάλματα) ενός μονού-κρυμμένου- επιπέδου νευρωνικού δικτύου είναι  $m \times (2 + D) + 1$ , όπου  $D$  η διάσταση του χώρου εισόδου (π.χ., ο αριθμός των μεταβλητών εισόδου του υποκατάστατου επιφάνειας απόκρισης). Ο βέλτιστος αριθμός των κρυμμένων νευρώνων,  $m$ , είναι συνάρτηση της μορφής και της πολυπλοκότητας της υποκείμενης (προς προσομοίωση) συνάρτησης (Xiang *et al.*, 2005), καθώς και της διαθεσιμότητας δεδομένων για χρήση στην εκπαίδευση (Razavi *et al.*, 2012a). Στα πλαίσια μοντελοποίησης με υποκατάστατα επιφάνειας απόκρισης, η μορφή της αρχικής συνάρτησης συνήθως  $p$ , είναι ο κύριος παράγοντας για τον καθορισμό των νευρώνων,  $m$ . Συνήθως, είναι προτιμότερο ο αριθμός των παραμέτρων των νευρωνικών δικτύων να είναι πολύ μικρότερος από τις θέσεις σχεδιασμού, παρόλο που μαθηματικά δεν υπάρχει όριο όταν ο αριθμός των παραμέτρων είναι μεγαλύτερος από τις θέσεις σχεδιασμού Maier and Dandy (2000).

Μια πιθανή προσέγγιση του προβλήματος είναι η δυναμική αύξηση του αριθμού  $m$  καθώς αυξάνεται ο αριθμός των παρεχόμενων θέσεων σχεδιασμού. Γενικά, για ένα συγκεκριμένο πρόβλημα, υπάρχουν πολλές διαφορετικές κατάλληλες δομές και για κάθε δομή υπάρχουν πολλά διαφορετικά κατάλληλα σετ βαρών και συστηματικών σφαλμάτων. Ο όρος «κατάλληλος» αναφέρεται στις δομές και τις παραμέτρους των νευρωνικών δικτύων που αναπαριστούν ικανοποιητικά τα δεδομένα εκπαίδευσης. Η εκπαίδευση των νευρικών δικτύων, δηλ. η ρύθμιση των παραμέτρων τους, μπορεί να είναι μια χρονοβόρα διαδικασία βελτιστοποίησης αναλόγως τη δομή του δικτύου και τη μέθοδο εκπαίδευσης που χρησιμοποιείται. Παραλλαγές δεύτερης τάξης αλγορίθμων «προς τα πίσω διάδοσης» (backpropagation algorithms) είναι οι περισσότερο υπολογιστικά αποδοτικές μέθοδοι εκπαίδευσης των νευρωνικών δικτύων (Hamm *et al.*, 2007), ενώ ο ρόλος κάθε παραμέτρου ενός νευρωνικού δικτύου στη διαμόρφωση της απόκρισής του δεν είναι ξεκάθαρος.

Γενικά, τα νευρωνικά δίκτυα δεν θεωρούνται κατάλληλα εργαλεία μεταμοντελοποίησης για περιορισμένο υπολογιστικό «προϋπολογισμό», ενώ αντί αυτών προτείνονται οι μέθοδοι krigging και RBF, καθώς επιδεικνύουν συνολικά καλύτερη επίδοση σε τέτοιες συνθήκες (Razavi *et al.*, 2012b). Επιπρόσθετα σε αυτό, όπως φανεί και από τα συμπεράσματα της παρούσας εργασίας, τα νευρωνικά δίκτυα απαιτούν αρκετά μεγάλο ποσοστό του υπολογιστικού «προϋπολογισμού» για τον προγραμματισμό τους, καθώς πρέπει να γίνουν αρκετές δοκιμές για την εύρεση μιας κατάλληλης δομής, αλλά και για την εκπαίδευσή τους. Ωστόσο, από τη στιγμή που θα δημιουργηθεί ένα αποτελεσματικό νευρωνικό δίκτυο απαιτεί πολύ λιγότερο

υπολογιστικό χρόνο σε σχέση με ένα μοντέλο προσομοίωσης βασισμένο σε αναλυτικές σχέσεις.

Πίνακας 3-2: Κατάλογος εφαρμογών υποκατάστατων μοντέλων στους υδατικούς πόρους από την ανασκόπηση των Razavi *et al.*, 2012. Μέρος Α.

Work by:	Type of problem	Type of metamodel	Type of Search or Sampling Algorithm	Type of framework	Number and Type of explanatory variables	Computational saving
<i>Johnson and Rogers</i> [2000]	Groundwater remediation	Linear Regression and Neural network (single hidden layer)	Simulated Annealing	Basic sequential framework	30 Continuous	Not reported
<i>Liong et al.</i> [2001]	Automatic calibration of the HydroWorks watershed model (Bi-objective)	Neural network (three hidden layers)	accelerated convergence GA (ACGA)	Basic sequential framework	8 Continuous	Not reported
<i>Khu and Werner</i> [2003]	Uncertainty based Automatic calibration of the SWMM rainfall-runoff model	Neural network (single hidden layer)	GLUE	Basic sequential framework (Instead of formal DoE, GA with niching was used to generate design sites)	8 Continuous	80% in number of full evaluations
<i>Schultz et al.</i> [2004; 2006]	Uncertainty analysis of a water quality model for regulatory decision support	Linear Regression, polynomial, and process-inspired simple functions	Monte Carlo Simulation	Basic sequential framework	9 Continuous	Not reported
<i>Khu et al.</i> [2004]	Automatic calibration of MIKE11/NAM	Radial basis functions	Genetic algorithms	Metamodel-embedded evolution framework, No formal DoE	9 Continuous	60% in number of full evaluations
<i>Regis and Shoemaker</i> [2004]	Groundwater bioremediation optimization and 17 test functions	Radial basis functions and second-order polynomial (both local)	$(\mu, \lambda)$ -evolution strategy	Metamodel-embedded evolution framework	12 Continuous	Not reported
<i>Ostfeld and Salomons</i> [2005]	Automatic calibration of CE-QUAL-W2 water quality model	$k$ -nearest neighbors (kNN)	Genetic algorithms	Metamodel-embedded evolution framework, No formal DoE	3 Continuous	Not reported
<i>Mugunthan et al.</i> [2005]	Automatic calibration of a groundwater bioremediation model	Radial basis functions	Gaussian random sampler	Approximation uncertainty based framework	8 Continuous	Not reported
<i>Broad et al.</i> [2005]	Water distribution system design optimization	Neural network (single hidden layer)	Genetic algorithms	Basic sequential framework	22 Discrete	21% of CPU time
<i>Mugunthan and Shoemaker</i> [2006]	Automatic calibration and parameter uncertainty analysis of groundwater models	Radial basis functions	Gaussian random sampler	Approximation uncertainty based framework	3 and 7 Continuous	More than 87% in number of full evaluations *
<i>Bau' and Mayer</i> [2006]	Pump-and-treat optimization (Bi-objective)	Kriging	Complete enumeration	Approximation uncertainty based framework	4 Discrete	Not reported
<i>Yan and Minsker</i> [2006]	Groundwater remediation design – MODFLOW and RT3D models used for flow field and contaminant concentration	Neural network (single hidden layer)	Genetic algorithms	Metamodel-embedded evolution framework, No formal DoE	9 and 28 Mixed integer	85-90% in number of full evaluations
<i>Zou et al.</i> [2007]	Automatic calibration of the WASP water quality model	Neural network (single hidden layer)	Genetic algorithms	Basic sequential and adaptive-recursive frameworks	19 Continuous	97% of CPU time
<i>Regis and Shoemaker</i> [2007a]	Groundwater bioremediation optimization and 17 test functions	Radial basis functions	Gaussian and uniform random samplers	Approximation uncertainty based framework	Test functions: 2-14 Groundwater problem: 12 Continuous	Not reported
<i>Shoemaker et al.</i> [2007]	Automatic calibration of two SWAT watershed models	Radial basis functions	$(\mu, \lambda)$ -evolution strategy	Metamodel-embedded evolution framework, No formal DoE	8 and 14 Continuous	Not reported
<i>Hemker et al.</i> [2008]	Well field design optimization and hydraulic capture problem	Kriging	Branch-and-bound on main problem - Sequential quadratic programming on sub-problems	Adaptive-recursive framework	5+ Integer with 15+ Continuous	Not reported
<i>Bliznyuk et al.</i> [2008]	Automatic calibration and Bayesian uncertainty analysis of an environmental model	Radial basis functions	Markov-Chain Monte Carlo Sampler	Basic sequential framework	4 Continuous	More than 90% in number of full evaluations

\* Computational saving is not explicitly mentioned in the paper, and this value is interpreted based on the available information.

**Πίνακας 3-3: Κατάλογος εφαρμογών υποκατάστατων μοντέλων στους υδατικούς πόρους από την ανασκόπηση των Razavi *et al.*, 2012. Μέρος Β.**

Work by:	Type of problem	Type of metamodel	Type of Search or Sampling Algorithm	Type of framework	Number and Type of explanatory variables	Computational saving
<i>Kourakos and Mantoglou</i> [2009]	Coastal aquifer pumping management	Neural network (modular) single hidden layer	Evolutionary Annealing Simplex Scheme optimization	Metamodel-embedded evolution framework, No formal DoE	34 Continuous (For metamodeling, disaggregated into smaller sub-sets having members with negligible correlations with members of other sub-sets)	95% of CPU time
<i>Fen et al.</i> [2009]	Cost and contaminant removal optimization for soil vapor extraction system design	Second-order polynomials and exponential functions	Genetic algorithms	Adaptive-recursive framework	6 and 9 Continuous	40-94% of total CPU time across 4 case studies *
<i>Behzadian et al.</i> [2009]	Water distribution system monitoring locations optimization (Bi-objective)	Neural network (single hidden layer)	NSGA-II	Metamodel-embedded evolution framework, No DoE	15 and 50 Discrete	87% and 96% of CPU time (~34% of total saving is due to caching)
<i>Zhang et al.</i> [2009]	Uncertainty-based automatic calibration of SWAT models	Support vector machines (SVMs) and Neural network (single hidden layer)	GLUE (was used only with SVMs, ANN was used for benchmarking SVMs)	Basic sequential framework	6, 9, 12, and 16 Continuous	20-42% of total CPU across 4 case studies
<i>Zou et al.</i> [2009]	Automatic calibration of the WASP water quality model	Neural network (single hidden layer)	Genetic algorithms	Adaptive-recursive framework	19 Continuous	Not reported
<i>Regis and Shoemaker</i> [2009]	Groundwater bioremediation optimization problems, automatic calibration of a groundwater bioremediation model, and 20 test functions	Radial basis functions	Gaussian and uniform random samplers	Approximation uncertainty based framework	Test functions: 2-6 Groundwater optimization problems: 12 Automatic calibration: 6 Continuous	Roughly 50-97% in number of full evaluations *
<i>Shrestha et al.</i> [2009]	Predictive uncertainty estimation of a hydrologic model (HBV)	Neural network (single hidden layer)	N/A (see Section 2.1)	N/A (see Section 2.1)	N/A (see Section 2.1)	Not reported
<i>di Pierro et al.</i> (2009)	Water distribution system design optimization (bi-objective)	Kriging	Genetic algorithms	Approximation uncertainty based	34 and 632 (Continuous)	N/A Inferior performance
<i>Broad et al.</i> [2010]	Water distribution system design optimization	Neural network (single hidden layer)	Genetic algorithms	Basic sequential framework	49 Discrete	98% of wall clock time
<i>Castelletti et al.</i> [2010]	Water quality rehabilitation in reservoirs (multi-objective optimization)	Radial basis functions, $n$ -dimensional linear interpolator, and inverse distance weighted	Complete enumeration	Adaptive-recursive framework	3 Discrete	Not reported
<i>Yan and Minsker</i> [2011]	Reliability-based groundwater remediation design – MODFLOW and RT3D models used for flow field and contaminant concentration	Three Neural networks (single hidden layer)	Noisy Genetic algorithm	Metamodel-embedded evolution framework, No formal DoE	28 Mixed integer	86-90% in number of full evaluations (this figure includes saving due to caching)
<i>Sreekanth and Datta</i> [2011]	Coastal aquifer pumping management	Ensemble of genetic programming-based models	NSGA-II	Basic sequential framework	33 Continuous	Not reported
<i>Razavi et al.</i> [2012]	Automatic calibration of a SWAT model and a groundwater model and 4 test functions	Kriging, radial basis function, and Neural networks (single hidden layer)	Genetic algorithms and Gaussian random sampler	Adaptive-recursive and approximation uncertainty based frameworks	7, 10, 14, and 15 Continuous	Not reported
<i>Borgonovo et al.</i> [2012]	Sensitivity analysis of an environmental nuclear waste model and three test functions	Smoothing spline ANOVA and kriging	Monte Carlo Simulation	Basic sequential framework	Test functions: 2, 3, and 3 Environmental problem: 12 Continuous	96% of CPU time

\* Computational saving is not explicitly mentioned in the paper, and this value is interpreted based on the available information.

Η προσομοίωση της λειτουργίας ταμειυτήρων αποτελεί μια δυναμική διαδικασία και, όπως αναφέρθηκε και στην προηγούμενη ενότητα, η χρήση υποκατάστατων αναφορικά με το πρόβλημα αυτό δεν παρουσιάζει εκτεταμένες εφαρμογές. Ειδικότερα, οι περισσότερες από τις εφαρμογές νευρωνικών δικτύων που καταγράφονται στους Πίνακες 3-2 και 3-3 αφορούν κυρίως σε προβλήματα αυτόματης βαθμονόμησης, ενώ για τη λειτουργία ταμειυτήρων δεν έχει βρεθεί

κάποια αντίστοιχη έρευνα. Ωστόσο, στο ευρύτερο πλαίσιο υποκατάστατης προσομοίωσης δυναμικών διαδικασιών συναντάται μια μελέτη του Chen *et al.* (2017), όπου τα νευρωνικά δίκτυα χρησιμοποιούνται ως υποκατάστατα για το υδροδυναμικό μοντέλο προσομοίωσης των διεργασιών που συμβαίνουν στο Δέλτα του ποταμού Sacramento, στις εκβολές στον κόλπο του San Francisco. Το αρχικό – υποκείμενο μοντέλο προσομοίωσης είναι αρκετά πολύπλοκο, καθώς λαμβάνει υπόψη τις εκροές από την ανάντη λεκάνη, μέρος των οποίων ρυθμίζεται από θυροφράγματα, την εισροή αλμυρού νερού, τις παλίρροιας και τις αντλήσεις που εφαρμόζονται για σκοπούς άρδευσης και αποσκοπεί στις ποσοτικά και ποιοτικά βέλτιστες συνθήκες για το οικολογικό σύστημα της περιοχής, το οποίο παρουσιάζει έντονες εποχιακές και ημερήσιες διακυμάνσεις. Τα νευρωνικά δίκτυα χρησιμοποιούνται για την προσομοίωση του παραπάνω μοντέλου, με σκοπό τη διευκόλυνση στη λήψη ορισμένων αποφάσεων. Για τον λόγο αυτό η εκπαίδευσή τους έγινε βάσει 10 διαφορετικών σεναρίων λειτουργίας των διατάξεων που ρυθμίζουν τις ροές στο ποτάμι που εκβάλλει στο Δέλτα.

### **3.5 Τα νευρωνικά δίκτυα στο περιβάλλον MATLAB**

Μέσα από το περιβάλλον MATLAB ο χρήστης έχει τη δυνατότητα να δημιουργήσει και να εκπαιδεύσει βάσει επιλεγμένων δεδομένων τεχνητά νευρωνικά δίκτυα. Η διαδικασία αυτή μπορεί να γίνει είτε δίνοντας τις κατάλληλες εντολές είτε μέσω ειδικού παράθυρου επικοινωνίας. Η διαδικασία περιλαμβάνει την επιλογή της επιθυμητής δομής, την επιλογή των δεδομένων εκπαίδευσης (εισόδων του νευρωνικού δικτύου και επιθυμητών εξόδων – στόχων), τον διαχωρισμό των δεδομένων αυτών σε σύνολα εκπαίδευσης, cross-training και αξιολόγησης βάσει του επιθυμητού τρόπου και μεγέθους των συνόλων αυτών και την επιλογή του αλγόριθμου εκπαίδευσης.

Στην παρούσα εργασία δοκιμάστηκαν τρεις αλγόριθμοι εκπαίδευσης: ο scaled conjugate gradient, ο Levenberg-Marquardt και ο Bayesian regularization, ο οποίος είναι ο αλγόριθμος Levenberg-Marquardt που έχει τροποποιηθεί ώστε να χρησιμοποιεί γενίκευση. Στο συγκεκριμένο αλγόριθμο, η διαδικασία της εκπαίδευσης δεν τερματίζεται όπως στις άλλες μεθόδους όταν η αξιολόγηση, βάσει του αντίστοιχου συνόλου δεδομένων, φτάσει συγκεκριμένα κριτήρια και για αυτό το λόγο δεν χρησιμοποιείται σύνολο αξιολόγησης. Αντιθέτως, το διαθέσιμο δείγμα χωρίζεται μόνο σε δεδομένα για εκπαίδευση και για cross-training. Στη συνέχεια, αναπτύσσεται ο αλγόριθμος Levenberg-Marquardt, αλλά και τα επιπλέον στοιχεία που διαμορφώνουν τον αλγόριθμο Bayesian regularization, καθώς αυτός είναι ο αλγόριθμος που τελικά επιλέχθηκε για την εκπαίδευση των νευρωνικών δικτύων της παρούσας εργασίας.

### 3.5.1 Ο αλγόριθμος Levenberg-Marquardt

Όπως κάθε ψευδο-Newton μέθοδος, ο αλγόριθμος Levenberg-Marquardt σχεδιάστηκε ώστε να προσεγγίζει δεύτερης τάξης ταχύτητα εκπαίδευσης, χωρίς να είναι απαραίτητο να υπολογίσει το Εσσιανό μητρώο (Hessian matrix). Όταν η συνάρτηση επίδοσης είναι ένα άθροισμα τετραγώνων, όπως συνήθως συμβαίνει κατά την εκπαίδευση των προς τα εμπρός τροφοδοτούμενων νευρωνικών δικτύων, τότε το Εσσιανό μητρώο μπορεί να προσεγγιστεί από τη σχέση  $H = J^T \cdot J$  και η κλίση υπολογίζεται ως  $g = J^T \cdot e$ , όπου  $J$  είναι το Ιακοβιανό μητρώο (Jacobian matrix), το οποίο αποτελείται από τις πρώτες παραγώγους των σφαλμάτων του δικτύου σε σχέση με τα βάρη  $w$  και τα συστηματικά σφάλματα  $b$ , και  $e$  είναι το διάνυσμα των σφαλμάτων του δικτύου. Το Ιακοβιανό μητρώο είναι λιγότερο περίπλοκο στον υπολογισμό του σε σχέση με Εσσιανό. Ο αλγόριθμος Levenberg-Marquardt χρησιμοποιεί την προσέγγιση αυτή για το μητρώο του Hess και έτσι σχηματίζεται ο παρακάτω «Νευτώνειος» τρόπος προσέγγισης:

$$x_k = x_{k+1} - [J^T \cdot J + \mu \cdot I]^{-1} \cdot g$$

Όταν ο αριθμός  $\mu$  είναι ίσος με το 0, τότε πρόκειται για την απλή μέθοδο Newton, με τη χρήση του Εσσιανού μητρώου. Όταν η τιμή του  $\mu$  είναι μεγάλη, τότε πρόκειται για μέθοδο κλίσης με μικρό βήμα. Η μέθοδος Newton είναι γρηγορότερη και πιο ακριβής κοντά σε ένα ελάχιστο σφάλμα, επομένως στόχος του αλγορίθμου αυτού αποτελεί η μετάβαση στη μέθοδο Newton όσο το δυνατόν γρηγορότερα. Συνεπώς, η τιμή του  $\mu$  μειώνεται μετά από κάθε επιτυχές βήμα, δηλαδή τη μείωση του σφάλματος, και αυξάνεται μόνο όταν κατά τη διάρκεια ενός δοκιμαστικού βήματος το σφάλμα αυξάνεται. Με αυτόν τον τρόπο, η τιμή του σφάλματος μειώνεται σε κάθε επαναληπτικό βήμα του αλγορίθμου.

Στο περιβάλλον MATLAB ο αλγόριθμος Levenberg-Marquardt υλοποιείται μέσω της εντολής «trainlm» και υποστηρίζει την εκπαίδευση με τη δυνατότητα αξιολόγησης και cross-training στην περίπτωση που έχουν οριστεί τα αντίστοιχα σύνολα. Τα διανύσματα με τις τιμές αξιολόγησης χρησιμοποιούνται για να τερματίζεται νωρίς η εκπαίδευση εάν η απόδοση του νευρωνικού δικτύου βάσει του συνόλου αξιολόγησης δεν βελτιώνεται ή παραμένει η ίδια για ένα καθορισμένο αριθμό συνεχόμενων επαναληπτικών βημάτων. Τα διανύσματα με τις τιμές που χρησιμοποιούνται για τον υπολογισμό της συνάρτησης επίδοσης κατά το cross-training αποτελούν ένα επιπλέον έλεγχο που είναι σε θέση να εξασφαλίσει την καλή γενίκευση του νευρωνικού δικτύου, αλλά δεν έχουν κάποια επίδραση πάνω στην εκπαίδευση. Ο συγκεκριμένος αλγόριθμος μπορεί να εκπαιδεύσει οποιοδήποτε δίκτυο με την προϋπόθεση ότι τα βάρη, οι καθαρές εισοδοί του και οι συναρτήσεις μετάβασης είναι παραγωγίσιμες συναρτήσεις.

Κριτήρια τερματισμού της εκπαίδευσης αποτελούν:

- Η επίτευξη του μέγιστου αριθμού επαναλήψεων του αλγορίθμου
- Η υπέρβαση του μέγιστου χρονικού ορίου που έχει θέσει ο χρήστης
- Η επίτευξη της βέλτιστης επίδοσης
- Η πτώση της κλίση του σφάλματος κάτω από την ελάχιστη τιμή
- Η υπέρβαση της μέγιστης τιμής για την παράμετρο  $\mu$
- Η αύξηση του σφάλματος κατά την αξιολόγηση για περισσότερες φορές από το μέγιστο καθορισμένο αριθμό, από την τελευταία φορά που αυτό μειώθηκε.

### 3.5.2 Ο αλγόριθμος Bayesian Regularization

Ο αλγόριθμος Bayesian Regularization αποτελεί μια τεχνική εκπαίδευσης, η οποία αναθεωρεί τα βάρη και τα συστηματικά σφάλματα του νευρωνικού δικτύου βάσει της μεθόδου βελτιστοποίησης Levenberg-Marquardt. Ουσιαστικά, ελαχιστοποιεί το συνδυασμό των τετραγώνων των σφαλμάτων και των βαρών, όπως εκφράζεται από την εξίσωση (3.1) για το μέσο τετραγωνικό σφάλμα, και στη συνέχεια καθορίζει το σωστό συνδυασμό έτσι ώστε να παραχθεί ένα νευρωνικό δίκτυο με καλή γενίκευση.

Κατά την εφαρμογή της μεθόδου αυτού δεν εκτελείται διαδικασία αξιολόγησης, προκειμένου η εκπαίδευση να συνεχίζεται μέχρι να βρεθεί ο βέλτιστος συνδυασμός των βαρών και των σφαλμάτων. Επιπλέον, η μέθοδος χρησιμοποιεί για τους υπολογισμούς την Jacobian, γεγονός που θεωρεί ότι η συνάρτηση επίδοσης είναι ο μέσος όρος ή το άθροισμα των τετραγώνων των σφαλμάτων. Επομένως, η εκπαίδευση πρέπει να γίνεται βάσει των δύο παραπάνω συναρτήσεων επίδοσης.

Ο συγκεκριμένος αλγόριθμος μπορεί να εκπαιδεύσει οποιοδήποτε δίκτυο, με την προϋπόθεση ότι τα βάρη, οι καθαρές εισοδοί του και οι συναρτήσεις μετάβασης έχουν παραγωγίσιμες συναρτήσεις, και έχει τα ίδια κριτήρια τερματισμού με αυτά του προηγούμενου αλγορίθμου, εκτός από το τελευταίο.



## 4. Προσομοίωση υποθετικού υβριδικού συστήματος της Αστυπάλαιας

### 4.1 Βασικά στοιχεία υβριδικών συστημάτων

Υβριδικό καλείται ένα σύστημα που χρησιμοποιεί παραπάνω από μία μεθόδους παραγωγής ενέργειας. Ειδικότερα, τα υβριδικά συστήματα νερού και ενέργειας διαχειρίζονται ταυτόχρονα τις ροές νερού και ενέργειας, οι οποίες σχετίζονται μεταξύ τους με τρόπο αμφίδρομο και άρρηκτο. Μέσω των υδροηλεκτρικών έργων γίνεται παραγωγή ενέργειας, ενώ διαδικασίες για την παραγωγή και επεξεργασία νερού ώστε αυτό να καταστεί κατάλληλο για την επιθυμητή χρήση απαιτούν την κατανάλωση ενέργειας.

Η αντλησιοταμίευση (pumped hydroelectric energy storage) αποτελεί μια διάταξη που εντάσσεται στα υβριδικά συστήματα ενέργειας, ολοκληρώνοντάς τα και βελτιώνοντας την απόδοσή τους. Μέσω της διάταξης αυτής, αποθηκεύεται ενέργεια με τη μορφή δυναμικής ενέργειας του νερού που αντλείται από ένα χαμηλότερου υψομέτρου ταμιευτήρα σε έναν ταμιευτήρα που βρίσκεται υψηλότερα. Κατά τις ώρες χαμηλότερης ζήτησης, η ενέργεια χαμηλής αξίας χρησιμοποιείται για τη λειτουργία των αντλιών, ενώ κατά τις περιόδους αιχμής της ζήτησης ηλεκτρικής ενέργειας, το νερό που έχει αποθηκευτεί στον ανάντη ταμιευτήρα εκρέει μέσω των στροβίλων για την παραγωγή ενέργειας υψηλότερης αξίας. Συνήθως, χρησιμοποιούνται αντιστρεπτοί στρόβιλοι (αντλησιοστρόβιλοι), οι οποίοι λειτουργούν είτε ως αντλίες είτε ως στρόβιλοι, κατά περίπτωση. Τα συνήθη συστήματα αντλησιοταμίευσης χρησιμοποιούν για την άντληση του νερού από τα κατάντη προς τα ανάντη ενέργεια που παράγεται από τον άνεμο ή την ηλιακή ακτινοβολία, υπάρχει όμως και η δυνατότητα λειτουργίας και με οποιαδήποτε άλλη πηγή παραγωγής ενέργειας. Η συγκεκριμένη μέθοδος αποτελεί προς το παρόν το οικονομικά αποδοτικότερο μέσο αποθήκευσης μεγάλων ποσών ηλεκτρικής ενέργειας, αλλά το κόστος κεφαλαίου καθώς και η κατάλληλη χωροθέτηση αποτελούν σημαντικούς παράγοντες που επηρεάζουν την παραπάνω οικονομική απόδοση (Koutsoyiannis *et al.*, 2009; Koutsoyiannis, 2011; Rehman *et al.*, 2014).

Η ανάγκη για αποθήκευση προκύπτει από την στοχαστική συμπεριφορά που παρουσιάζει η παραγωγή ενέργειας από ανανεώσιμες πηγές. Η ηλιακή, η αιολική, η κυματική και η παλιρροιακή ενέργεια παρουσιάζουν μια διαλείπουσα συμπεριφορά που εξαρτάται άμεσα από τις μετεωρολογικές συνθήκες που επικρατούν, με αποτέλεσμα να μην είναι δυνατή η συνεχής και με ελεγχόμενο τρόπο παραγωγή ενέργειας. Επομένως, κάποιες χρονικές στιγμές υπάρχει έλλειμμα στην παραγωγή της ζήτησης, ενώ κάποιες άλλες πλεόνασμα. Επιπλέον, τις περισσότερες φορές η παραγόμενη ενέργεια είναι ασύγχρονη της ζήτησης. Το γεγονός αυτό έρχεται σε σύγκρουση με τον στόχο για την ικανοποίηση του ενεργειακού ισοζυγίου κάθε χρονική στιγμή, ελλείψει μάλιστα της δυνατότητας αποθήκευσης της πλεονάζουσας

ενέργειας. Από την άλλη πλευρά, μέσω των συστημάτων αντλησιοταμίευσης, δεν ικανοποιείται μόνο η ανάγκη για αποθήκευση της ενέργειας, αλλά δίνεται, επιπλέον, η δυνατότητα αναρρύθμισης του ενεργειακού ισοζυγίου, καθώς η υδροηλεκτρική ενέργεια που μπορεί να παραχθεί είναι πλήρως ελεγχόμενη.

Η αντλησιοταμίευση θεωρείται γενικά ως η πιο πολλά υποσχόμενη τεχνολογία για την αύξηση της διείσδυσης των ανανεώσιμων πηγών ενέργειας σε ένα ενεργειακό σύστημα, και πολύ περισσότερο όταν γίνεται λόγος για μικρά αυτόνομα δίκτυα (π.χ., νησιωτικά). Επομένως, η αξιοποίηση τέτοιων μεθόδων συμβάλλει καθοριστικά στη διαμόρφωση ενός περισσότερο κερδοφόρου, περιβαλλοντικά και οικονομικά, ενεργειακού μίγματος.

Σύμφωνα με την ισχύ τους, τα συστήματα αντλησιοταμίευσης μπορούν να ταξινομηθούν σε μεγάλα, μικρά, *micro* και  *pico*. Τα συστήματα με εγκατεστημένη ισχύ από κάποιες εκατοντάδες kW έως λίγο περισσότερο από 10 MW, είναι γνωστά ως μεγάλες εγκαταστάσεις, παρόλο που δεν υπάρχει ένας επίσημος ορισμός για τους μεγάλους υδροηλεκτρικούς σταθμούς. Ένα μικρό σύστημα μπορεί να έχει δυναμικότητα μέχρι και 10 MW, παρόλο που και πάλι δεν υπάρχει ένα σαφώς ορισμένο εύρος. Η κατηγορία *micro* μπορεί να έχει δυναμικότητα μέχρι και 100 kW και θα μπορούσε να παρέχει ενέργεια σε απομονωμένες ή μικρές κοινότητες ή ακόμη και να ενταχθεί σε δίκτυο όπου υπάρχουν ανανεώσιμες πηγές ενέργειας. Ο όρος *pico* χρησιμοποιείται για συστήματα αντλησιοταμίευσης με δυναμικότητα μικρότερη από 5kW, τα οποία μπορεί να βρίσκονται σε κοινότητες όπου η ζήτηση είναι πάρα πολύ μικρή (Rehman *et al.*, 2014).

Η καθιερωμένη τεχνική της αντλησιοταμίευσης αποτελεί την καλύτερη διαθέσιμη τεχνολογία αποθήκευσης ενέργειας. Στα οφέλη της συγκαταλέγονται οι μηδενικές εκπομπές ρύπων προς το περιβάλλον και η παροχή ικανοποιητικής ποιότητας ηλεκτρική ενέργεια προς απορρόφηση από το δίκτυο. Ακόμη πιο σημαντικό είναι το γεγονός ότι βελτιώνει την απόδοση του ενεργειακού συστήματος μέσω της μείωσης της ενσωματωμένης αβεβαιότητας, καθώς αντισταθμίζει τις αποκλίσεις των προβλέψεων για τη ζήτηση ισχύος και είναι σε θέση να εξουδετερώνει τις αστοχίες του ηλεκτρικού συστήματος μέσω κατανομής της αβεβαιότητας, λόγω της αναρρυθμιστικής της λειτουργίας. Τέλος, μέσω των συγκεκριμένων διατάξεων, δεν καταναλώνεται νερό, αλλά μετατρέπεται η δυναμική του ενέργεια, ενώ ταυτόχρονα είναι διαθέσιμο και για άλλες χρήσεις.

Η χρήση συστημάτων αντλησιοταμίευσης στα υβριδικά συστήματα ενέργειας παρουσιάζει και σημαντικά οικονομικά οφέλη. Αρχικά, δίνει τη δυνατότητα ενός σχετικά σταθερού κόστους παραγωγής ενέργειας. Ακόμη, καθώς, η ανανεώσιμη ενέργεια που παράγεται αξιοποιείται με το βέλτιστο δυνατό τρόπο, γίνεται εξοικονόμηση των συμβατικών πηγών ενέργειας. Επιπλέον, στην περίπτωση που περιλαμβάνονται και μη ανανεώσιμες πηγές ενέργειας, η λειτουργία των υβριδικών

συστημάτων γίνεται με σκοπό την ελάχιστη δυνατή κατανάλωση καυσίμου, καθιστώντας τα περισσότερο οικονομικά επωφελή για τις μη διασυνδεδεμένες ή απομακρυσμένες από το δίκτυο περιοχές όπου η σύνδεση ή εγκατάσταση δικτυακών υποδομών και η μεταφορά καυσίμου θεωρούνται αντιοικονομικές επιλογές (Δήμας, 2013). Τέλος, καθώς τα ποσοστά απωλειών είναι μικρότερα από το 10% (βαθμός απόδοσης >90%), όταν πρόκειται για μεγάλης κλίμακας έργα, αποτελεί μια οικονομικά αποδοτική λύση.

Άλλα πλεονεκτήματα που παρουσιάζουν τα συστήματα αντλησιοταμίευσης αποτελούν η ευελιξία στην έναρξη και τη λήξη της λειτουργίας τους, η ταχύτερη απόκριση σε σχέση με άλλα συστήματα παραγωγής ενέργειας, η ικανότητα να παρακολουθούν και να προσαρμόζονται σε μεγάλες αλλαγές του ενεργειακού φορτίου και σε αλλαγές της συχνότητας του ηλεκτρικού ρεύματος και να διατηρούν σταθερή την τάση (Rehman *et al.*, 2014), καθώς και η ταχύτητα εγκατάστασης των τεχνολογιών.

Η προσομοίωση της λειτουργίας τέτοιων συστημάτων είναι αρκετά δύσκολη, καθώς ανακύπτουν διάφορα ζητήματα που δυσχεραίνουν τις υπολογιστικές διαδικασίες. Κατ' αρχάς, η μοντελοποίηση των συστημάτων υδατικών πόρων ξεχωριστά χαρακτηρίζεται από ορισμένες αδυναμίες όπως είναι η μη γραμμική δυναμική, οι άγνωστες μελλοντικές εισροές, ο μεγάλος αριθμός μεταβλητών και περιορισμών, τα αντικρουόμενα κριτήρια κ.ά. Η εισαγωγή των ενεργειακών συνιστωσών και των ροών ενέργειας εντείνει το συγκεκριμένο πρόβλημα, καθώς εμφανίζει προσθέτει επιπλέον πολυπλοκότητα και αβεβαιότητες. Επίσης, δεδομένου ότι για τη μοντελοποίηση των υδροσυστημάτων η ανάλυση γίνεται συνήθως σε μηνιαίο χρονικό βήμα, ενώ για την κατάρτιση του ενεργειακού ισοζυγίου απαιτείται πολύ λεπτομερέστερη χρονική ανάλυση, συνήθως ωριαία, προκειμένου να αναπαρασταθούν ταυτόχρονα οι ροές νερού και ενέργειας, τίθεται η ανάγκη σύζευξης διαφορετικών χρονικών κλιμάκων. Επιπλέον, η ταυτόχρονη μοντελοποίηση των δύο παράλληλων ροών και των μεταξύ τους αλληλεπιδράσεων αυξάνει τις μεταβλητές ελέγχου, τους περιορισμούς και τους επιδιωκόμενους στόχους. Τέλος, εξίσου σημαντική είναι η αβεβαιότητα των υδρομετεωρολογικών διεργασιών εισόδου του συστήματος και για το λόγο αυτό καθίσταται απαραίτητη η χρήση συνθετικών χρονοσειρών εισόδου μεγάλου μήκους, με σκοπό η αξιολόγηση της επίδοσης του συστήματος αναφορικά με την αξιοπιστία και το ρίσκο να γίνεται με ικανοποιητική ακρίβεια (Efstratiadis *et al.*, 2015).

Όπως αναφέρεται και από το Ινστιτούτο Έρευνας για την Ηλεκτρική Ενέργεια (EPRI), τα συστήματα αντλησιοταμίευσης αντιπροσωπεύουν περισσότερο από το 99% της δυνατότητας αποθήκευσης σε όγκο παγκοσμίως, που ανέρχεται σε περίπου 127 GW. Το 2009, η δυναμικότητα της αντλησιοταμίευσης παγκοσμίως έφτανε περίπου τα 100 GW, με την κατανομή που καταγράφεται στον Πίνακα 4-1.

Πίνακας 4-1: Δυναμικότητα αντλησιοταμίευσης παγκοσμίως το 2009. Πηγή: Rehman *et al.* (2014)

	Εγκατεστημένη ισχύς συστημάτων αντλησιοταμίευσης (τέλος του 2009) (GW)
Καναδάς	0,2
Η.Π.Α	22,0
Αργεντινή	1,0
Αυστρία	4,4
Βέλγιο	1,3
Βουλγαρία	0,9
Κροατία	0,3
Τσεχία	1,1
Γαλλία	4,3
Γερμανία	6,7
Ελλάδα	0,6
Ιρλανδία	0,3
Ιταλία	7,5
Λουξεμβούργο	1,1
Νορβηγία	1,4
Πολωνία	1,4
Πορτογαλία	1,0
Σερβία	0,6
Σλοβακία	0,9
Ισπανία	5,3
Σουηδία	0,1
Ελβετία	1,8
Ηνωμένο Βασίλειο	2,7
Λιθουανία	0,8
Ρωσία	1,2
Μαρόκο	0,5
Νότια Αφρική	1,0
Αυστραλία	1,0
Ιαπωνία	25,0
Νότια Κορέα	4,0
Ταϊβάν	3,0

## 4.2 Περιοχή μελέτης


Στην παρούσα ενότητα γίνεται η περιγραφή της περιοχής μελέτης τόσο στην υπάρχουσα κατάσταση της, αλλά και όπως διαμορφώνεται έπειτα από την εφαρμογή του υβριδικού συστήματος που μελετάται.

### 4.2.1 Υπάρχουσα κατάσταση

Στη συγκεκριμένη εργασία λαμβάνονται υπόψη οι ροές νερού και ενέργειας σε ένα υποθετικό υβριδικό σύστημα νερού και ενέργειας που τοποθετείται στο νησί της Αστυπάλαιας. Η Αστυπάλαια, που καταλαμβάνει έκταση ίση με 97 km<sup>2</sup>, αποτελεί μέρος του συμπλέγματος των Δωδεκανήσων και, όπως τα περισσότερα μικρά νησιά

της Ελλάδας, δεν διαθέτει ενεργειακή σύνδεση με το ηπειρωτικό τμήμα της χώρας. Οι μόνιμοι κάτοικοι φτάνουν μόλις τους 1.300, αριθμός που ξεπερνιέται κατά πολύ στη διάρκεια των θερινών μηνών, με το πλήθος των επισκεπτών να φτάνει τους 20.000 ανά έτος.

Κατά την παρούσα φάση, οι ενεργειακές απαιτήσεις καλύπτονται εξ' ολοκλήρου από θερμικό σταθμό παραγωγής, ο οποίος λειτουργεί με πετρέλαιο. Το γεγονός αυτό έχει ως αποτέλεσμα αυξημένο κόστος παραγωγής, σε σύγκριση με το αντίστοιχο της ηπειρωτικής χώρας, λόγω του κόστους μεταφοράς του καυσίμου, καθώς και μεγαλύτερη πιθανότητα αστοχίας κάλυψης της ζήτησης. Ταυτόχρονα, δεν υπάρχουν εγκαταστάσεις ανανεώσιμων πηγών ενέργειας, ώστε να μειωθεί το συγκεκριμένο κόστος. Σύμφωνα με καταγραφές από το 2014 έως το 2015, η μέση ετήσια ζήτηση ηλεκτρικής ενέργειας ήταν 6.250 MWh. Η μέγιστη ωριαία ζήτηση ήταν 2,2 MWh, ενώ η αντίστοιχη ελάχιστη ήταν 0,23 MWh. Όπως φαίνεται και στο Διάγραμμα 1, οι υψηλότερες τιμές καταγράφονται τη θερινή περίοδο, γεγονός αναμενόμενο, λόγω του τουρισμού και των αυξημένων θερμοκρασιών (Mavroyeorgos *et al.*, 2017).



Διάγραμμα 4-1: Ζήτηση ενέργειας σε ωριαία κλίμακα. Πηγή: Mavroyeorgos *et al.*, 2017

Αναφορικά με τις υδατικές ανάγκες, η κύρια υποδομή για την κάλυψή τους είναι ο ταμιευτήρας του Λειβαδίου, ο οποίος σχηματίζεται από φράγμα ύψους 32 m, έχει συνολική και η ωφέλιμη χωρητικότητα είναι 1.050.000 m<sup>3</sup> και 875.000 m<sup>3</sup>, αντίστοιχα, και καταλαμβάνει επιφάνεια 105.000 m<sup>2</sup>. Ο ταμιευτήρας ξεκίνησε να λειτουργεί από το 1998 και καλύπτει οικιακές, αρδευτικές και τουριστικές χρήσεις. Η εκτιμώμενη ετήσια ζήτηση είναι 210.000 m<sup>3</sup> για ύδρευση και 230.000 m<sup>3</sup> για άρδευση, με μηνιαία διακύμανση, της οποίας οι μέγιστες τιμές καταγράφονται κατά τους θερινούς μήνες. Στον ταμιευτήρα καταλήγει η απορροή εφήμερου ρέματος από την ανάντη λεκάνη απορροής, έκτασης 8 km<sup>2</sup> (Paparoulakos *et al.*, 2017). Για τη λεκάνη αυτή δεν υπάρχουν διαθέσιμες υδρομετρήσεις, παρά μόνο ορισμένες αδρομερείς εκτιμήσεις για το υδρολογικό καθεστώς και δείχνουν ότι το 15%

περίπου της μέσης ετήσιας βροχόπτωσης μετατρέπεται σε επιφανειακή απορροή και το 11% ρέει υπόγεια και καταλήγει προς τη θάλασσα, ενώ το υπόλοιπο ποσοστό αποτελεί τις απώλειες μέσω εξατμοδιαπνοής (Κ/Ξ Υδατοσυστημάτων Αιγαίου, 2005). Βάσει των εκτιμήσεων αυτών και με χρήση μετρήσεων βροχόπτωσης και θερμοκρασίας από τη γειτονική Κάλυμνο, διαμορφώθηκε ένα αδιαμέριστο μοντέλο βροχής-απορροής, οι παράμετροι του οποίου εκτιμήθηκαν με προσέγγιση Monte Carlo, ώστε να ληφθούν υπόψη οι μείζονες αβεβαιότητες που εισάγει η έλλειψη υδρομετρικής πληροφορίας για τη βαθμονόμηση του μοντέλου (Paroulakos *et al.*, 2017). Το μοντέλο αυτό, το οποίο χρησιμοποιείται και στην παρούσα διπλωματική εργασία, εκτιμά τη μέση ετήσια βροχόπτωση στα 610 mm και τη μέση ετήσια απορροή στα 110 mm, επομένως η μέση ετήσια εισροή στον ταμιευτήρα φτάνει τα 880.000 m<sup>3</sup>.

#### 4.2.2 Το υποθετικό υβριδικό σύστημα

Στην εργασία εξετάζεται είναι ένα υποθετικό υβριδικό σύστημα νερού και ενέργειας. Ο υπάρχον ταμιευτήρας, μαζί με μία υποθετική δεξαμενή τοποθετημένη σε μεγαλύτερο υψόμετρο, παρέχουν τη δυνατότητα ρύθμισης του ενεργειακού ισοζυγίου με σύστημα άντλησης – ταμίευσης. Πιο συγκεκριμένα, έχει θεωρηθεί ότι στην έξοδο του ταμιευτήρα υπάρχει στρόβιλος παροχτευτικότητας 1.000 m<sup>3</sup>/h με συντελεστή απόδοσης 0,85 και χρησιμοποιείται για παραγωγή υδροηλεκτρικής ενέργειας από τη διέλευση του νερού που καλύπτει την οικιακή και αγροτική ζήτηση. Το μέγιστο ύψος πτώσης από τον ταμιευτήρα είναι τα 32 m, όσο δηλαδή το ύψος του φράγματος. Επιπλέον, έχει θεωρηθεί ότι υπάρχει δεξαμενή ωφέλιμης χωρητικότητας 50.000 m<sup>3</sup> (100 m x 100 m x 5 m) με υψομετρική διαφορά από τον ταμιευτήρα 200 m. Από τη δεξαμενή αυτή ξεκινάει αγωγός προσαγωγής με παροχτευτικότητα 1.500 m<sup>3</sup>/h, η έξοδος του οποίου καταλήγει σε αντλιοστρόβιλο. Η διάταξη αυτή για τη λειτουργία παραγωγής ενέργειας έχει συντελεστή απόδοσης 0,85, ενώ για την καταστροφή ενέργειας μέσω άντλησης έχει συντελεστή απόδοσης 0,80. Σε κάθε χρονικό βήμα είναι δυνατή μόνο η μία από τις δύο λειτουργίες. Τέλος, έχουν θεωρηθεί εγκαταστάσεις αιολικών και φωτοβολταϊκών πάρκων εγκατεστημένης ισχύος 1,0 και 0,5 MW αντίστοιχα. Το σύστημα προορίζεται για την ικανοποίηση των αναγκών ζήτησης της ενέργειας καθώς και για την παροχή νερού ύδρευσης και αρδευτικού νερού για την κάλυψη των αναγκών τεσσάρων βασικών καλλιεργειών (αρροτριαιών, κηπευτικών, οπωρικών και αμπελώνων).

### 4.3 Μεθοδολογία

#### 4.3.1 Ευρύτερο μεθοδολογικό πλαίσιο αντιμετώπισης του προβλήματος

Στο σημείο αυτό εξηγείται το ευρύτερο πλαίσιο βάσει του οποίου αντιμετωπίστηκε το εξεταζόμενο πρόβλημα, ενώ στις επόμενες ενότητες γίνεται λεπτομερέστερη αναφορά στα βασικά λειτουργικά του μέρη. Αρχικά, πέρα από την πολυπλοκότητα του ίδιου του προβλήματος, ένα ακόμη μειονέκτημα που δυσχεραίνει την ανάλυσή

του είναι η έλλειψη υδρομετεωρολογικών δεδομένων στην περιοχή μελέτης. Το πρόβλημα αυτό αντιμετωπίστηκε από τους Paroulakos *et al.* (2017) με τη χρήση δεδομένων βροχόπτωσης και θερμοκρασίας από το μετεωρολογικό σταθμό της Καλύμνου, με κατάλληλη στατιστική επεξεργασία και χρήση μεθόδων που αναπαράγουν κατάλληλα τη στοχαστική συμπεριφορά των μεταβλητών αυτών, σε μια προσπάθεια διαχείρισης του συστήματος σε καθεστώς έλλειψης δεδομένων. Στην παρούσα εργασία χρησιμοποιήθηκε μια αλληλουχία αναλυτικών μοντέλων καθένα από τα οποία προσομοιώνει διαφορετικές λειτουργίες του συστήματος και πιο συγκεκριμένα τις μετεωρολογικές και υδρολογικές διεργασίες και τη λειτουργία του υποθετικού συστήματος της αντλησιοταμίευσης. Οι δύο μετεωρολογικές μεταβλητές που χρησιμοποιούνται, της βροχόπτωσης και της θερμοκρασίας, προέκυψαν από την προαναφερθείσα έρευνα. Οι προσομοιώσεις αυτές μπορούν να διαχωριστούν σε δύο μέρη, ανάλογα με τη διάρκεια του χρονικού βήματος στο οποίο λαμβάνει χώρα η προσομοίωση και περιλαμβάνουν:

Το **A' μέρος**, σε ημερήσιο χρονικό βήμα, με:

- Ένα μοντέλο εκτίμησης της δυνητικής εξατμοδιαπνοής, μέσω της θερμοκρασίας και της εξωγήινης ηλιακής ακτινοβολίας.
- Το εννοιολογικό μοντέλο βροχής – απορροής.
- Το μοντέλο ζήτησης νερού για αρδευτική χρήση.

Το **B' μέρος**, σε ωριαίο χρονικό βήμα, με:

- Το μοντέλο λειτουργίας του υβριδικού συστήματος.

Τα αποτελέσματα που προκύπτουν από την ανάλυση του **μέρους A'** και έπειτα από κατάλληλη μετατροπή των μονάδων μέτρησης, χρησιμοποιούνται ως είσοδοι για το **B' μέρος** της επεξεργασίας. Για την μετατροπή από το ημερήσιο στο ωριαίο βήμα έχει θεωρηθεί, απλουστευτικά, ομοιόμορφη κατανομή των τιμών των δεδομένων εισόδου μέσα στο ίδιο εικοσιτετράωρο.

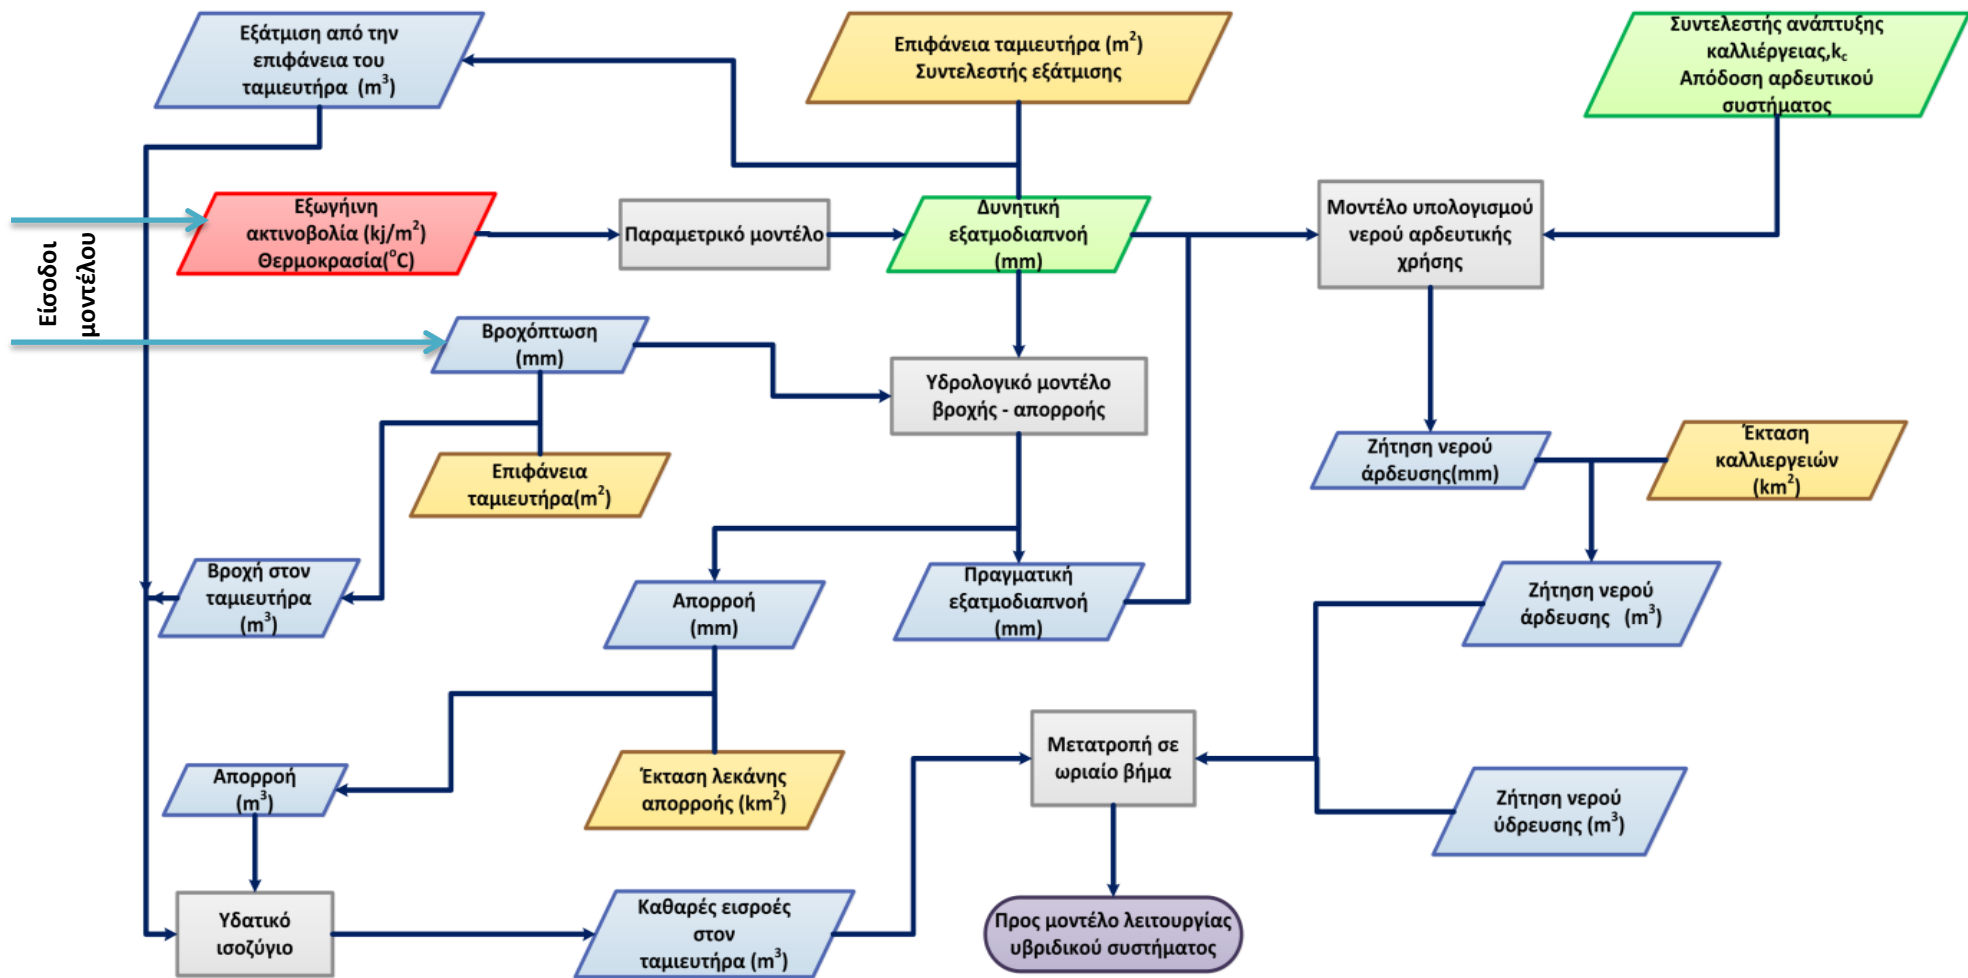
Στη συνέχεια, έπειτα από εκτεταμένες δοκιμές, καταρτίστηκε ένα σχήμα προσομοίωσης ορισμένων εξόδων των παραπάνω μοντέλων με τη χρήση τεχνητών νευρωνικών δικτύων. Σκοπό του σχήματος αυτού αποτελεί η υποκατάστατη μοντελοποίηση της επιφάνειας απόκρισης του ισοζυγίου ενέργειας, όπως αυτό διαμορφώνεται τελικά, σύμφωνα με τη ζήτηση και την κάλυψή της από το υβριδικό σύστημα.

Η αναλυτική προσομοίωση περιγράφεται στην επόμενη ενότητα, ενώ η μεθοδολογία διαμόρφωσης των νευρωνικών δικτύων αποτελεί αντικείμενο του επόμενου κεφαλαίου. Στην Εικόνα 4-1 παρουσιάζεται το διάγραμμα ροής των διαδικασιών της αναλυτικής προσομοίωσης που προαναφέρθηκαν.

Τέλος, θεωρείται σκόπιμο να αναφερθεί ότι τα δεδομένα που αφορούν τη ζήτηση ενέργειας και νερού ύδρευσης, καθώς και την παραγωγή ενέργειας από τον ήλιο και τον άνεμο, έχουν δημιουργηθεί με την εφαρμογή μεθόδων που αναπαράγουν κατάλληλα τη стоχαστική συμπεριφορά των μετεωρολογικών μεταβλητών με τις οποίες συσχετίζονται. Αναλυτικότερη περιγραφή των παραπάνω στοχαστικών μεθόδων γίνεται σε ξεχωριστή ενότητα.

Όλες οι επεξεργασίες των δεδομένων και η εφαρμογή της μεθοδολογίας που περιγράφεται έγινε σε περιβάλλον MATLAB, έκδοση R2016a.





Εικόνα 4-1: Διάγραμμα ροής της αναλυτικής προσομοίωσης



### 4.3.2 Αναλυτική προσομοίωση του συστήματος

#### ι. Το Παραμετρικό μοντέλο δυνητικής εξατμοδιαπνοής

Η εξάτμιση από την επιφάνεια του ταμιευτήρα και η δυνητική εξατμοδιαπνοή από φυτοκαλυμμένες επιφάνειες αποτελούν εισόδους του μοντέλου προσομοίωσης της λειτουργίας του ταμιευτήρα και του μοντέλου ζήτησης νερού για άρδευση, αντίστοιχα. Επιπλέον, η δυνητική εξατμοδιαπνοή αποτελεί είσοδο και του μοντέλου βροχής-απορροής, καθώς αποτελεί μια φυσική ζήτηση νερού της λεκάνης που προσομοιώνεται. Για τον υπολογισμό της χρησιμοποιήθηκε το παραμετρικό μοντέλο για τη δυνητική εξατμοδιαπνοή (Tegos *et al.*, 2017), που μαθηματικά εκφράζεται ως:

$$PET = \frac{a * R_a}{1 - c * T} \quad (4.1)$$


όπου: PET, είναι η δυνητική εξατμοδιαπνοή σε mm

$R_a$ , είναι η εξωγήινη ακτινοβολία σε  $kJ \cdot m^{-2}$

$T$ , είναι η μέση θερμοκρασία του αέρα σε  $^{\circ}C$

$a$  και  $c$ , είναι παράμετροι του μοντέλου σε  $kg \cdot kJ^{-1}$  και  $^{\circ}C^{-1}$ , αντίστοιχα.

Οι παράμετροι  $a$  και  $c$  έχουν προκύψει από βαθμονόμηση με δεδομένα αναφοράς τα οποία έχουν εκτιμηθεί σύμφωνα με τη μέθοδο Penman – Monteith, με βάση τα αναλυτικά μετεωρολογικά δεδομένα γειτονικών νησιών (Μήλος, Σαντορίνη, Ρόδος, Κάλυμνος). Για την περιοχή μελέτης με συντεταγμένες ( $36^{\circ}5390'N$   $26^{\circ}3131'E$ ), οι παράμετροι αυτοί είναι  $a = 7.167 \times 10^{-5} kg/kJ$  και  $c = 0.0234 ^{\circ}C^{-1}$ .



Διάγραμμα 4-2: Εξωγήινη ακτινοβολία για το γεωγραφικό πλάτος της περιοχής μελέτης

Καθώς η παραπάνω μαθηματική έκφραση (4.1) χρησιμοποιεί δύο μεταβλητές, την εξωγήινη ακτινοβολία και τη θερμοκρασία, και δεδομένου ότι η εξωγήινη ακτινοβολία είναι αστρονομική μεταβλητή, που αποτελεί μια σταθερή περιοδική συνάρτηση του χρόνου και του γεωγραφικού πλάτους, η μόνη τυχαία μεταβλητή του μοντέλου αυτού είναι η μέση θερμοκρασία. Στο Διάγραμμα 4-2 αναπαριστάται γραφικά η εξωγήινη ακτινοβολία για το δεδομένο γεωγραφικό πλάτος.

## ii. Το εννοιολογικό μοντέλο βροχής – απορροής

Το υδρολογικό μοντέλο που εφαρμόστηκε για την εκτίμηση της απορροής και της πραγματικής εξατμοδιαπνοής χρησιμοποιεί ως εισόδους τη βροχόπτωση και τη δυνητική εξατμοδιαπνοή. Επιπλέον, το μοντέλο αντιμετωπίζει το έδαφος ως μια δεξαμενή υγρασίας ορισμένης χωρητικότητας. Οι παράμετροι του μοντέλου είναι η ικανότητα επιφανειακής συγκράτησης  $I_a$  (mm), η χωρητικότητα  $K$  (mm) της δεξαμενής εδαφικής υγρασίας και ο συντελεστής στείρευσης της εδαφικής υγρασίας  $\alpha$ . Οι τιμές των παραμέτρων για τη συγκεκριμένη περιοχή μελέτης είναι 6,1 mm,  $2,703 \times 10^3$  mm και  $1,86 \times 10^{-3}$  αντίστοιχα. Τελικές έξοδοί του αποτελούν η πραγματική εξατμοδιαπνοή, η απορροή, οι απώλειες προς τη θάλασσα και η εδαφική υγρασία. Οι μονάδες μέτρησης στις οποίες εκτιμώνται αυτά τα μεγέθη είναι τα χιλιοστά.

Αρχικά, στην περίπτωση που η βροχόπτωση ξεπερνάει την ικανότητα επιφανειακής συγκράτησης του εδάφους  $I_a$ , εφαρμόζεται ο τύπος της SCS-CN για τον υπολογισμό της επιφανειακής απορροής:

$$Q_{ov} = \frac{(Rain - I_a)^2}{Rain - I_a + K - S_o} \quad (4.2)$$

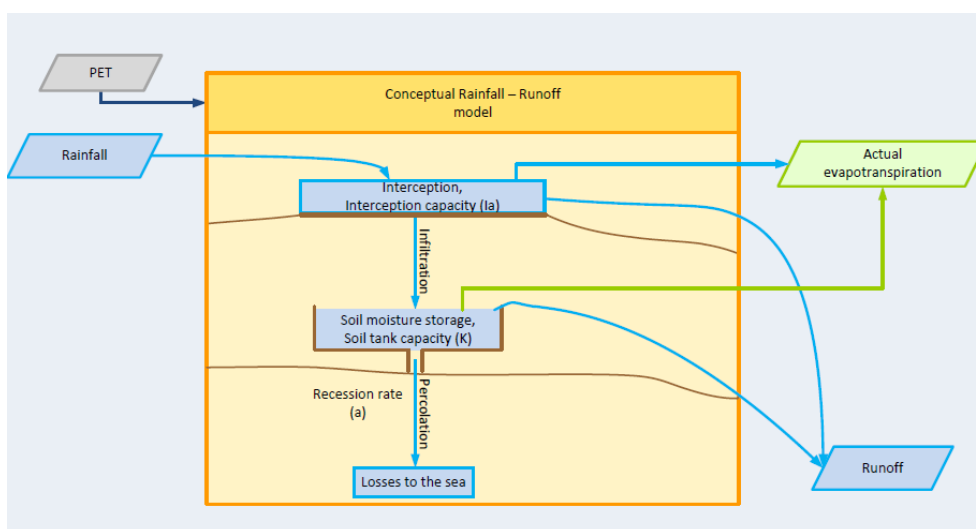
Στη συνέχεια, η εναπομένουσα βροχόπτωση θεωρείται ότι ικανοποιεί κατά προτεραιότητα τη ζήτηση της δυνητικής εξατμοδιαπνοής, δημιουργώντας άμεση εξατμοδιαπνοή, ενώ το υπόλοιπό της διηθείται στο έδαφος και προστίθεται στο απόθεμα της δεξαμενής της εδαφικής υγρασίας. Το αρχικό απόθεμα της δεξαμενής θεωρήθηκε ίσο με το μισό της χωρητικότητάς της.

Το απόθεμα αυτό συμβάλλει στην ικανοποίηση της δυνητικής εξατμοδιαπνοής, παράγοντας εδαφική εξατμοδιαπνοή, η οποία εκτιμάται από την εμπειρική σχέση:

$$ET_s = (PET - ET_d) * \tanh\left(\frac{S}{K}\right) \quad (4.3)$$

όπου  $ET_s$  είναι η εξατμοδιαπνοή από το έδαφος και  $ET_d$  είναι η άμεση εξατμοδιαπνοή, από την επιφάνεια του εδάφους.

Η ποσότητα αυτή αφαιρείται από το απόθεμα της εδαφικής υγρασίας. Έπειτα, ένα ποσοστό του αποθέματος αυτού θεωρείται ότι κατεισδύει με ρυθμό  $\alpha$  και τελικά εκρέει στη θάλασσα, ενώ στην περίπτωση που το εναπομείναν απόθεμα είναι μεγαλύτερο από τη χωρητικότητα  $K$  της δεξαμενής της εδαφικής υγρασίας, η πλεονάζουσα ποσότητα υπερχειλίζει και δημιουργεί υπεδάφια απορροή. Τέλος, επικαιροποιείται το απόθεμα της εδαφικής υγρασίας, υπολογίζεται η απορροή ως το άθροισμα της επιφανειακής και της υπεδάφιας απορροής και υπολογίζεται η πραγματική εξατμοδιαπνοή ως το άθροισμα της άμεσης και της εδαφικής. Ο αλγόριθμος που περιγράφει τις διεργασίες προσομοίωσης είναι διαθέσιμος στο Παράρτημα, ενώ στο Σχήμα 4-1 παρουσιάζεται γραφικά το εννοιολογικό μοντέλο.



Σχήμα 4-1: Εννοιολογικό μοντέλο βροχής – απορροής

### iii. Μοντέλο ζήτησης νερού για αρδευτική χρήση

Η ζήτηση νερού για αρδευτική χρήση εκτιμάται μέσω του ελλείμματος στην κάλυψη των θεωρητικών αναγκών των καλλιεργειών από την πραγματική εξατμοδιαπνοή προς την απόδοση του αρδευτικού συστήματος. Μαθηματικά, η παραπάνω σχέση εκφράζεται ως:

$$D_{irrigation,i} = \frac{k_{c,i} * PET - ET}{e} \text{ (mm)} \quad (4.4)$$

όπου  $ET$  είναι η πραγματική εξατμοδιαπνοή που υπολογίστηκε από το μοντέλο βροχής-απορροής,  $e$  είναι ο συντελεστής απόδοσης του αρδευτικού συστήματος, ο οποίος έχει θεωρηθεί ίσος με 0,80, και  $k_c$  είναι ο συντελεστής ανάπτυξης της καλλιέργειας, ο οποίος διαφέρει ανά τύπο καλλιέργειας  $i$  και ανά μήνα, λόγω της διαφορετικής φάσης ανάπτυξης. Οι τιμές για τον συντελεστή  $k_c$  λήφθηκαν από τη μελέτη της Κ/Ξ Υδατοσυστημάτων Αιγαίου (2005). Για την εκτίμηση των αρδευτικών αναγκών σε μονάδες όγκου πολλαπλασιάζονται οι παραπάνω εκτιμήσεις με την έκταση των αντίστοιχων καλλιεργειών, ήτοι 13 km<sup>2</sup> για την αροτριαία, 123 km<sup>2</sup> για τους οπωρώνες, 226 km<sup>2</sup> για τα κηπευτικά και 5 km<sup>2</sup> για τους αμπελώνες, ήτοι:

$$D_{irrigation} = \sum_i^n D_{irrigation,i} * E_i \text{ (m}^3\text{)} \quad (4.5)$$

#### iv. Μοντέλο λειτουργίας υβριδικού συστήματος

Το συγκεκριμένο μοντέλο προσομοιώνει τις διεργασίες που συμβαίνουν κατά τη λειτουργία του υβριδικού συστήματος νερού και ενέργειας. Το σύστημα λειτουργεί με συγκεκριμένες παραδοχές στην ιεράρχηση των προτεραιοτήτων αναφορικά με τις χρήσεις του νερού. Η ιεράρχηση αυτή κατατάσσει στην πρώτη θέση τη χρήση για την κάλυψη των αναγκών ύδρευσης, στη δεύτερη θέση τη χρήση για παραγωγή ενέργειας και στην τρίτη θέση τη χρήση για κάλυψη των αναγκών άρδευσης.

Είσοδοι του μοντέλου αποτελούν οι καθαρές εισροές νερού, η ζήτηση νερού για ύδρευση και άρδευση και το ισοζύγιο ενέργειας, όπως διαμορφώνεται ως η διαφορά μεταξύ της ζήτησης ενέργειας και της παραγωγής ενέργειας από τις αιολικές και φωτοβολταϊκές εγκαταστάσεις. Μέσω του μοντέλου υπολογίζονται οι ροές νερού ανάλογα με τον αγωγό και την κατεύθυνση προς την οποία λαμβάνουν χώρα, τα αποθέματα στον ταμιευτήρα και την δεξαμενή, η υπερχειλίση του ταμιευτήρα και το τελικό ισοζύγιο ενέργειας όπως διαμορφώνεται μετά την εξισορρόπηση μέσω του συστήματος. Παράμετροι του μοντέλου αποτελούν ο μέγιστος και ο ελάχιστος όγκος λειτουργίας του ταμιευτήρα, το εμβαδόν και το ύψος της δεξαμενής, η υψομετρική διαφορά μεταξύ του ταμιευτήρα και της δεξαμενής, οι συντελεστές υδραυλικών απωλειών στους δύο αγωγούς, οι συντελεστές απόδοσης των συστημάτων παραγωγής/καταστροφής ενέργειας και η παροχτευτικότητα του κάθε αγωγού. Η προσομοίωση ξεκινάει με αρχικές συνθήκες για τα ωφέλιμα αποθέματα του ταμιευτήρα και της δεξαμενής να βρίσκονται στο μισό της μέγιστης τιμής που μπορούν να λάβουν. Στη συνέχεια, περιγράφονται οι προσομοιωμένες διεργασίες του συστήματος.

Αρχικά, υπολογίζεται το απόθεμα του ταμιευτήρα όπως διαμορφώνεται μετά από τις καθαρές εισροές νερού. Οι καθαρές εισροές προκύπτουν ως αποτέλεσμα του υδατικού ισοζυγίου, δηλαδή:

$$I = Rain + Q - ET \quad (4.6)$$

Η ποσότητα των καθαρών εισροών στον ταμιευτήρα  $I$  θα είναι ίση με το άθροισμα της ποσότητας του νερού που εισέρχεται και της ποσότητας του νερού που εξέρχεται. Το νερό που εισέρχεται βρίσκεται είτε σε μορφή βροχής στην επιφάνεια του ταμιευτήρα,  $Rain$ , είτε ως απορροή από την ανάντη λεκάνη,  $Q$ , όπως έχει υπολογιστεί από το υδρολογικό μοντέλο, ενώ το νερό που εξέρχεται προέρχεται από τη διεργασία της εξάτμισης νερού από την επιφάνεια του ταμιευτήρα. Η τιμή της εξάτμισης από την επιφάνεια του ταμιευτήρα έχει προκύψει με βάση τη δυνητική εξατμοδιαπνοή,  $PET$ , προσαυξημένη κατά 10%.

Στη συνέχεια, υπολογίζονται η εκροή για την κάλυψη της οικιακής ζήτησης με χρήση νερού από τον ταμιευτήρα, ως το ελάχιστο μεταξύ της ζήτησης, του αποθέματος του ταμιευτήρα και της παροχетеυτικότητας του αγωγού υδροληψίας. Έπειτα, ελέγχεται εάν έχει καλυφθεί η ζήτηση του νερού οικιακής χρήσης. Στην περίπτωση που εμφανίζεται έλλειμμα, τότε για την κάλυψή του ενεργοποιείται η εκροή νερού από τη δεξαμενή. Η ποσότητα αυτή προκύπτει ως το ελάχιστο μεταξύ του ελλείμματος, του αποθέματος της δεξαμενής και της παροχетеυτικότητας του αγωγού μεταφοράς από τη δεξαμενή στον ταμιευτήρα. Στο σημείο αυτό, είναι σημαντικό να αναφερθεί ότι στον παραπάνω περιορισμό δεν έχει συμπεριληφθεί η παροχетеυτικότητα του αγωγού υδροληψίας, καθώς θεωρήθηκε ότι έχει διαστασιοποιηθεί επαρκώς για τις ανάγκες ύδρευσης και άρδευσης, και δεδομένου ότι έχει εμφανιστεί έλλειμμα στη ζήτηση, το όριο αυτό σίγουρα δεν έχει εξαντληθεί.

Στην επόμενη φάση υπολογίζεται η εκροή από τον ταμιευτήρα για την κάλυψη των αναγκών της άρδευσης. Η ποσότητα της εκροής για άρδευση θα είναι ίση με την ελάχιστη ποσότητα μεταξύ της ζήτησης, του αποθέματος του ταμιευτήρα και της παροχетеυτικότητας του αγωγού. Αντιθέτως με την ύδρευση, στην περίπτωση που εμφανιστεί έλλειμμα, τότε αυτό δεν προβλέπεται να καλύπτεται, καθώς προτεραιότητα έναντι της αρδευτικής χρήσης έχει η χρήση για την εξισορρόπηση του ενεργειακού ισοζυγίου. Επομένως, δεν ενεργοποιούνται επιπλέον εκροές από τη δεξαμενή ανάντη, προκειμένου το ενεργειακό δυναμικό του νερού αυτού να διατηρείται σε όσο το δυνατόν υψηλότερα επίπεδα και να είναι διαθέσιμο σε περιόδους αιχμής.

Μετά από την ολοκλήρωση των απολήψεων, ελέγχεται το απόθεμα του ταμιευτήρα. Στην περίπτωση που αυτό υπερβαίνει την ωφέλιμη χωρητικότητά του, τότε αντλείται νερό προς την ανάντη δεξαμενή. Η ποσότητα που αντλείται είναι το ελάχιστο μεταξύ της περίσσειας νερού, της παροχетеυτικότητας του αγωγού προσαγωγής και της διαθέσιμης χωρητικότητας της δεξαμενής. Διευκρινιστικά, στην περίπτωση που υπάρχει περίσσεια νερού στον ταμιευτήρα, θα έχουν καλυφθεί σίγουρα οι υδατικές ανάγκες, επομένως, δεν θα υπάρξει ανάγκη για υδροληψία από τη δεξαμενή. Κατ' αυτό τον τρόπο, με την παραπάνω διατύπωση εξασφαλίζεται η σωστή προσομοίωση της λειτουργίας του αντλιοστροβίλου, κατά την οποία η ροή του νερού έχει μία μοναδική κατεύθυνση στο ίδιο χρονικό βήμα. Έπειτα, στην περίπτωση που και μετά την άντληση νερού παραμένει κάποια πλεονάζουσα ποσότητα, τότε αυτή διοχετεύεται μέσω του κατάντη αγωγού για παραγωγή ενέργειας. Η ποσότητα αυτή προκύπτει από το ελάχιστο μεταξύ της πλεονάζουσας ποσότητας και της παροχетеυτικότητας του αγωγού προσαγωγής. Τέλος, αν δεν είναι δυνατή η άντληση ή παροχетеυση όλης της περίσσειας νερού, τότε το εναπομείναν μέρος της εκρέει μέσω του υπερχειλιστή.

Όλα τα παραπάνω αφορούν τις εργασίες που γίνονται με γνώμονα τις ροές νερού στο εξεταζόμενο σύστημα. Αφού συντελεστούν οι εργασίες αυτές, υπολογίζεται η παραγωγή ενέργειας από τους στρόβιλους και η ενέργεια που καταναλώθηκε μέσω της άντλησης. Η αρχική ζήτηση ενέργειας που εισάγεται στο μοντέλο λειτουργίας του συστήματος έχει προκύψει από τη διαφορά μεταξύ της ζήτησης ενέργειας και της παραγωγής ενέργειας από τις αιολικές και φωτοβολταϊκές εγκαταστάσεις. Η ενέργεια που παράχθηκε ή καταναλώθηκε λόγω των ροών νερού αναθεωρεί το παραπάνω ισοζύγιο της ενέργειας και πλέον με γνώμονα τις τρέχουσες ενεργειακές ανάγκες εκτιμώνται επιπλέον ροές νερού, όπως αναλύεται στη συνέχεια.

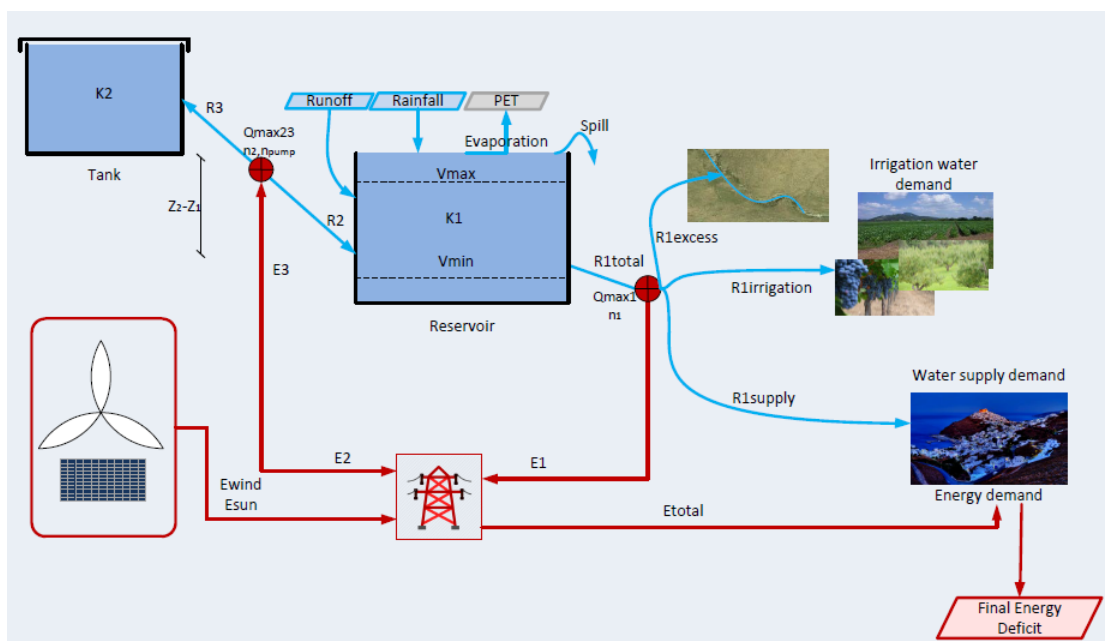
Στην περίπτωση που εμφανίζεται έλλειμμα ενέργειας, γίνεται απόληψη από την ανάντη δεξαμενή προς τον ταμιευτήρα και παράγεται ενέργεια από τον στρόβιλο του αντίστοιχου αγωγού. Για την εκτίμηση της παραπάνω απόληψης είναι απαραίτητο η ζήτηση ενέργειας να μετατραπεί στην αντίστοιχη ζήτηση νερού. Τελικά, η εκροή από τη δεξαμενή θα είναι ίση με το ελάχιστο μεταξύ της ζήτησης για την παραγωγή της απαιτούμενης ενέργειας, της παροχетеυτικότητας του αγωγού προσαγωγής, του διαθέσιμου αποθέματος της δεξαμενής και της διαθέσιμης χωρητικότητας του ταμιευτήρα. Από τον παραπάνω περιορισμό εξασφαλίζεται και πάλι η διατήρηση της μοναδικότητας της κατεύθυνσης ροής του νερού στο ίδιο χρονικό βήμα, καθώς στην περίπτωση που θα είχε ήδη εκτελεστεί μια ροή από τον ταμιευτήρα προς την δεξαμενή, τότε αυτό θα είχε συμβεί για την αποτροπή της υπερχειλίσης, επομένως η τρέχουσα διαθέσιμη χωρητικότητα του ταμιευτήρα θα ήταν μηδενική. Επιπλέον, καθώς η κάλυψη των υδρευτικών αναγκών βρίσκεται σε προτεραιότητα έναντι της παραγωγής υδροηλεκτρικής ενέργειας, το νερό δεν παροχетеύεται μέσω του κατάντη αγωγού για την παραγωγή επιπλέον ενέργειας, αλλά διατηρείται στον ταμιευτήρα για αργότερη χρήση.

Στην περίπτωση που εμφανίζεται περίσσεια ενέργειας, γίνεται άντληση νερού από τον ταμιευτήρα προκειμένου να καταστραφεί το ενεργειακό πλεόνασμα και να αποθηκευτεί ως δυναμική ενέργεια της μάζας του νερού λόγω της νέας του θέσης. Για την εκτίμηση του απαιτούμενου όγκου νερού, υπολογίζεται η απαραίτητη ποσότητα νερού που πρέπει να αντληθεί ώστε να καταναλωθεί το συγκεκριμένο πλεόνασμα, ενώ η ποσότητα που τελικά αντλείται διαμορφώνεται από το ελάχιστο μεταξύ του απαιτούμενου όγκου, της παροχетеυτικότητας του αγωγού προσαγωγής, του διαθέσιμου αποθέματος του ταμιευτήρα και της διαθέσιμης χωρητικότητας της δεξαμενής.

Τελικά, αναθεωρείται το ισοζύγιο ενέργειας και διαμορφώνονται δύο έξοδοι, μία που αφορά την περίσσεια ενέργειας και μία που αφορά το έλλειμμα. Επιπλέον, έξοδοι του μοντέλου αποτελούν και οι ροές νερού και τα αποθέματα της δεξαμενής και του ταμιευτήρα.



Τα μεγέθη των αποθεμάτων, των εκροών, των παροχευευτικότητας και των υψών πτώσης και άντλησης επικαιροποιούνται έπειτα από κάθε διεργασία που λαμβάνει χώρα, προκειμένου να πραγματοποιούνται σωστά οι απαραίτητοι για την προσομοίωση του συστήματος λογικοί έλεγχοι. Επιπλέον, τα αποθέματα που προκύπτουν μετά την ολοκλήρωση όλων των διεργασιών αποτελούν τις αρχικές συνθήκες του επόμενου βήματος. Οι μονάδες μέτρησης των μεταβλητών που αφορούν τις ροές νερού είναι σε  $m^3$ , ενώ αυτές που αφορούν τις ροές ενέργειας γίνονται σε kWh. Στο Σχήμα 4-2 που ακολουθεί οπτικοποιείται το μοντέλο προσομοίωσης του υβριδικού συστήματος, ενώ ο αντίστοιχος αλγόριθμος δίνεται στο Παράρτημα.



Σχήμα 4-2: Μοντέλο προσομοίωσης λειτουργίας υβριδικού συστήματος


#### 4.4 Δεδομένα εισόδου

Για την κατάρτιση του σχήματος προσομοίωσης από τα νευρωνικά δίκτυα χρησιμοποιήθηκαν δύο σέτ δεδομένων. Το πρώτο αποτελείται από τις χρονοσειρές των μεταβλητών που χρειάζονται ως εισοδοί στο αναλυτικό μοντέλο προσομοίωσης και τα αποτελέσματα που προκύπτουν χρησιμοποιούνται για την εκπαίδευση των νευρωνικών δικτύων. Το δεύτερο αποτελείται από συνθετικές χρονοσειρές των ίδιων μεταβλητών, οι οποίες εισάγονται και αυτές στο αναλυτικό μοντέλο προσομοίωσης ώστε να προκύψουν τα δεδομένα σύμφωνα με τα οποία γίνεται η αξιολόγηση του σχήματος των νευρωνικών δικτύων. Κατά αυτό τον τρόπο δίνεται η δυνατότητα να ληφθεί υπόψη η αβεβαιότητα των αντίστοιχων διαδικασιών, καθώς και να παρέχει επαρκώς μεγάλα δείγματα για καλύτερη αξιολόγηση.


#### 4.4.1 Εισροές στο σύστημα

##### i. Βροχόπτωση και θερμοκρασία

Οι χρονοσειρές βροχόπτωσης και θερμοκρασίας που χρησιμοποιήθηκαν λήφθηκαν από τη μελέτη των Paroulakos *et al.* (2017) και έχουν εκτιμηθεί στην ημερήσια χρονική κλίμακα. Για την δημιουργία των αντίστοιχων συνθετικών χρονοσειρών χρησιμοποιήθηκε το στοχαστικό πλαίσιο που εφαρμόζεται μέσω του προγράμματος Castalia. Το συγκεκριμένο μοντέλο χρησιμοποιεί σύγχρονες στοχαστικές μεθοδολογίες, οι οποίες διασφαλίζουν τη διατήρηση των απαραίτητων στατιστικών χαρακτηριστικών των αρχικών ιστορικών δεδομένων σε τρεις χρονικές κλίμακες, ετήσια, μηνιαία και ημερήσια. Επιπλέον, αναπαράγει τη μακροχρόνια εμμονή (δυναμική Hurst-Kolmogorov) σε ετήσια και υπερετήσια κλίμακα, την περιοδικότητα και τα διαλείπουσα συμπεριφορά διεργασιών όπως η βροχόπτωση. Στα Διαγράμματα 4-3 και 4-4 απεικονίζονται οι χρονοσειρές των υπόψη μεταβλητών.



Διάγραμμα 4-3: Ιστορική χρονοσειρά θερμοκρασίας




Διάγραμμα 4-4: Ιστορική χρονοσειρά βροχόπτωσης

## ii. Ταχύτητα ανέμου και ηλιακή ακτινοβολία


Ο άνεμος και η ηλιακή ακτινοβολία αποτελούν τις πηγές παραγωγής της αιολικής και ηλιακής ενέργειας. Στην παρούσα μελέτη χρησιμοποιήθηκαν οι ωριαίες χρονοσειρές της παραγόμενης ενέργειας από τις πηγές αυτές για υποθετικές υποδομές δεδομένης εγκατεστημένης ισχύος, όπως προέκυψαν από τη μελέτη των Chalakatevaki *et al.* (2017). Ωστόσο, τα δεδομένα για τον άνεμο και την ηλιακή ακτινοβολία είναι αποτέλεσμα δύο άλλων μελετών, των Moschos *et al.* (2017) και των Koudouris *et al.* (2017) αντίστοιχα, και θεωρείται σκόπιμο να αναφερθεί το μεθοδολογικό πλαίσιο στο οποίο στηρίχθηκε η δημιουργία των συγκεκριμένων συνθετικών χρονοσειρών.

Η μεθοδολογία βάσει της οποίας δημιουργήθηκαν οι παραπάνω χρονοσειρές είναι αυτή που αναπτύχθηκε από τους Dimitriadis and Koutsoyiannis (2015a), η οποία είναι κατάλληλη για διαδικασίες με διπλή περιοδικότητα. Η συγκεκριμένη μεθοδολογία διατηρεί τη διπλή κυκλοστασιμότητα (ημερήσια και εποχιακή) μιας διαδικασίας μέσω των ωριαίων – μηνιαίων οριακών κατανομών, συμπεριλαμβανομένων των διαλειπόντων χαρακτηριστικών, όπως για παράδειγμα οι τιμές μηδενικής πιθανότητας. Επιπλέον, διατηρεί και τη δομή εξάρτησης μέσω της εφαρμογής ενός μοντέλου Hurst-Kolmogorov βασισμένο στο εμπειρικό κλιμακόγραμμα της κάθε διαδικασίας (Dimitriadis and Koutsoyiannis, 2015b). Το σχήμα γένεσης των συνθετικών χρονοσειρών είναι ο αλγόριθμος CSAR, ο οποίος δίνει τη δυνατότητα δημιουργίας χρονοσειρών οποιουδήποτε μήκους ακολουθώντας τη διαδικασία Hurst-Kolmogorov, ή οποιαδήποτε άλλη στοχαστική διαδικασία, με τη χρήση τυχαίων κατανομών για κάθε εσωτερική στάσιμη διαδικασία των διπλών κυκλοστάσιμων διαδικασιών. Τέλος, όλες οι χρονοσειρές αναπαράγουν εξαιρετικά καλά τα απαραίτητα χαρακτηριστικά των οριακών κατανομών και των δομών εξάρτησης κάθε διαδικασίας. Παρόλο που οι μεθοδολογίες δεν αποσκοπούν ιδιαίτερα στην αναπαραγωγή της ακραίας συμπεριφοράς, παρουσιάζουν ικανοποιητική αναπαραγωγή των ακραίων τιμών, με τη διατήρηση της ασυμμετρίας σε όλες τις περιπτώσεις, ή ακόμη και της κύρτωσης, όπως συμβαίνει με τις χρονοσειρές που δημιουργούνται με την παραπάνω μέθοδο (Dimitriadis and Koutsoyiannis, 2015a).

Στα Διαγράμματα 4-5 και 4-6 απεικονίζονται οι χρονοσειρές της παραγόμενης ηλιακής και αιολικής ενέργειας, βάσει των ιστορικών καταγραφών των αντίστοιχων μετεωρολογικών μεταβλητών.



Διάγραμμα 4-5: Παραγωγή ηλιακής ενέργειας




Διάγραμμα 4-6: Παραγωγή αιολικής ενέργειας

#### 4.4.2 Ζητήσεις

##### i. Ζήτηση νερού ύδρευσης

Οι χρονοσειρές ημερήσιας ζήτησης νερού ύδρευσης εκτιμήθηκαν σε προηγούμενη έρευνα (Παρουακος *et al.*, 2017). Οι τιμές της χρονοσειράς αποτελούνται από δύο συστατώσες, μία ντετερμινιστική και μία στοχαστική. Η ντετερμινιστική συστατώσα αντιπροσωπεύει τις εποχιακές διακυμάνσεις στην κατά κεφαλήν ζήτηση του νερού και τις αντίστοιχες μεταβολές ανάλογα με τον εξυπηρετούμενο πληθυσμό (μόνιμοι κάτοικοι ή επισκέπτες/τουρίστες). Η στοχαστική συστατώσα αποτελεί συνάρτηση της ημερήσιας θερμοκρασίας. Στο Διάγραμμα 4-7 φαίνεται η χρονοσειρά ζήτησης νερού ύδρευσης.



Διάγραμμα 4-7: Ζήτηση νερού ύδρευσης.

## ii. Ζήτηση\_ενέργειας

Τα δεδομένα για τη ζήτηση ενέργειας έχουν προκύψει από προηγούμενη μελέτη (Manrogeorgos *et al.*, 2017). Η συνθετική χρονοσειρά μήκους 100 ετών για την ωριαία ζήτηση της ενέργειας δημιουργήθηκε βάσει των ιστορικών δεδομένων ζήτησης των δύο ετών 2014 και 2015 (Διάγραμμα 4-1). Η δημιουργία της έγινε βάσει προσομοίωσης μέσω block bootstrap. Πιο συγκεκριμένα, η ιστορική χρονοσειρά μονιμοποιείται με αφαίρεση της μέσης τιμής και με διαίρεση με την τυπική απόκλιση που προκύπτει ανά ώρα της ημέρας για κάθε μήνα, δηλαδή τη μέση τιμή και την τυπική απόκλιση της πρώτης ώρας του Ιανουαρίου, της δεύτερης ώρας του Ιανουαρίου, ... , της τελευταίας ώρας του Δεκεμβρίου. Στη συνέχεια, από τη μονιμοποιημένη χρονοσειρά επιλέγεται μια αλληλουχία, της οποίας οι τιμές ανακατανέμονται και έτσι αποτελούν τμήμα της συνθετικής χρονοσειράς. Η διαδικασία αυτή επαναλαμβάνεται μέχρι η νέα συνθετική χρονοσειρά να αποκτήσει το επιθυμητό μήκος, η οποία στη συνέχεια απομονιμοποιείται με πολλαπλασιασμό με την τυπική απόκλιση και με πρόσθεση της μέσης τιμής της αντίστοιχης ώρας. Γνώμονας της διαδικασίας αυτής αποτελεί η διατήρηση της περιοδικότητας, των μέσων όρων, της τυπικής απόκλισης και της αυτοσυσχέτισης των εικοσιπέντε πρώτων υπολοίπων.


## 4.5 Αποτελέσματα

Στην παρούσα ενότητα παρουσιάζονται τα αποτελέσματα που προκύπτουν από την εφαρμογή του μεθοδολογικού πλαισίου που περιγράφηκε προηγουμένως. Αρχικά, παρουσιάζονται τα αποτελέσματα, όπως αυτά προκύπτουν από την αναλυτική προσομοίωση σύμφωνα με τα ιστορικά δεδομένα, σε μορφή διαγραμμάτων. Στη συνέχεια, παρουσιάζονται τα αντίστοιχα διαγράμματα των αποτελεσμάτων που χρησιμοποιήθηκαν για την εκπαίδευση των νευρωνικών δικτύων, ενώ τα

αποτελέσματα για τα δεδομένα επαλήθευση είναι διαθέσιμα στο Παράρτημα. Λόγω του ότι η διαθέσιμη ιστορική χρονοσειρά ενεργειακής ζήτησης έχει μήκος 2 έτη και οι διαθέσιμες ιστορικές χρονοσειρές των υδρομετεωρολογικών μεταβλητών είναι μήκους 7 ετών, τα δεδομένα εκπαίδευσης των νευρωνικών δικτύων προέκυψαν από την αναλυτική προσομοίωση με χρήση των ιστορικών δεδομένων των υδρομετεωρολογικών μεταβλητών και συνθετικών χρονοσειρών ίσου μήκους για την ενεργειακή ζήτηση και υποθετική παραγωγή ενέργειας. Τα δεδομένα για αξιολόγηση των νευρωνικών δικτύων προέκυψαν από την αναλυτική προσομοίωση με χρήση των συνθετικών δεδομένων των κοινών ετών των αντίστοιχων χρονοσειρών, οι οποίες είχαν μήκος 92 έτη.

#### 4.5.1 Αποτελέσματα ιστορικής προσομοίωσης

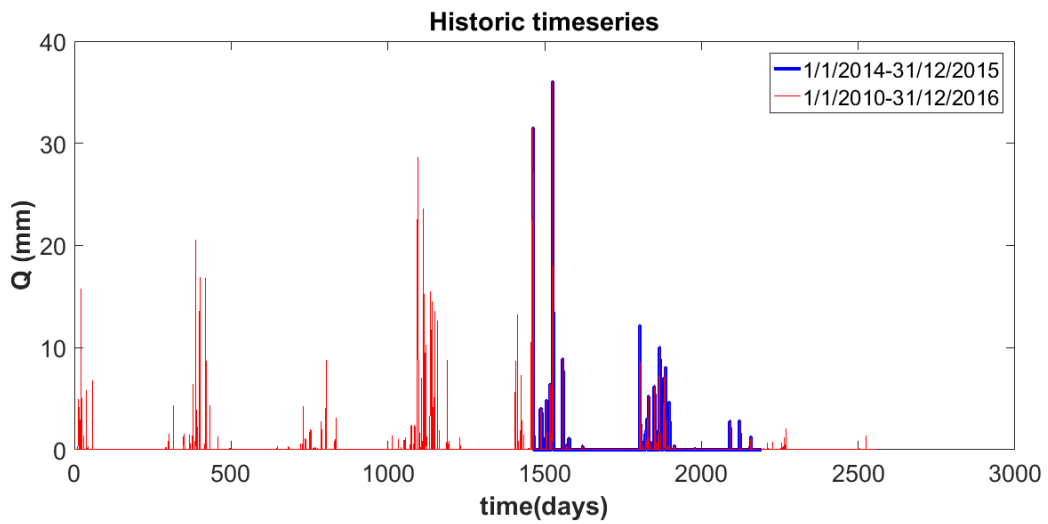
Στο Διάγραμμα 4-8 καταγράφονται τα αποτελέσματα του παραμετρικού μοντέλου για τη δυνητική εξατμοδιαπνοή.




Διάγραμμα 4-8: Χρονοσειρά δυνητικής εξατμοδιαπνοής για τα ιστορικά έτη

Στη συνέχεια, ακολουθούν τα αποτελέσματα του υδρολογικού μοντέλου και πιο συγκεκριμένα τα μεγέθη της απορροής, της πραγματικής εξατμοδιαπνοής, της εδαφικής υγρασίας και των διαφυγών προς της θάλασσα. Οι χρονοσειρές των αποτελεσμάτων αυτών καταγράφονται στα Διαγράμματα 4-9 έως 4-12 αντίστοιχα.


Η χρονοσειρά της ζήτησης αρδευτικού νερού για την ίδια περίοδο, όπως υπολογίστηκε από τη σχέση (4.5) και έπειτα από τη μετατροπή σε ωριαίο χρονικό βήμα καταγράφεται στο Διάγραμμα 4-13. Οι καθαρές εισροές στον ταμιευτήρα, όπως υπολογίστηκαν από τη σχέση (4.6) απεικονίζονται, σε ωριαίο βήμα, στο Διάγραμμα 4-14.




Διάγραμμα 4-9: Προσομοιωμένη απορροή ιστορικών ετών



Διάγραμμα 4-10: Προσομοιωμένη εξατμοδιαπνοή ιστορικών ετών




Διάγραμμα 4-11: Προσομοιωμένη εδαφική υγρασία ιστορικών ετών




Διάγραμμα 4-12: Προσομοιωμένες απώλειες προς τη θάλασσα ιστορικών ετών





Διάγραμμα 4-13: Εκτίμηση αρδευτικής ζήτησης σε ωριαίο χρονικό βήμα




Διάγραμμα 4-14: Εκτιμώμενες καθαρές εισροές στον ταμιευτήρα

Σε όλα τα παραπάνω διαγράμματα, με μπλε χρώμα επισημαίνονται τα κοινά έτη για τα οποία υπάρχουν ιστορικές καταγραφές των δεδομένων ζήτησης ενέργειας.


Στο Διάγραμμα 4-15 καταγράφεται η αρχική ζήτηση ενέργειας μαζί με το ισοζύγιο ενέργειας που προκύπτει από τη διάθεση της παραχθείσας ανανεώσιμης ενέργειας, που έχει καταγραφεί στα Διαγράμματα 4-5 και 4-6 για την κάλυψη της ζήτησης. Όπως φαίνεται στο Διάγραμμα 4-15, η ανανεώσιμη ενέργεια που παράγεται δεν επαρκεί για την πλήρη κάλυψη της ζήτησης ενέργειας, με αποτέλεσμα να προκύπτει έλλειμμα ενέργειας, στην ωριαία κλίμακα. Ταυτόχρονα, σε άλλες χρονικές στιγμές (ώρες) υπάρχουν πλεονάσματα ενέργειας, καθώς η παραγωγή ηλεκτρικής ενέργειας

από τον άνεμο και τον ήλιο δεν είναι δυνατόν να ρυθμίζονται ώστε να συγχρονίζονται με τη ζήτηση.


Από τις προηγούμενες μεταβλητές, οι χρονοσειρές ζήτησης υδρευτικού και αρδευτικού νερού, των καθαρών εισροών στον ταμιευτήρα καθώς και του ισοζυγίου ενέργειας σε ωριαία χρονική κλίμακα είναι αυτές που αποτελούν τις εισόδους του μοντέλου προσομοίωσης του υβριδικού σταθμού. Η προσομοίωση αυτή πραγματοποιήθηκε για τα δύο έτη που υπάρχουν κοινές καταγραφές όλων των απαραίτητων δεδομένων. Στα διαγράμματα που ακολουθούν αναπαριστώνται οι χρονοσειρές των μεταβλητών του συστήματος όπως προκύπτουν από την παραπάνω προσομοίωση. Συγκεκριμένα, αφορούν στα αποθέματα του ταμιευτήρα και της δεξαμενής (Διαγράμματα 4-16 και 4-17), τις εκροές από τον ταμιευτήρα για άρδευση και ύδρευση, τις απώλειες λόγω υπερχείλισης (Διαγράμματα 4-18 και 4-19), τις ροές νερού μεταξύ της δεξαμενής και του ταμιευτήρα (Διαγράμματα 4-20 και 4-21) και το ισοζύγιο ενέργειας όπως αυτό διαμορφώνεται τελικά σε σύγκριση με την αρχική του μορφή (Διάγραμμα 4-22).




Διάγραμμα 4-15: Ζήτηση ενέργειας και ενεργειακό ισοζύγιο έπειτα από τη διάθεση ανανεώσιμης ενέργειας.




Διάγραμμα 4-16: Συνολικό και ωφέλιμο απόθεμα ταμιευτήρα




Διάγραμμα 4-17: Απόθεμα δεξαμενής




Διάγραμμα 4-18: Συνολική εκροή από τον ταμιευτήρα




Διάγραμμα 4-19: Απώλειες ταμιευτήρα λόγω υπερχειλίσης



Διάγραμμα 4-20: Ροή από την δεξαμενή προς τον ταμιευτήρα




Διάγραμμα 4-21: Ροή από τον ταμιευτήρα προς τη δεξαμενή




Διάγραμμα 4-22: Αρχικό και τελικό ισοζύγιο όπως διαμορφώνεται μετά την αναρρύθμιση μέσω της αντλησοταμίευσης

#### 4.5.2 Δεδομένα εκπαίδευσης νευρωνικών δικτύων


Στα Διαγράμματα 4-23 έως 4-29 παρουσιάζονται τα αποτελέσματα της προσομοίωσης της λειτουργίας του υβριδικού συστήματος που πραγματοποιήθηκε με σκοπό την παραγωγή δεδομένων εκπαίδευσης για τα νευρωνικά δίκτυα.



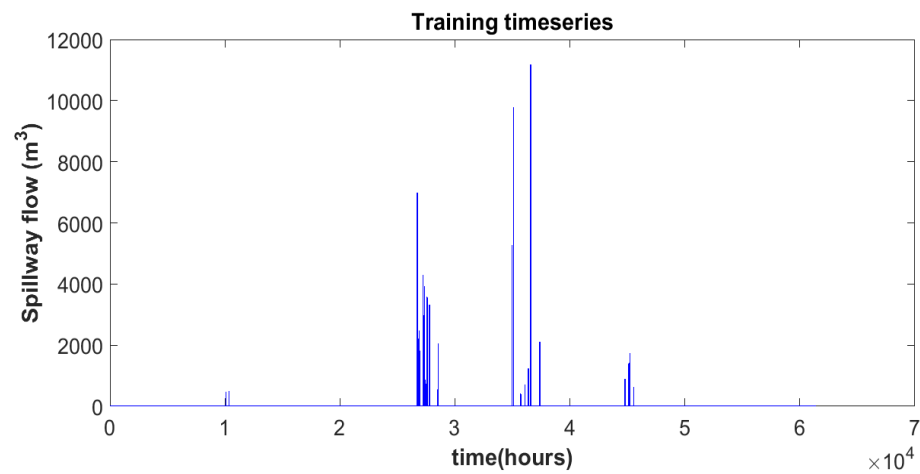
Διάγραμμα 4-23: Συνολικό και ωφέλιμο απόθεμα ταμιευτήρα




Διάγραμμα 4-24: Απόθεμα δεξαμενής




Διάγραμμα 4-26: Συνολική εκροή από τον ταμιευτήρα




Διάγραμμα 4-25: Απώλειες ταμιευτήρα λόγω υπερχειλίσης



Διάγραμμα 4-29: Ροή από την δεξαμενή προς τον ταμιευτήρα



Διάγραμμα 4-28: Ροή από τον ταμιευτήρα προς τη δεξαμενή



Διάγραμμα 4-27: Αρχικό και τελικό ισοζύγιο όπως διαμορφώνεται μετά την αναρρύθμιση μέσω της αντλιοσταμείωσης

## 5. Υποκατάστατα αναλυτικού μοντέλου μέσω ANN

Το αναλυτικό σχήμα προσομοίωσης που αναπτύχθηκε στην προηγούμενη ενότητα, αποτελείται από τμήματα με απλές πράξεις (παραμετρικό μοντέλο εξωγήινης ακτινοβολίας, μοντέλο ζήτησης νερού άρδευσης) και από τμήματα προσομοίωσης των συντελούμενων λειτουργιών του συστήματος νερού-ενέργειας που είναι περισσότερο πολύπλοκα (μοντέλο βροχής-απορροής, μοντέλο λειτουργίας υβριδικού συστήματος). Δεδομένου ότι οι απλές πράξεις δεν χαρακτηρίζονται από το μεγάλο υπολογιστικό φόρτο των πολύπλοκων προσομοιώσεων, τα αντίστοιχα τμήματα διατηρούνται αυτούσια. Αντιθέτως, τα μοντέλα βροχής-απορροής και λειτουργίας του υβριδικού σταθμού αντικαθίστανται από δομές τεχνητών νευρωνικών δικτύων, οι οποίες προσομοιώνουν την επιφάνεια απόκρισης που προκύπτει από την αναλυτική προσομοίωση. Πιο συγκεκριμένα, τα τεχνητά νευρωνικά δίκτυα που δημιουργούνται λαμβάνουν τις ίδιες εισόδους με τα αντίστοιχα αναλυτικά μοντέλα και δίνουν ως αποτέλεσμα τις ίδιες ή κάποιες από τις εξόδους τους.

Η κατάρτιση του κατάλληλου σχήματος προσομοίωσης με χρήση των νευρωνικών δικτύων γίνεται μέσω πολλαπλών δοκιμών και στη συνέχεια επιλέγεται το καταλληλότερο σενάριο με βάση τον δείκτη αποτελεσματικότητας (NSE), τόσο για τις ιστορικές όσο και για τις συνθετικές χρονοσειρές. Ο δείκτης αυτός περιγράφεται από τη μαθηματική σχέση:

$$NSE = 1 - \frac{\sum_{i=1}^n (Y_{\text{αναλυτικό},i} - Y_{\text{υποκατάστατο},i})^2}{\sum_{i=1}^n (Y_{\text{αναλυτικό},i} - \overline{Y_{\text{αναλυτικό}}})^2} \quad (6)$$

Στη συνέχεια περιγράφεται η διαδικασία που ακολουθήθηκε ξεχωριστά για κάθε αναλυτικό μοντέλο προσομοίωσης.

### 5.1 Τα νευρωνικά δίκτυα για το μοντέλο βροχής-απορροής

Το μοντέλο βροχής-απορροής είναι αυτό πάνω στο οποίο έγιναν οι περισσότερες δοκιμές, καθώς ήταν το πρώτο που προσομοιώθηκε. Οι δοκιμές αυτές ήταν απαραίτητο να γίνουν προκειμένου να προκύψουν συμπεράσματα για τη λήψη των σωστών αποφάσεων που αφορούν:

- στον καταλληλότερο από τους διαθέσιμους αλγορίθμους εκπαίδευσης.
- στο διαχωρισμό των δεδομένων χρονοσειρών στα σετ για εκπαίδευση, για τεστ και για αξιολόγηση: τρόπος διαχωρισμού και μήκος χρονοσειρών.
- στις εξόδους του νευρωνικού δικτύου: μία ή πολλαπλές έξοδοι.
- στην κατάλληλη δομή του νευρωνικού δικτύου: αριθμός κρυμμένων επιπέδων και αριθμός νευρώνων σε κάθε επίπεδο.



Είσοδοι των νευρωνικών δικτύων αποτελούν, κάθε φορά, η θερμοκρασία, η εξωγήινη ακτινοβολία και η βροχόπτωση.

Τα σενάρια που δοκιμάστηκαν μπορούν να κατηγοριοποιηθούν κατά ομάδες:

- **Ομάδα Α:** Εκπαίδευση νευρωνικών δικτύων με τον αλγόριθμο «scaled conjugate gradient», τα οποία έχουν διαφορετικές δομές και διαφορετικό διαχωρισμό των δεδομένων. Έξοδοί τους αποτελούν η απορροή και η πραγματική εξατμοδιαπνοή, οι οποίες προκύπτουν από το ίδιο νευρωνικό δίκτυο, διπλών, για τη συγκεκριμένη περίπτωση, εξόδων. Ο τρόπος που γίνεται ο διαχωρισμός των δεδομένων είναι η τυχαία επιλογή, όπως καθορίζεται από την προεπιλογή του προγράμματος, επομένως για κάθε σενάριο χρησιμοποιήθηκαν διαφορετικά σετ για εκπαίδευση, τεστ και αξιολόγηση. Ο σκοπός των σεναρίων της ομάδας αυτής είναι καθαρά διερευνητικός και βασίζεται σε τυχαίες δοκιμές. Από τη διαδικασία αυτή έχουν προκύψει 23 διαφορετικά νευρωνικά δίκτυα.
- **Ομάδα Β:** Εκπαίδευση νευρωνικών δικτύων ενός κρυμμένου επιπέδου με τον αλγόριθμο «Bayesian regularization». Ο διαχωρισμός των δεδομένων γίνεται με τον ίδιο τρόπο και για το ίδιο μήκος χρονοσειρών, προκειμένου να είναι εφικτή η σωστή σύγκριση μεταξύ των διαφορετικών δοκιμών. Η εκπαίδευση γίνεται για μέγεθος του κρυμμένου επιπέδου ίσο με 1 έως 100 νευρώνες και για πολλαπλές εξόδους, για την ταυτόχρονη προσομοίωση της απορροής, της πραγματικής εξατμοδιαπνοής και της αποθήκευσης εδαφικής υγρασίας. Από τη διαδικασία αυτή έχουν προκύψει 100 διαφορετικά νευρωνικά δίκτυα.
- **Ομάδα Γ:** Εκπαίδευση νευρωνικών δικτύων ενός κρυμμένου επιπέδου με τον αλγόριθμο «Bayesian regularization». Ο διαχωρισμός των δεδομένων γίνεται με τον ίδιο τρόπο και για το ίδιο μήκος χρονοσειρών, ενώ η εκπαίδευση γίνεται για μέγεθος του κρυμμένου επιπέδου ίσο με 1 έως 50 νευρώνες και για μία απλή έξοδο. Η παραπάνω διαδικασία επαναλαμβάνεται για τις τρεις διαφορετικές εξόδους, την απορροή, την πραγματική εξατμοδιαπνοή και την αποθήκευση εδαφικής υγρασίας. Από τις παραπάνω εκπαιδεύσεις προκύπτουν 50 διαφορετικά νευρωνικά δίκτυα για κάθε διαφορετική έξοδο.
- **Ομάδα Δ:** Εκπαίδευση νευρωνικών δικτύων ενός κρυμμένου επιπέδου με τον αλγόριθμο «Bayesian regularization». Ο διαχωρισμός των δεδομένων γίνεται με τον ίδιο τρόπο και για το ίδιο μήκος χρονοσειρών, ενώ η εκπαίδευση γίνεται για μέγεθος του κρυμμένου επιπέδου ίσο με 15 νευρώνες και για πολλαπλές εξόδους, για την ταυτόχρονη προσομοίωση της απορροής, της πραγματικής εξατμοδιαπνοής και της αποθήκευσης εδαφικής

υγρασίας. Η ειδοποιός διαφορά μεταξύ των διαφορετικών εκπαιδεύσεων είναι ότι σε κάθε επανάληψη της διαδικασίας προστίθεται ένα επιπλέον βήμα υστέρησης της βροχόπτωσης. Συνεπώς, η πρώτη εκπαίδευση γίνεται λαμβάνοντας υπόψη τα δεδομένα της θερμοκρασίας και της εξωγήινης ακτινοβολίας του τρέχοντος βήματος και τη βροχόπτωση του τρέχοντος και του προηγούμενου χρονικού βήματος, η δεύτερη λαμβάνοντας υπόψη τη θερμοκρασία και την εξωγήινη ακτινοβολία του τρέχοντος βήματος και τη βροχόπτωση του τρέχοντος και μέχρι δύο προηγούμενα χρονικά βήματα κοκ. Από τις παραπάνω εκπαιδεύσεις προκύπτουν 50 διαφορετικά νευρωνικά δίκτυα (Ομάδα Δ1). Επιπλέον, η παραπάνω διαδικασία επαναλήφθηκε για την προσομοίωση της απορροής, ως μόνης εξόδου του νευρωνικού δικτύου (Ομάδα Δ2).

## 5.2 Τα νευρωνικά δίκτυα για το μοντέλο λειτουργίας του υβριδικού συστήματος

Για όλα τα νευρωνικά δίκτυα που χρησιμοποιήθηκαν για την προσομοίωση των αποκρίσεων του μοντέλου λειτουργίας του υβριδικού συστήματος χρησιμοποιήθηκε ο ίδιος αλγόριθμος εκπαίδευσης και ο ίδιος διαχωρισμός των δεδομένων. Τα σενάρια που δοκιμάστηκαν μπορούν να ταξινομηθούν σε τρεις ομάδες:

- **Ομάδα Α:** Εκπαίδευση νευρωνικών δικτύων μίας μοναδικής εξόδου. Οι εισοδοί των νευρωνικών δικτύων ήταν οι ίδιες με αυτές του αντίστοιχου αναλυτικού μοντέλου, ενώ έξοδο του κάθε ενός αποτελούσε μία από τις προσομοιωμένες εκροές νερού από τους στρόβιλους, είτε του ταμιευτήρα είτε της δεξαμενής. Η προσέγγιση αυτή στη συνέχεια παραμερίστηκε, καθώς οι συσχετίσεις μεταξύ των δεδομένων ήταν αρκετά πολύπλοκες, με αποτέλεσμα οι εκπαιδεύσεις να είναι χρονοβόρες και να μην υπάρχει η δυνατότητα πολλαπλών εκπαιδεύσεων ώστε να επιλεγεί το αποδοτικότερο νευρωνικό δίκτυο.
- **Ομάδα Β:** Εκπαίδευση νευρωνικών δικτύων με μοναδική έξοδο την τελική ζήτηση ενέργειας. Προκειμένου να επιτευχθεί ένα κατάλληλο και αποδοτικό νευρωνικό δίκτυο έγιναν πολλαπλές δοκιμές αναφορικά με τον τρόπο προσέγγισης των εξόδων του νευρωνικού. Πιο συγκεκριμένα, οι εισοδοί των νευρωνικών δικτύων ήταν οι ίδιες με αυτές του αντίστοιχου αναλυτικού μοντέλου, όμως οι εξοδοί τους διέφεραν. Επομένως, τα νευρωνικά δίκτυα που εκπαιδεύτηκαν αφορούν:
  - i) Την προσομοίωση της χρονοσειράς της τελικής ζήτησης ενέργειας συνολικά, με τα ελλείμματα και τα πλεονάσματα να προκύπτουν από ίδιο νευρωνικό δίκτυο. Η εκπαίδευση γίνεται

για μέγεθος του κρυμμένου επιπέδου ίσο με 1 έως 93 νευρώνες. Στο σημείο αυτό η διαδικασία εκπαίδευσης δεν πραγματοποιήθηκε για παραπάνω νευρώνες, καθώς απαιτούσε πολύ περισσότερο χρόνο. Αναλυτικότερα, η διαδικασία εκπαίδευσης για το πρώτο νευρωνικό δίκτυο που αποτελούνταν από έναν κρυμμένο νευρώνα διήρκησε λιγότερο από πέντε λεπτά, ενώ για το τελευταίο σχήμα, με τους 93 νευρώνες, διήρκησε περίπου 6 ώρες.

- ii) Την προσομοίωση της τελικής ζήτησης ενέργειας ξεχωριστά για τα ελλείμματα και τα πλεονάσματα ενέργειας. Επομένως, εκπαιδεύονται διαφορετικά νευρωνικά δίκτυα τα οποία έχουν τις ίδιες εισόδους, αλλά έξοδό τους αποτελεί είτε το τελικό έλλειμμα είτε το τελικό πλεόνασμα της ενέργειας.
- **Ομάδα Γ:** Εκπαίδευση νευρωνικών δικτύων με μοναδική έξοδο την τελική ζήτηση ενέργειας, όμως με ορισμένες τροποποιήσεις αναφορικά με τις εισόδους (i) και με τη δομή του νευρωνικού δικτύου (ii). Πιο αναλυτικά, η εκπαίδευση των νευρωνικών δικτύων αφορά:
    - i) Την προσομοίωση της χρονοσειράς της τελικής ζήτησης ενέργειας συνολικά, όπως και στην προηγούμενη περίπτωση, όμως με επιπλέον εισόδους τις χρονοσειρές των αποθεμάτων του ταμιευτήρα και της δεξαμενής, όπως προκύπτουν από το αναλυτικό μοντέλο. Η εκπαίδευση επαναλήφθηκε 50 φορές για αριθμό νευρώνων ίσο με 10 σε ένα κρυμμένο επίπεδο. Είναι σημαντικό να αναφερθεί ότι καθώς οι επιπλέον εισοδοί που χρησιμοποιούνται αποτελούν εξόδους του αναλυτικού μοντέλου προσομοίωσης, τα νευρωνικά δίκτυα δεν μπορούν στη συγκεκριμένη περίπτωση να χρησιμοποιηθούν για πλήρη υποκατάσταση. Παρόλα αυτά, το συγκεκριμένο παράδειγμα δίνει τη δυνατότητα κατανόησης της σημασίας που έχει η διατήρηση της μνήμης του συστήματος.
    - ii) Την προσομοίωση της τελικής ζήτησης ενέργειας συνολικά μέσω μιας διαφορετικής δομής νευρωνικού δικτύου. Για το συγκεκριμένο σενάριο, το νευρωνικό δίκτυο που εκπαιδεύτηκε δεν είχε την ίδια δομή με τα προηγούμενα (multiple-layer perceptrons), αλλά αποτελεί ένα μη-γραμμικό αυτοπαλινδρούμενο νευρωνικό δίκτυο με χρήση εξωτερικών - εξωγενών δεδομένων εισόδου (non-linear autoregressive with

external (exogenous) input – NARX). Η δομή αυτή για τον υπολογισμό της τιμής εξόδου στο τρέχον βήμα χρησιμοποιεί τα δεδομένα εισόδου του παρόντος βήματος και προηγούμενων βημάτων, το πλήθος των οποίων ορίζεται από το χρήστη, και τα δεδομένα εξόδου προηγούμενων βημάτων, των οποίων το πλήθος ορίζεται και πάλι από το χρήστη. Λόγω του ότι ήταν επιθυμητό να ληφθούν υπόψη τα δεδομένα των αποθεμάτων και να αποτελούν μια χρονοσειρά ανατροφοδότησης του νευρωνικού δικτύου με συγκεκριμένη υστέρηση ήταν αναγκαίο να αποτελούν ταυτόχρονα και έξοδο του νευρωνικού δικτύου. Επομένως, στη συγκεκριμένη περίπτωση το νευρωνικό δίκτυο εκπαιδεύεται για μια τριπλή έξοδο, του ισοζυγίου ενέργειας συνολικά και των αποθεμάτων του ταμειυτήρα και της δεξαμενής.

### **5.3 Αποτελέσματα εκπαίδευσης νευρωνικών δικτύων**

Στην παρούσα ενότητα γίνεται παρουσίαση των αποτελεσμάτων από τις εκπαιδεύσεις των νευρωνικών δικτύων σύμφωνα με τις ομάδες που αναλύθηκαν προηγουμένως. Η παρουσίαση γίνεται μέσω διαγραμμάτων που απεικονίζουν το δείκτη αποτελεσματικότητας NSE, ανάλογα με το εξεταζόμενο νευρωνικό δίκτυο. Παράλληλα δίνονται σε πίνακες οι δομές που εμφάνισαν τον καλύτερο δείκτη αποτελεσματικότητας. Εξάιρεση σε αυτό αποτελεί η Ομάδα Α των νευρωνικών δικτύων για το μοντέλο βροχής-απορροής, για την οποία η παρουσίαση των αποτελεσμάτων γίνεται σε μορφή Πίνακα, με περισσότερες λεπτομέρειες, ώστε να καταγραφούν και να αναλυθούν όλα τα στοιχεία που συνετέλεσαν στη διαμόρφωση των αποφάσεων για τις επόμενες εκπαιδεύσεις. Οι Πίνακες με τα αποτελέσματα όλων των εκπαιδεύσεων είναι διαθέσιμοι στο Παράρτημα.

#### **5.3.1 Νευρωνικά δίκτυα για το μοντέλο βροχής – απορροής**

##### **i. Ομάδα Α**

Στον Πίνακα 5-1 που ακολουθεί παρουσιάζονται τα αποτελέσματα των αρχικών δοκιμών που αποτελούν τα σενάρια της ομάδας Α. Σε αυτόν, καταγράφονται τα αποτελέσματα των δοκιμών όπου η απορροή και η πραγματική εξατμοδιαπνοή προέρχονται από το ίδιο νευρωνικό δίκτυο διπλής εξόδου.

Πίνακας 5-1: Αποτελέσματα εκπαίδευσης και αξιολόγησης νευρωνικών δικτύων για την Ομάδα Α του υδρολογικού μοντέλου

Σενάριο	Ποσοστά δεδομένων (%)			Δομή ANN (Hidden Layer Size)	Απορροή (Q)		Πραγματική εξατμοδιαπνοή (ET)	
	Training	Validation	Testing (Cross-training)		Εκπαίδευση	Αξιολόγηση	Εκπαίδευση	Αξιολόγηση
hydro_1	70	15	15	10	0,46	0,48	0,51	0,01
hydro_2	50	25	25	10	0,57	0,54	0,38	0,21
hydro_3	50	25	25	10	0,38	0,44	0,51	-0,13
hydro_4	80	10	10	10	0,51	0,51	0,55	0,13
hydro_5	70	15	15	15	0,46	0,22	0,09	-0,36
hydro_6	50	25	25	15	0,51	0,52	0,34	0,02
hydro_7	80	10	10	15	0,53	0,45	0,46	-0,21
hydro_8	70	15	15	5,5	0,42	0,46	0,00	-0,01
hydro_9	50	25	25	5,5	0,12	0,06	-0,62	-0,55
hydro_10	80	10	10	5,5	0,45	0,53	0,01	-0,01
hydro_11	70	15	15	10,5	0,41	0,34	0,34	0,19
hydro_12	50	25	25	10,5	0,47	0,34	0,20	-0,17
hydro_13	80	10	10	10,5	0,40	0,39	-0,04	-0,11
hydro_14	70	15	15	20	0,49	-0,06	0,35	0,03
hydro_15	70	15	15	25	0,57	0,36	0,55	0,29
hydro_16	70	15	15	30	0,60	0,47	0,42	0,01
hydro_17	70	15	15	40	0,61	0,28	0,52	0,15
hydro_18	70	15	15	60	0,60	0,11	0,32	-0,21
hydro_19	70	15	15	80	0,56	-0,17	0,61	-0,03
hydro_20	70	15	15	100	0,49	-1,92	0,14	-1,06
hydro_21	70	15	15	30,25	0,54	0,31	0,43	0,09
hydro_22	70	15	15	30,30	0,35	-0,48	0,17	-0,31
hydro_23	70	15	15	30,40	0,44	-0,02	0,45	-0,06

Στα σενάρια εκπαίδευσεων 1 έως 13 διατηρείται σταθερός ο αριθμός των νευρώνων είτε σε ένα είτε σε δύο κρυμμένα επίπεδα, και αυτό που διαφέρει κάθε φορά είναι το μέγεθος των χρονοσειρών εκπαίδευσης, αξιολόγησης και για τεστ. Παρόλο που κάθε φορά τα δεδομένα κατατάσσονται με τυχαίο τρόπο στις τρεις παραπάνω ομάδες, παρατηρείται ότι για την ίδια δομή, τα νευρωνικά δίκτυα που εκπαιδεύονται με χρήση διαφορετικών τιμών παρουσιάζουν κοντινές τιμές για το συντελεστή απόδοσης NSE κατά τη διαδικασία εκπαίδευσης. Ο NSE για την απορροή κυμαίνεται περίπου από 0,40 έως 0,60, ενώ για την εξατμοδιαπνοή παρουσιάζει σχεδόν πάντα μικρότερες τιμές για το ίδιο νευρωνικό δίκτυο. Έπειτα, στα σενάρια 14 έως 23 διατηρούνται σταθερά τα ποσοστά σύμφωνα με τα οποία διαχωρίζονται τα δεδομένα εκπαίδευσης, ενώ αλλάζει η δομή του νευρωνικού δικτύου που εκπαιδεύεται. Στις περιπτώσεις αυτές, όταν υπάρχει ένα κρυμμένο

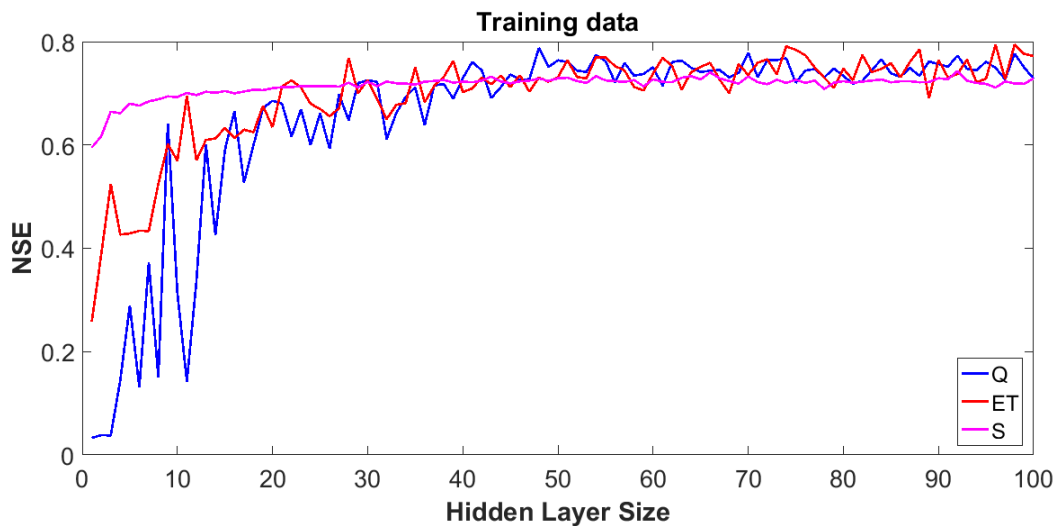
επίπεδο, ο δείκτης NSE διατηρείται σχετικά σταθερός για την απορροή, τις περισσότερες φορές κοντά στο 0,60, ενώ για την εξατμοδιαπνοή κυμαίνεται από το 0,40 έως 0,60. Αντίθετα, στις περιπτώσεις με δύο κρυμμένα επίπεδα, παρατηρείται ότι όσο αυξάνεται η πολυπλοκότητα της δομής τόσο λιγότερο αποδοτικό γίνεται το νευρωνικό δίκτυο. Σε όλες τις παραπάνω περιπτώσεις, κατά την αξιολόγηση βάσει των συνθετικών χρονοσειρών ο δείκτης επίδοσης παρουσιάζει τιμές από μέτρια έως καθόλου ικανοποιητικές, ενώ σχεδόν πάντα η απορροή προσεγγίζεται πολύ καλύτερα σε σχέση με την εξατμοδιαπνοή.

Επομένως, συμπεραίνεται ότι τα νευρωνικά δίκτυα διπλής εξόδου δεν είναι σε θέση να προσεγγίσουν το ίδιο καλά και τις δύο μεταβλητές ενδιαφέροντος ταυτόχρονα. Στην περίπτωση που αυτό είναι εφικτό, το ίδιο νευρωνικό δίκτυο παρουσιάζει πολύ μεγάλες διαφορές στην απόδοση μεταξύ των δεδομένων εκπαίδευσης και των συνθετικών χρονοσειρών αξιολόγησης. Για παράδειγμα, στο σενάριο hydro\_19, ο NSE έχει ικανοποιητική τιμή και για τις δύο μεταβλητές κατά την εκπαίδευση, ενώ κατά την αξιολόγηση παρουσιάζει αρνητικές τιμές, οι οποίες δεν είναι αποδεκτές.


Στη συνέχεια, προκειμένου να προκύψουν καλύτερα συγκρίσιμα σενάρια εκπαίδευσης, έγιναν μερικές ακόμα εκπαιδεύσεις όπου διατηρούνταν σταθερά το ποσοστό και ο τρόπος διαχωρισμού των δεδομένων εκπαίδευσης και η δομή του νευρωνικού δικτύου, αλλά με εφαρμογή διαφορετικού αλγορίθμου εκπαίδευσης. Από τις εκπαιδεύσεις αυτές προέκυψε ότι ο αλγόριθμος «Bayesian regularization» έδινε πάντα καλύτερα αποτελέσματα για το συντελεστή απόδοσης NSE, με αποτέλεσμα να είναι αυτός που αποφασίστηκε να χρησιμοποιείται για όλες τις επόμενες εκπαιδεύσεις νευρωνικών δικτύων. Τέλος, το ποσοστό και ο τρόπος διαχωρισμού των δεδομένων εκπαίδευσης διατηρήθηκαν επίσης σταθερά και δοκιμάστηκαν διαφορετικές δομές νευρωνικών δικτύων, είτε μονής είτε πολλαπλής εξόδου.

## **ii. Ομάδα Β**

Στα Διαγράμματα 5-1 και 5-2 καταγράφεται ο δείκτης αποδοτικότητας των νευρωνικών δικτύων στο στάδιο της εκπαίδευσης και στο στάδιο της επαλήθευσης αντίστοιχα και στον Πίνακα 5-2 οι δομές που είχαν την καλύτερη απόδοση και στα δύο στάδια για κάθε μεταβλητή. Είναι σημαντικό να αναφερθεί ότι οι προσομοιωμένες έξοδοι προκύπτουν από το ίδιο νευρωνικό δίκτυο κάθε φορά, ενώ ο αριθμός των νευρώνων του κρυμμένου επιπέδου αυξάνεται σε κάθε επανάληψη της εκπαιδευτικής διαδικασίας.



Διάγραμμα 5-1: Αποδοτικότητα νευρωνικών δικτύων με την αύξηση των κρυμμένων νευρώνων κατά τη διαδικασία εκπαίδευσης



Διάγραμμα 5-2: Αποδοτικότητα νευρωνικών δικτύων με την αύξηση των κρυμμένων νευρώνων κατά τη διαδικασία επαλήθευσης

Από τα παραπάνω Διαγράμματα 5-1 και 5-2 φαίνεται ότι κατά τη διαδικασία των εκπαίδευσεων, η αύξηση του αριθμού των νευρώνων του κρυμμένου επιπέδου έχει θετική επίδραση στην απόδοση του εκάστοτε νευρωνικού δικτύου, καθώς με την αύξηση τους αυξάνεται και η απόδοση, μέχρι που φτάνει σε ένα σημείο στο οποίο παραμένει σχεδόν σταθερή και για τις τρεις εξόδους εμφανίζοντας τιμές οι οποίες είναι μεγαλύτερες από το 0,6. Η ίδια συμπεριφορά παρουσιάζεται και κατά τη διαδικασία της επαλήθευσης, αλλά όχι για όλες τις μεταβλητές. Η αύξηση και έπειτα σταθεροποίηση της τιμής της απόδοσης με την αύξηση των νευρώνων ισχύει για την απορροή και την εξατμοδιαπνοή, αλλά για την εδαφική υγρασία παρουσιάζει ακριβώς την αντίθετη συμπεριφορά, αποκτώντας ακόμη και αρνητικές τιμές απόδοσης. Οι τιμές της απόδοσης κατά την επαλήθευση παρουσιάζουν

αρκετά χαμηλότερες τιμές σε σχέση με τις αντίστοιχες της εκπαίδευσης, το οποίο είναι γενικά αναμενόμενο. Ακόμη, όπως φαίνεται από τα Διαγράμματα 5-1 και 5-2, αλλά και από τον Πίνακα 5-2 που ακολουθεί, η καλύτερη δυνατή απόδοση δεν παρατηρείται στο ίδιο νευρωνικό δίκτυο για κάθε μεταβλητή. Επομένως, στη συγκεκριμένη περίπτωση, με τη χρήση ενός νευρωνικού δικτύου με πολλαπλές εξόδους δεν είναι εύκολο να επιτευχθεί υψηλή απόδοση για όλες τις προσομοιωμένες μεταβλητές ταυτόχρονα.

**Πίνακας 5-2: Καλύτερη παρατηρημένη αποδοτικότητα για τις προσομοιωμένες μεταβλητές**

Ομάδα Β	Εκπαίδευση			Αξιολόγηση		
	Q	ET	S	Q	ET	S
myNeuralNetworkHydro_4	0,14	0,43	0,66	0,08	0,09	0,50
myNeuralNetworkHydro_16	0,67	0,61	0,70	0,56	0,31	0,47
myNeuralNetworkHydro_48	0,79	0,73	0,73	0,42	0,52	0,14
myNeuralNetworkHydro_74	0,77	0,79	0,72	0,44	0,64	-0,05
myNeuralNetworkHydro_92	0,77	0,74	0,74	0,42	0,54	-0,73
myNeuralNetworkHydro_98	0,78	0,79	0,72	0,44	0,62	-1,45


### iii. Ομάδα Γ

Στα Διαγράμματα 5-3, 5-4 και 5-5 καταγράφεται ο δείκτης αποδοτικότητας των νευρωνικών δικτύων για κάθε προσομοιωμένη μεταβλητή στο στάδιο της εκπαίδευσης και στο στάδιο της επαλήθευσης και στον Πίνακα 5-3 οι δομές που είχαν την καλύτερη απόδοση και στα δύο στάδια για κάθε μεταβλητή. Τα νευρωνικά δίκτυα που αποτελούν τη συγκεκριμένη ομάδα είναι νευρωνικά δίκτυα μονής εξόδου, επομένως η κάθε μεταβλητή ενδιαφέροντος προσεγγίζεται από ένα διαφορετικό νευρωνικό δίκτυο. Τα συγκεκριμένα νευρωνικά προέκυψαν από επαναλαμβανόμενες εκπαιδεύσεις στις οποίες ο αριθμός των νευρώνων του κρυμμένου επιπέδου αυξάνεται σε κάθε επανάληψη.


Η απορροή που προσεγγίζεται μέσω των νευρωνικών δικτύων της συγκεκριμένης ομάδας παρουσιάζει μεγάλες διαφορές στο στάδιο της εκπαίδευσης και στο στάδιο της επαλήθευσης. Όπως φαίνεται από το Διάγραμμα 5-3 κατά την επαλήθευση παρουσιάζονται πολύ μεγάλες αρνητικές τιμές για την αποδόση νευρωνικών δικτύων που κατά το στάδιο της εκπαίδευσης παρουσίαζαν πολύ ικανοποιητικές τιμές απόδοσης. Η μικρότερη τιμή του δείκτη απόδοσης στο στάδιο της εκπαίδευσης ισούται με 0,64 και αυξάνεται με την αύξηση των νευρώνων φτάνοντας μέχρι και την τιμή 0,93. Κατά τη διαδικασία επαλήθευσης η μέγιστη τιμή της απόδοσης είναι 0,55, ενώ η ελάχιστη -38. Αξιοσημείωτο είναι το γεγονός ότι το νευρωνικό δίκτυο με απόδοση -38 κατά την επαλήθευση, στην εκπαίδευση έχει απόδοση 0,90. Όλα τα παραπάνω συντελούν στο να εξαχθεί το συμπέρασμα ότι πρόκειται για «υπερεκπαιδευμένα» νευρωνικά δίκτυα, καθώς εμφανίζουν υψηλή




απόδοση στα δεδομένα εκπαίδευσης, ενώ παρουσιάζουν αδυναμία προσαρμογής σε νέα δεδομένα. Το γεγονός αυτό ίσως οφείλεται είτε στην αύξηση των νευρώνων του κρυμμένου επιπέδου είτε στο γεγονός ότι έχει χρησιμοποιηθεί η περιοδική συνάρτηση της εξωγήινης ακτινοβολίας ως μεταβλητή εισόδου.



Διάγραμμα 5-3 : Αποδοτικότητα νευρωνικών δικτύων με την αύξηση των κρυμμένων νευρώνων για την απορροή



Διάγραμμα 5-4: Αποδοτικότητα νευρωνικών δικτύων με την αύξηση των κρυμμένων νευρώνων για την πραγματική εξατμοδιαπνοή



Διάγραμμα 5-5: Αποδοτικότητα νευρωνικών δικτύων με την αύξηση των κρυμμένων νευρώνων για την εδαφική υγρασία


Όσον αφορά τις μεταβλητές της πραγματικής εξατμοδιαπνοής και της εδαφικής υγρασίας, δεν παρουσιάζουν την ίδια συμπεριφορά με την απορροή. Όπως είναι αναμενόμενο, κατά το στάδιο της επαλήθευσης εμφανίζονται μικρότερες τιμές του δείκτη NSE σε σχέση με το στάδιο εκπαίδευσης, αλλά ποτέ δεν γίνονται αρνητικές. Τα νευρωνικά δίκτυα για την εξατμοδιαπνοή παρουσιάζουν καλύτερη απόδοση με την αύξηση των νευρώνων τους μέχρι ένα σημείο, έπειτα από το οποίο η αύξηση των νευρώνων δεν επηρεάζει σημαντικά την απόδοση του δικτύου. Κατά την εκπαίδευση, όταν ο δείκτης αποδοτικότητας σταθεροποιείται παρουσιάζει αρκετά ικανοποιητικές τιμές μεταξύ 0,8 και 0,9, ενώ κατά την επαλήθευση τα αντίστοιχα νευρωνικά δίκτυα παρουσιάζουν κάποιες διακυμάνσεις στην απόδοσή τους, με τα περισσότερα από αυτά να έχουν απόδοση από 0,6 έως 0,7. Αναφορικά με τα νευρωνικά δίκτυα για την εδαφική υγρασία παρατηρείται ότι η απόδοσή τους κατά την εκπαίδευση παρουσιάζει μεγαλύτερες τιμές και μεγαλύτερη σταθερότητα σε σχέση με το στάδιο της επαλήθευσης, όπου οι αποδόσεις των νευρωνικών δικτύων παρουσιάζουν μια πτωτική τάση σε σχέση με την αύξηση των νευρώνων και έχουν τιμές μικρότερες από 0,5.

Πίνακας 5-3: Καλύτερη και χειρότερη παρατηρημένη αποδοτικότητα για τις προσομοιωμένες μεταβλητές


Ομάδα Γ	Q		ET		S	
	Εκπαί- δευση	Αξιολό- γηση	Εκπαί- δευση	Αξιολό- γηση	Εκπαί- δευση	Αξιολό- γηση
myNeuralNetworkHydro_2	0,67	0,55	0,76	0,59	0,63	0,45
myNeuralNetworkHydro_4	0,78	0,35	0,80	0,65	0,66	0,50
myNeuralNetworkHydro_7	0,79	0,38	0,82	0,68	0,69	0,49
myNeuralNetworkHydro_26	0,90	-38,47	0,84	0,66	0,70	0,47
myNeuralNetworkHydro_38	0,92	-9,35	0,85	0,45	0,72	0,34
myNeuralNetworkHydro_41	0,87	-4,15	0,85	0,63	0,72	0,37
myNeuralNetworkHydro_48	0,93	-5,82	0,84	0,65	0,70	0,48

#### iv. Ομάδα Δ


Στα Διαγράμματα 5-6, 5-7 και 5-8 παρουσιάζεται ο δείκτης αποδοτικότητας των νευρωνικών δικτύων για κάθε προσομοιωμένη μεταβλητή στο στάδιο της εκπαίδευσης και στο στάδιο της επαλήθευσης και στους Πίνακα 5-4 και 5-6 οι δομές που είχαν την καλύτερη απόδοση και στα δύο στάδια για κάθε μεταβλητή. Τα νευρωνικά δίκτυα των Διαγραμμάτων 5-6 και 5-7 αποτελούν νευρωνικά δίκτυα τριπλής εξόδου, με τα οποία προσομοιώνονται ταυτόχρονα η απορροή, η πραγματική εξατμοδιαπνοή και η εδαφική υγρασία, ενώ αυτά του διαγράμματος 5-8 είναι νευρωνικά δίκτυα με μονή έξοδο την απορροή. Στις επαναλαμβανόμενες εκπαιδεύσεις διατηρήθηκε σταθερός ο αριθμός των κρυμμένων νευρώνων, ενώ σε κάθε μία από αυτές αυξανόταν το βήμα υστέρησης της βροχόπτωσης.



Διάγραμμα 5-6: Αποδοτικότητα νευρωνικών δικτύων τριπλής εξόδου με την αύξηση του βήματος υστέρησης της βροχόπτωσης στο στάδιο της εκπαίδευσης



Διάγραμμα 5-7: Αποδοτικότητα νευρωνικών δικτύων τριπλής εξόδου με την αύξηση του βήματος υστέρησης της βροχόπτωσης στο στάδιο της επαλήθευσης



Διάγραμμα 5-8: Αποδοτικότητα νευρωνικών δικτύων για την προσομοίωση της απορροής με την αύξηση του βήματος υστέρησης της βροχόπτωσης

Σύμφωνα με τα δύο προηγούμενα Διαγράμματα (5-6 και 5-7), η μεταβλητή που φαίνεται να ευνοείται περισσότερο με την αύξηση της υστέρησης είναι αυτή της εδαφικής υγρασίας, καθώς αυξάνεται η τιμή της απόδοσης των αντίστοιχων νευρωνικών δικτύων κατά το στάδιο της εκπαίδευσης και παραμένει η υψηλότερη σε σχέση με αυτή για τις άλλες μεταβλητές στο στάδιο της επαλήθευσης. Καθώς η απόδοση αυτή είναι πολύ χαμηλή κατά την επαλήθευση για τις μεταβλητές ενδιαφέροντος, εξατμοδιαπνοή και απορροή, όπου αποκτά τιμές μικρότερες από το 0,4 καθιστά τη συγκεκριμένη προσέγγιση αναποτελεσματική. Προκειμένου να αποκλιστεί η περίπτωση δυσχέρειας των νευρωνικών δικτύων να προσαρμοστούν ταυτόχρονα στις τρεις εξόδους, έγιναν οι εκπαιδεύσεις των νευρωνικών δικτύων με μόνη έξοδο την απορροή, των οποίων οι αποδόσεις φαίνονται στο Διάγραμμα 5-8.

Η προσέγγιση αυτή δεν δείχνει να αποφέρει κάποια βελτίωση, καθώς παρόλο που κατά την εκπαίδευση παρουσιάζονται ικανοποιητικές τιμές στις αποδόσεις μερικών νευρωνικών δικτύων, από 0,86 έως 0,99, κατά την επαλήθευση όλες οι τιμές του δείκτη απόδοσης είναι αρνητικές και η μεγαλύτερη τιμή που συναντάται είναι ίση με -0,33. Επιπλέον, από ένα σημείο κι έπειτα, με την αύξηση του βήματος υστέρησης της βροχόπτωσης παρουσιάζονται αρνητικές τιμές της απόδοσης και κατά το στάδιο της εκπαίδευσης.

**Πίνακας 5-4: Καλύτερη παρατηρημένη αποδοτικότητα για τις προσομοιωμένες μεταβλητές των νευρωνικών δικτύων τριπλής εξόδου**

Ομάδα Δ1	Εκπαίδευση			Αξιολόγηση		
	Q	ET	S	Q	ET	S
myNeuralNetworkHydro_10	0,49	0,59	0,80	0,37	0,30	0,47
myNeuralNetworkHydro_37	0,33	0,64	0,93	0,28	0,42	0,58
myNeuralNetworkHydro_38	0,25	0,57	0,93	0,16	0,32	0,60
myNeuralNetworkHydro_46	0,26	0,54	0,94	0,20	0,31	0,55

**Πίνακας 5-5: Καλύτερη παρατηρημένη αποδοτικότητα για τα νευρωνικά δίκτυα της απορροής**

Ομάδα Δ2	Q	
	Εκπαίδευση	Αξιολόγηση
myNeuralNetworkHydro_1	0,86	-0,31
myNeuralNetworkHydro_45	1,00	-22,49

### 5.3.2 Νευρωνικά δίκτυα μοντέλου λειτουργίας υβριδικού συστήματος

#### ι. Ομάδα Α

Τα νευρωνικά δίκτυα της συγκεκριμένης ομάδας προσομοιώνουν τις ροές νερού που αφορούν τη συνολική απόληψη από τον ταμιευτήρα και τη ροή από τη δεξαμενή προς τον ταμιευτήρα που γίνεται με σκοπό την εξισορρόπηση της ενέργειας. Για τη συνολική απόληψη από τον ταμιευτήρα το νευρωνικό δίκτυο που εκπαιδεύτηκε αποτελείται από ένα κρυμμένο επίπεδο μεγέθους 90 νευρώνων. Ο αριθμός των νευρώνων επιλέχθηκε με μόνο κριτήριο το γεγονός ότι ήταν επιθυμητή μια μεγάλη τιμή δεδομένου ότι η συγκεκριμένη προσομοίωση είναι πιο πολύπλοκη σε σχέση με την υδρολογική. Το ίδιο συνέβη και για τα νευρωνικά δίκτυα που προσομοιώνουν τις τιμές των ροών νερού για την εξισορρόπηση της ενέργειας. Το πρώτο από αυτά είχε ένα κρυμμένο επίπεδο με 80 νευρώνες και το δεύτερο δύο κρυμμένα επίπεδα με 30 νευρώνες το καθένα. Αναφορικά με τις ροές από τον ταμιευτήρα προς τη δεξαμενή για την εξισορρόπηση των ελλειμμάτων της υδρευτικής ζήτησης δεν ήταν δυνατή η δημιουργία νευρωνικών δικτύων, καθώς κατά την επταετία από την οποία χρησιμοποιήθηκαν τα δεδομένα εκπαίδευσης

όλες οι τιμές της συγκεκριμένης μεταβλητής ήταν μηδενικές, λόγω της επάρκειας των αποθεμάτων του ταμιευτήρα.

Όσον αφορά τις απολήψεις του ταμιευτήρα, κατά τη διαδικασία της εκπαίδευσης, ο δείκτης αποδοτικότητας παρουσιάζει τιμή ίση με -2,3 και κατά την επαλήθευση ίση με -192. Καθώς από το νευρωνικό δίκτυο προκύπτουν και αρνητικές τιμές, αλλά και τιμές μεγαλύτερες από την παροχετευτικότητα του αγωγού προσαγωγής, γεγονός το οποίο δεν έχει λογική συνέχεια, έγινε απαλοιφή των τιμών εκτός του παραπάνω εύρους. Ως αποτέλεσμα ο δείκτης αποδοτικότητας κατά τη διαδικασία εκπαίδευσης έφτασε το 0,9, αλλά κατά την επαλήθευση παρέμεινε αρνητικός και ίσος με το -0,25. Αντίστοιχα χαμηλοί βαθμοί απόδοσης παρουσιάζουν και τα νευρωνικά δίκτυα που προσομοιώνουν τη ροή από την δεξαμενή προς τον ταμιευτήρα. Οι χαμηλές τιμές των δεικτών απόδοσης καταδεικνύουν είτε την εγγενή δυσκολία προσομοίωσης των συγκεκριμένων ροών μέσω νευρωνικών δικτύων, είτε τη λάθος προσέγγιση λόγω του μεγάλου αριθμού των κρυμμένων νευρώνων. Λόγω των μη ενθαρρυντικών αποτελεσμάτων των προσεγγίσεων αυτών, η προσομοίωση των παραπάνω ροών παραμερίστηκε και η αναζήτηση επικεντρώθηκε στην προσομοίωση του ενεργειακού ισοζυγίου. Επομένως, το ζήτημα της προσομοίωσης των ροών νερού του υβριδικού συστήματος μέσω νευρωνικών δικτύων παραμένει ανοιχτό. Στον Πίνακα 5-6 καταγράφονται οι τιμές του δείκτη αποδοτικότητας για τα τρία προαναφερθέντα νευρωνικά δίκτυα, ενώ τα διαγράμματα που απεικονίζουν τις αντίστοιχες χρονοσειρές είναι διαθέσιμα στο Παράρτημα.

Πίνακας 5-6: Αποτελέσματα υποκατάστατης προσομοίωσης μέσω ANN ορισμένων ροών νερού


Νευρωνικό δίκτυο	Προσομοιωμένη ροή νερού	Εκπαίδευση	Αξιολόγηση
myNeuralNetworkRes_90	Εκροή ταμιευτήρα	-2,31/0,91*	-192,15/-0,26*
myNeuralNetworkRes_80	Εκροή δεξαμενής	0,29	-2,49
myNeuralNetworkRes_3030	Εκροή δεξαμενής	0,46	-12,47

\*Η τιμή αυτή προκύπτει έπειτα από την απαλοιφή των τιμών εκτός του εύρους μεταξύ της μέγιστης και ελάχιστης παροχετευτικότητας.


## ii. Ομάδα Β

Στα Διαγράμματα 5-9 έως 5-13 απεικονίζεται η απόδοση των νευρωνικών δικτύων που προσομοιώνουν το ισοζύγιο ενέργειας, όπως αυτό διαμορφώνεται έπειτα από την αναρρύθμισή του από τη διάταξη της αντλησιοταμίευσης, τόσο κατά το στάδιο της εκπαίδευσης όσο και κατά το στάδιο της επαλήθευσης. Συγκεκριμένα, το Διάγραμμα 5-9 αναφέρεται στην απόδοση των νευρωνικών δικτύων που δημιουργήθηκαν έτσι ώστε να προσομοιώνουν συνολικά το ισοζύγιο ενέργειας (ομάδα Β.i), ενώ τα Διαγράμματα 5-10 έως 5-13 αναφέρονται στην απόδοση των νευρωνικών δικτύων που δημιουργήθηκαν ώστε να προσομοιώνουν χωριστά τα ελλείμματα από τα πλεονάσματα (ομάδα Β.ii). Στα τελευταία διαγράμματα δεν απεικονίζονται οι αρνητικές τιμές, προκειμένου να είναι περισσότερο κατανοητή η πληροφορία για τις θετικές τιμές.


Η απόδοση των νευρωνικών δικτύων της ομάδας B.i είναι αρκετά υψηλή και δίνει ικανοποιητικές τιμές στο στάδιο εκπαίδευσης, οι οποίες κυμαίνονται γύρω στο 0,70 για τα περισσότερα νευρωνικά δίκτυα που εξετάστηκαν ανεξάρτητα από την αύξηση του μεγέθους του κρυμμένου επιπέδου. Αντιθέτως, κατά το στάδιο της επαλήθευσης δεν συμβαίνει το ίδιο. Η απόδοση των νευρωνικών δικτύων είναι πολύ μικρότερη από τα αποδεκτά όρια, με την μεγαλύτερη τιμή να φτάνει μόλις στο 0,39, ενώ εμφανίζεται και μεγάλο πλήθος αρνητικών τιμών.




Διάγραμμα 5-9: Απόδοση των νευρωνικών δικτύων για την προσομοίωση του ισοζυγίου ενέργειας με αύξηση των κρυμμένων νευρώνων




Διάγραμμα 5-10: Απόδοση νευρωνικών δικτύων για την προσομοίωση του ελλείμματος ενέργειας με σταθερό μέγεθος κρυμμένου επιπέδου, 1<sup>ο</sup> σετ δικτύων.



Διάγραμμα 5-11: Απόδοση νευρωνικών δικτύων για την προσομοίωση του ελλείμματος ενέργειας με σταθερό μέγεθος κρυμμένου επιπέδου, 2<sup>ο</sup> σετ δικτύων.



Διάγραμμα 5-12: Απόδοση νευρωνικών δικτύων για την προσομοίωση της περίσσειας ενέργειας με σταθερό μέγεθος κρυμμένου επιπέδου, 1<sup>ο</sup> σετ δικτύων.



Διάγραμμα 5-13: Απόδοση νευρωνικών δικτύων για την προσομοίωση της περίσσειας ενέργειας με σταθερό μέγεθος κρυμμένου επιπέδου, 2<sup>ο</sup> σετ δικτύων.



Από τις εκπαιδεύσεις των νευρωνικών δικτύων της ομάδας B.ii δημιουργήθηκαν συνολικά 150 νευρωνικά δίκτυα για την προσομοίωση των ελλειμμάτων (Διαγράμματα 5-10 και 5-11) και 143 νευρωνικά δίκτυα για την προσομοίωση των πλεονασμάτων ενέργειας (Διαγράμματα 5-12 και 5-13). Τα συγκεκριμένα νευρωνικά δίκτυα διαθέτουν σταθερό αριθμό νευρώνων στο κρυμμένο επίπεδο ίσο με 10. Όπως και τα νευρωνικά της προηγούμενης υποομάδας, παρουσιάζουν σχετικά σταθερή τιμή για το δείκτη NSE κατά τη διαδικασία της εκπαίδευσης, αλλά τα αποτελέσματα κατά την επαλήθευση δεν είναι ικανοποιητικά. Ο δείκτης αυτός προκύπτει για όλα τα δίκτυα που προσομοιώνουν τα ελλείμματα περίπου ίσος με 0,77, ενώ κατά την επαλήθευση παρουσιάζει τιμές οι οποίες είναι όλες μικρότερες από το 0,50, ακόμα και αρνητικές. Αναφορικά με τα νευρωνικά δίκτυα που προσομοιώνουν τα πλεονάσματα ο δείκτης απόδοσης δεν παρουσιάζει αποδεκτές τιμές ήδη από το στάδιο της εκπαίδευσης, όπου για το πρώτο σετ οι τιμές του είναι μικρότερες από το 0,50 και για το δεύτερο μικρότερες από το 0,35. Οι αρνητικές τιμές έχουν αφαιρεθεί από τα παραπάνω Διαγράμματα (5-10 και 5-13), ώστε να φαίνονται καλύτερα οι τιμές του δείκτη στο εκπαιδευτικό στάδιο. Τα καλύτερα αποτελέσματα του δείκτη απόδοσης κατά το στάδιο εκπαίδευσης και το στάδιο επαλήθευσης καταγράφονται στους ακόλουθους ανάλογα με το σετ στο οποίο ανήκουν στους Πίνακες 5-7 έως 5-9.

Πίνακας 5-7: Καλύτερη παρατηρημένη αποδοτικότητα για το ισοζύγιο ενέργειας

Ομάδα B.i	Denergy_final	
	Εκπαίδευση	Αξιολόγηση
myNeuralNetworkRes_11	0,71	0,39
myNeuralNetworkRes_49	0,72	-0,45

Πίνακας 5-8 Καλύτερη παρατηρημένη αποδοτικότητα για το έλλειμμα ενέργειας


Ομάδα B.ii – Έλλειμμα	Εκπαίδευση	Αξιολόγηση	
myNNDEF_25	0,77	0,45	1 <sup>ο</sup> σετ
myNNDEF_48	0,77	0,37	
myNNDEF_2	0,77	0,45	2 <sup>ο</sup> σετ
myNNDEF_35	0,77	0,37	

Πίνακας 5-9: Καλύτερη παρατηρημένη αποδοτικότητα για την περίσσεια ενέργειας

Ομάδα B.ii – Περίσσεια	Εκπαίδευση	Αξιολόγηση	
myNNSUR_94	0,33	0,14	1 <sup>ο</sup> σετ
myNNSUR_129	0,32	0,43	
myNNSUR_6	0,32	0,07	2 <sup>ο</sup> σετ
myNNSUR_8	0,32	0,32	

### iii. Ομάδα Γ

Στο Διάγραμμα 5-14 παρουσιάζεται ο δείκτης απόδοσης των νευρωνικών δικτύων που προσομοιώνουν συνολικά το ενεργειακό ισοζύγιο. Αυτό που διαφοροποιεί τα συγκεκριμένα νευρωνικά δίκτυα από αυτά της ομάδας Β.ι είναι ότι λαμβάνουν ως επιπλέον εισόδους τα ωφέλιμα αποθέματα του ταμιευτήρα και της δεξαμενής και οι εκπαιδεύσεις που έγιναν αφορούν σε δίκτυα που διαθέτουν τον ίδιο αριθμό κρυμμένων νευρώνων.




Διάγραμμα 5-14: Απόδοση νευρωνικών δικτύων με επιπλέον εισόδο τα αποθέματα του ταμιευτήρα και της δεξαμενής


Αυτό που παρατηρείται είναι ότι οι τιμές της απόδοσης είναι γενικά πολύ μεγαλύτερες από αυτές που προέκυψαν για τα νευρωνικά δίκτυα των προηγούμενων ομάδων. Είναι σημαντικό να αναφερθεί ότι και σε αυτή την περίπτωση εμφανίζονται αρνητικές τιμές τόσο κατά την εκπαίδευση όσο και κατά την επαλήθευση των νευρωνικών δικτύων, αλλά για τα περισσότερα νευρωνικά δίκτυα ο δείκτης αυτός έχει τιμή μεγαλύτερη από το 0,90. Στην 47<sup>η</sup> επανάληψη μάλιστα, τα αποτελέσματα της οποίας καταγράφονται στον Πίνακα 5-10, παρατηρείται ο μέγιστος βαθμός απόδοσης τόσο κατά την εκπαίδευση όσο και κατά την αξιολόγηση, γεγονός που σημαίνει ότι το συγκεκριμένο νευρωνικό δίκτυο μπορεί να δώσει ικανοποιητικά αποτελέσματα για την προσομοίωση του στα Διαγράμματα 5-15 και 5-16 που ακολουθούν.

Πίνακας 5-10: Καλύτερη απόδοση νευρωνικών δικτύων ομάδας Γ.ι

Ομάδα Γ.ι	Denergy_final	
	Εκπαίδευση	Αξιολόγηση
myNNDenergy_final_47	0,96	0,91



Διάγραμμα 5-15: Τελικό ισοζύγιο ενέργειας από ANN της ομάδας Γ.ι κατά την εκπαίδευση




Διάγραμμα 5-16: Τελικό ισοζύγιο ενέργειας από ANN της ομάδας Γ.ι κατά την επαλήθευση


Τα νευρωνικά δίκτυα της ομάδα Γ.ii προκειμένου να λειτουργήσουν χρειάζεται να έχουν και κάποια πρόγνωση για τις τιμές των μεταβλητών που εκτιμώνται προκειμένου να δώσουν αξιόπιστα αποτελέσματα. Επιπλέον, τα νευρωνικά δίκτυα εκπαιδεύονται αρχικά με ανοιχτό το βρόγχο της ανατροφοδότησης και στη συνέχεια υπάρχει η δυνατότητα κλεισίματός του, καθώς και η δυνατότητα μετατόπισης της χρονοσειράς ένα βήμα πιο πριν προκειμένου να είναι δυνατή η πρόγνωση της τιμής νωρίτερα. Με την αξιοποίηση των παραπάνω δυνατοτήτων, από τα νευρωνικά δίκτυα που εκπαιδεύτηκαν το καλύτερο αποτέλεσμα το έδωσε αυτό όπου γίνεται η μετατόπιση της χρονοσειράς ένα βήμα νωρίτερα. Κατά την εκπαίδευση του συγκεκριμένου νευρωνικού δικτύου, η τιμή του δείκτη NSE είναι ίση με 0,92, ενώ για την επαλήθευση ίση με 0,84. Τα αποτελέσματα για τις υπόλοιπες μορφές καταγράφονται στον Πίνακα 5-11, ενώ οι χρονοσειρές του ενεργειακού ισοζυγίου φαίνονται στα Διαγράμματα 5-17 και 5-18.

Πίνακας 5-11: Αποτελέσματα νευρωνικών δικτύων Ομάδας Γ.ii

Ομάδα Γ.ii	Denergy_final	
	Εκπαίδευση	Αξιολόγηση
myNeuralNetworkDenergyfinal_x	-	-
Ανοιχτός βρόγχος	0,64	0,60
Κλειστός βρόγχος	0,46	0,27
Ανοιχτός βρόγχος με μετατόπιση	0,92	0,84



Διάγραμμα 5-17: Τελικό ισοζύγιο ενέργειας από ANN της ομάδας Γ.ii κατά την εκπαίδευση



Διάγραμμα 5-18: Τελικό ισοζύγιο ενέργειας από ANN της ομάδας Γ.ii κατά την επαλήθευση

### 5.3.3 Επιλογή τελικού σχήματος και υπολογιστικό κέρδος

Από την ανάλυση των προηγούμενων αποτελεσμάτων μπορεί να γίνει μια τελική επιλογή ενός νευρωνικού δικτύου με ικανοποιητική απόδοση με σκοπό την εξοικονόμηση υπολογιστικού χρόνου. Τα νευρωνικά δίκτυα που έδειξαν να προσομοιώνουν καλύτερα το ενεργειακό ισοζύγιο είναι αυτά της ομάδας Γ. Μεταξύ των υποομάδων Γ.i και Γ.ii, αυτά που απαιτούν λιγότερο υπολογιστικό χρόνο είναι της ομάδας Γ.i, καθώς δεν απαιτούν ειδική διαμόρφωση των μητρώων των δεδομένων όπως αυτά της ομάδας Γ.ii. Επομένως, η διαδικασία της χρονομέτρησης και ο υπολογισμός της εξοικονόμησης του υπολογιστικού χρόνου γίνεται με την εφαρμογή του νευρωνικού δικτύου που προέκυψε ως το καλύτερο από την ομάδα Γ.i. με τη χρήση των συνθετικών χρονοσειρών.

Όπως φαίνεται και από την Εικόνα 5-1, το αναλυτικό μοντέλο προσομοίωσης του υβριδικού συστήματος χρειάστηκε 14,4 s ενώ το αντίστοιχο νευρωνικό δίκτυο χρειάστηκε 0,3 s. Επομένως, η επί τοις εκατό εξοικονόμηση χρόνου διαμορφώνεται στην τιμή του:

$$\text{Εξοικονόμηση (\%)} = \frac{14,4 - 0,3}{14,4} * 100 = 97,9 \%$$

Παρόλα αυτά, είναι σίγουρο ότι δεν είναι δυνατόν να γίνεται λόγος για πλήρη υποκατάστατη μέσω νευρωνικών δικτύων, καθώς για τα συγκεκριμένα νευρωνικά δίκτυα είναι απαραίτητο να γίνει χρήση ορισμένων από τις εξόδους του αναλυτικού μοντέλου. Σε περίπτωση που βρεθεί ένας αποδοτικός τρόπος προσέγγισης των αποθεμάτων, τότε αυτή η προσέγγιση είναι σε θέση να συντελέσει σε σημαντική μείωση του υπολογιστικού φόρτου.

#### Profile Summary

Generated 03-Jul-2018 07:58:17 using performance time.

Function Name	Calls	Total Time	Self Time*	Total Time Plot (dark band = self time)
<a href="#">finalmodel</a>	1	16.321 s	0.762 s	
<a href="#">RESMAN</a>	1	14.396 s	14.396 s	
<a href="#">myNNDenergy_final_47</a>	1	0.764 s	0.290 s	
<a href="#">myNNDenergy_final_47&gt;tansig_apply</a>	1	0.358 s	0.358 s	
<a href="#">RFRO</a>	1	0.265 s	0.265 s	
<a href="#">myNNDenergy_final_47&gt;mapminmax_apply</a>	1	0.105 s	0.105 s	
<a href="#">IRDm</a>	1	0.064 s	0.064 s	
<a href="#">D2H</a>	5	0.050 s	0.050 s	
<a href="#">PET_1</a>	1	0.017 s	0.017 s	
<a href="#">myNNDenergy_final_47&gt;mapminmax_reverse</a>	1	0.011 s	0.011 s	
<a href="#">PREP1</a>	1	0.002 s	0.002 s	

Εικόνα 5-1: Αποτελέσματα χρονομέτρησης αναλυτικού και υποκατάστατου μοντέλου

## 6. Συμπεράσματα και προτάσεις για μελλοντική έρευνα

Στο κεφάλαιο αυτό συνοψίζονται τα συμπεράσματα που προκύπτουν από τη συγκεκριμένη μεταπτυχιακή εργασία και γίνονται προτάσεις για μελλοντική έρευνα, για βελτιώσεις της παρούσας προσέγγισης.

Αρχικά, είναι σημαντικό να αναφερθεί ότι η βασική αρχή της δημιουργίας του υποκατάστατου σχήματος μοντελοποίησης βάσει των νευρωνικών δικτύων είναι η χρήση των ίδιων μεταβλητών εισόδου με αυτές της αναλυτικής προσομοίωσης. Για το λόγο αυτό, για τη δημιουργία των νευρωνικών δικτύων του υδρολογικού μοντέλου ως μία από τις εισόδους χρησιμοποιήθηκε η εξωγήινη ακτινοβολία. Το γεγονός αυτό πιθανώς να συνετέλεσε σημαντικά στο μειωμένο βαθμό απόδοσης για την προσομοίωση της απορροής από τα νευρωνικά δίκτυα μονής εξόδου (ομάδα Γ των νευρωνικών δικτύων για το υδρολογικό μοντέλο), καθώς η εξωγήινη ακτινοβολία αποτελεί περιοδική συνάρτηση, με αποτέλεσμα να δίνεται στο δίκτυο μια μεταβλητή με επαναλαμβανόμενες τιμές. Παρόμοια μειωμένες αποδόσεις για την απορροή εμφανίζουν και τα νευρωνικά δίκτυα που λαμβάνουν υπόψη ως είσοδο και κάποια υστέρηση στις τιμές της βροχόπτωσης, ενώ δεν συμβαίνει το ίδιο για την εξατμοδιαπνοή και την εδαφική υγρασία (ομάδες Δ.i και Δ.ii).

Ωστόσο, η μειωμένη απόδοση για την απορροή δεν μπορεί να αποδοθεί αποκλειστικά στην επανάληψη της πληροφορίας που χρησιμοποιείται στην εκπαίδευση των νευρωνικών δικτύων, καθώς είναι άγνωστος ο τρόπος ως προς τον οποίο την έχει αντιμετωπίσει – προσεγγίσει το δίκτυο. Αντιθέτως, τα νευρωνικά δίκτυα που χρησιμοποιούν τις ίδιες εισόδους με το αντίστοιχο αναλυτικό υδρολογικό μοντέλο και προσεγγίζουν ταυτόχρονα την απορροή, την εξατμοδιαπνοή και την εδαφική υγρασία (ομάδα Β) φαίνεται να αποδίδουν καλύτερα τις τιμές της απορροής. Οι τιμές της απόδοσης των νευρωνικών δικτύων για την εξατμοδιαπνοή και την απορροή, παρότι φτάνουν στα επιτρεπτά όρια ( $>0,50$ ), δεν είναι αρκετά ικανοποιητικές ώστε αυτά να χρησιμοποιηθούν στο υποκατάστατο του μοντέλου προσομοίωσης του υβριδικού συστήματος, καθώς και το τελευταίο παρουσιάζει μια συγκεκριμένη επίδοση και έτσι θα μειωνόταν η ακρίβεια των εκτιμήσεών του. Ωστόσο, τα συγκεκριμένα νευρωνικά δίκτυα θα ήταν χρήσιμα ως απλά υποκατάστατα για την απλή προσομοίωση των συγκεκριμένων υδρολογικών μεταβλητών. Άλλωστε, νευρωνικά δίκτυα για την μοντελοποίηση βροχής-απορροής έχουν χρησιμοποιηθεί και σε προηγούμενες εφαρμογές της βιβλιογραφίας, αλλά έχουν εκπαιδευτεί με καταγεγραμμένες μετρήσεις των απορροών και όχι μέσω μοντελοποιημένων.

Όσον αφορά την προσομοίωση του υβριδικού συστήματος, είναι σαφές ότι πρόκειται για ένα περισσότερο απαιτητικό μοντέλο. Η λειτουργία αναρρύθμισης του υδατικού και ενεργειακού ισοζυγίου αποτελεί επιπλέον κριτήριο βάσει του οποίου λαμβάνουν χώρα οι ροές νερού και ενέργειας, με αποτέλεσμα να μην είναι

δυνατή η ικανοποιητική υποκατάστατη μοντελοποίησή τους με νευρωνικά δίκτυα, τα οποία χρησιμοποιούν ως εισόδους τις ίδιες μεταβλητές με το αναλυτικό μοντέλο. Καθώς τα αποθέματα της δεξαμενής και του ταμιευτήρα αναδιαμορφώνονται κατά τη διάρκεια ενός βήματος της προσομοίωσης, είναι σημαντικό να ληφθεί υπόψη και αυτή η πληροφορία για τη διαμόρφωση των νευρωνικών δικτύων. Η χρήση των χρονοσειρών των αποθεμάτων βοήθησε σημαντικά στην αύξηση της επίδοσης των νευρωνικών δικτύων για την προσομοίωση του ενεργειακού ισοζυγίου και μάλιστα συνολικά. Ακόμα και κατά τις δοκιμές όπου τα νευρωνικά δίκτυα εκτιμούσαν χωριστά τα πλεονάσματα από τα ελλείμματα ενέργειας, δεν στάθηκε δυνατή μια τόσο καλή εκτίμηση όσο σε σχέση με αυτήν που προήλθε από τα νευρωνικά δίκτυα που χρησιμοποίησαν και την πληροφορία για τα αποθέματα. Επομένως, γίνεται κατανοητό ότι στη συγκεκριμένη περίπτωση είναι απαραίτητη και η χρήση περισσότερων δεδομένων, εκτός των εισόδων του αναλυτικού μοντέλου, που είναι αντιπροσωπευτικά της τρέχουσας κατάστασης (πέραν των εισροών και των ζητήσεων) του συστήματος.

Επιπλέον, για την υποκατάστατη προσέγγιση που τελικά χρονομετρήθηκε μπορεί να μην φαντάζει υπερβολικός ο χρόνος των 14 περίπου δευτερολέπτων του αρχικού μοντέλου. Ωστόσο, η τιμή αυτή θα μπορούσε να είναι πολύ μεγαλύτερη στην περίπτωση που η εφαρμογή γινόταν σε ένα πιο εκτενές σύστημα, που περιλαμβάνει μεγάλο αριθμό υδραυλικών και ενεργειακών έργων, ή χρησιμοποιούνταν μεγαλύτερου μήκους χρονοσειρές, με σκοπό την ακριβέστερη προσέγγιση της απόδοσης του συστήματος. Ακόμη περισσότερο, ο χρόνος αυτός θα ήταν εξαιρετικά κρίσιμος παράγοντας αν υπήρχε ανάγκη πολλαπλών δοκιμών του μοντέλου προσομοίωσης (π.χ. σε προβλήματα βελτιστοποίησης, ανάλυσης ευαισθησίας, εκτίμησης αβεβαιότητας κτλ.). Συνεπώς, αξιολογώντας με βάση την εξοικονόμηση του χρόνου, είναι σαφές ότι η χρήση των νευρωνικών δικτύων συμβάλλει σημαντικά στη μείωση του υπολογιστικού φόρτου.

Στην προσέγγιση των εκροών του ταμιευτήρα και της δεξαμενής του υβριδικού συστήματος δεν δόθηκε μεγάλη έκταση, λόγω κυρίως του μεγάλου υπολογιστικού χρόνου που απαιτήθηκε κατά την πρώτη δοκιμή. Πιθανώς η επιλογή νευρωνικών δικτύων με τόσο μεγάλη δομή (π.χ. 90 κρυμμένοι νευρώνες) να ήταν υπερβολική, με αποτέλεσμα να απαιτείται μεγάλος χρόνος για την διαδικασία εκπαίδευσης. Η προσομοίωση των συγκεκριμένων ροών μέσω νευρωνικών δικτύων απαιτεί περαιτέρω διερεύνηση. Είναι πιθανό είτε να διευκολυνθεί με τη χρήση κάποιου νευρωνικού δικτύου μικρότερου μεγέθους είτε να απαιτεί κάποιο με ακόμα περισσότερους νευρώνες ώστε να έχει ικανοποιητική απόδοση. Το ζήτημα αυτό παραμένει ανοιχτό.

Τα νευρωνικά δίκτυα που εκπαιδεύτηκαν κατά την εκπόνηση της παρούσας εργασίας παρουσιάζουν πολλές διαφορές μεταξύ τους αναφορικά με τα δεδομένα

εισόδου-εξόδου και τις εξεταζόμενες δομές. Κάθε εκπαίδευση δίνει ως αποτέλεσμα έναν κατάλληλο συνδυασμό για τις παραμέτρους του δικτύου, ο οποίος αφορά την εκάστοτε διαδικασία βελτιστοποίησης που έχει ως σημείο εκκίνησης διαφορετικές τυχαίες τιμές κάθε φορά που αυτή λαμβάνει χώρα. Συνεπώς, η επανάληψη της εκπαίδευσης διατηρώντας σταθερές όλες τις επιλογές, μπορεί να δώσει ένα πολύ διαφορετικό συνδυασμό τιμών για τις παραμέτρους του δικτύου. Για τη διασφάλιση της επιλογής που δίνει το καλύτερο αποτέλεσμα είναι καλό η εκπαίδευση ενός νευρωνικού δικτύου να επαναλαμβάνεται πολλές φορές και η τελική επιλογή να γίνεται βάσει ορισμένων κριτηρίων απόδοσης.

Τέλος, δεδομένου ότι η εξοικονόμηση του υπολογιστικού χρόνου στη συγκεκριμένη περίπτωση δίνει ελπιδοφόρα αποτελέσματα, τίθεται ο ερευνητικός στόχος για τη χρήση των νευρωνικών δικτύων ως υποκατάστατων μοντέλων για σκοπούς βελτιστοποίησης των υβριδικών συστημάτων.



## Βιβλιογραφικές Αναφορές

- Allaire, D. L. (2009), Uncertainty assessment of complex models with application to aviation environmental systems, MIT.
- Bau, D. A., and A. S. Mayer (2006), Stochastic management of pump-and-treat strategies using surrogate functions, *Advances in Water Resources*, 29(12), 1901-1917.
- Behzadian, K., Z. Kapelan, D. Savic, and A. Ardeshir (2009), Stochastic sampling design using a multiobjective genetic algorithm and adaptive neural networks, *Environmental Modelling & Software*, 24(4), 14 530-541.
- Bieker, H. P., O. Slupphaug, and T. A. Johansen (2007), Real-time production optimization of oil and gas production systems: A technology survey, *SPE Production & Operations*, 22(4), 382-391.
- Blanning, R. W. (1975), Construction and implementation of metamodels, *Simulation*, 24(6), 177-184.
- Bliznyuk, N., D. Ruppert, C. Shoemaker, R. Regis, S. Wild, and P. Mugunthan (2008), Bayesian calibration and uncertainty analysis for computationally expensive models using optimization and radial basis function approximation, *Journal of Computational and Graphical Statistics*, 17(2), 270-294.
- Borgonovo, E., W. Castaings, and S. Tarantola (2012), Model emulation and moment-independent sensitivity analysis: An application to environmental modelling, *Environmental Modelling & Software*, 34, 105-115.
- Broad, D. R., G. C. Dandy, and H. R. Maier (2005), Water distribution system optimization using metamodels, *Journal of Water Resources Planning and Management-Asce*, 131(3), 172-180.
- Broad, D. R., H. R. Maier, and G. C. Dandy (2010), Optimal Operation of Complex Water Distribution Systems Using Metamodels, *Journal of Water Resources Planning and Management*, 136(4), 433-443.
- Castelletti, A., F. Pianosi, R. Soncini-Sessa, and J. P. Antenucci (2010), A multiobjective response surface approach for improved water quality planning in lakes and reservoirs, *Water Resources Research*, 46.
- Castro-Gama, M.E., Popescu, I., Li, S., Mynett, A. and van Damb, A. (2014), Flood inference simulation using surrogate modelling for the Yellow River multiple reservoir system, *Environmental Modelling & Software*, 55,250-265.

- Chalakatevaki, M., Stamou P., Karali, S., Daniil, V., Dimitriadis, P., Tzouka, K., Iliopoulou, T. Koutsoyiannis, D., Papanicolaou, P. and Mamassis N. (2017), Creating the electric energy mix in a non-connected island, *Energy Procedia*, 124, 425–424. European Geosciences Union General Assembly 2017, Division Energy Resources & Environment.
- Chen, L., Roy, S. B. and Hutton, P. H. (2018), Emulation of a Process-Based Estuarine Hydrodynamic Model, *Hydrological Sciences Journal*, 63(5), 783-802 doi.org/10.1080/02626667.2018.1447112.
- de Villiers, J., and E. Barnard (1993), Backpropagation neural nets with one and two hidden layers, *IEEE Transactions on Neural Networks*, 4(1), 136-141.
- de Vos, N. J. (2003), Rainfall – Runoff modeling using artificial neural networks, M. Sc. Thesis Report, Civil Engineering Informatics Group and Section of Hydrology & Ecology, Subfaculty of Civil Engineering, Delft University of Technology.
- di Pierro, F., S. T. Khu, D. Savic, and L. Berardi (2009), Efficient multi-objective optimal design of water distribution networks on a budget of simulations using hybrid algorithms, *Environmental Modelling & Software*, 24(2), 202-213.
- Dimitriadis P., and Koutsoyiannis D. (2015) Application of stochastic methods to double cyclostationary processes for hourly wind speed simulation, *Energy Procedia*, 76, 406–411, doi:10.1016/j.egypro.2015.07.851.
- Dimitriadis P., and Koutsoyiannis D. (2015) Climacogram versus autocovariance and power spectrum in stochastic modelling for Markovian and Hurst–Kolmogorov processes, *Stochastic Environmental Research & Risk Assessment*, 29 (6), 1649–1669, doi:10.1007/s00477-015-1023-7.
- Efstratiadis, A., I. Tsoukalas, P. Kossieris, G. Karavokiros, A. Christofides, A. Siskos, N. Mamassis, and D. Koutsoyiannis, Computational issues in complex water-energy optimization problems: Time scales, parameterizations, objectives and algorithms, *European Geosciences Union General Assembly 2015, Geophysical Research Abstracts*, Vol. 17, Vienna, EGU2015-5121, European Geosciences Union, 2015.
- Forrester, A. I. J., A. Sobester, and A. J. Keane (2007), Multi-fidelity optimization via surrogate modelling, *Proceedings of the Royal Society a-Mathematical Physical and Engineering Sciences*, 463(2088), 3251-3269
- Forrester, A. I. J., A. Sobester, and A. J. Keane (2007), Multi-fidelity optimization via surrogate modelling, *Proceedings of the Royal Society a-Mathematical Physical and Engineering Sciences*, 463(2088), 3251-3269.

- Gano, S. E., J. E. Renaud, J. D. Martin, and T. W. Simpson (2006), Update strategies for kriging models used in variable fidelity optimization, *Structural and Multidisciplinary Optimization*, 32(4), 287-298.
- Gutmann, H. M. (2001), A radial basis function method for global optimization, *Journal of Global Optimization*, 19(3), 201-227.
- Hamm, L., B. W. Brorsen, and M. T. Hagan (2007), Comparison of stochastic global optimization methods to estimate neural network weights, *Neural Processing Letters*, 26, 145-158.
- Hecht-Nielsen, R. (1990) *Neurocomputing* Addison-Wesley
- Hemker, T., K. R. Fowler, M. W. Farthing, and O. von Stryk (2008), A mixed-integer simulation-based optimization approach with surrogate functions in water resources management, *Optimization and Engineering*, 9(4), 341-360.
- Hornik, K., M. Stinchcombe, and H. White (1989), Multilayer feedforward networks are universal approximators, *Neural Networks*, 2(5), 359-366.
- Huang, D., T. T. Allen, W. I. Notz, and R. A. Miller (2006), Sequential kriging optimization using multiple-fidelity evaluations, *Structural and Multidisciplinary Optimization*, 32(5), 369-382.
- Keating, E. H., J. Doherty, J. A. Vrugt, and Q. J. Kang (2010), Optimization and uncertainty assessment of strongly nonlinear groundwater models with high parameter dimensionality, *Water Resources Research*, 46.
- Kennedy, M. C., and A. O'Hagan (2000), Predicting the output from a complex computer code when fast approximations are available, *Biometrika*, 87(1), 1-13.
- Khu, S. T., and M. G. F. Werner (2003), Reduction of Monte-Carlo simulation runs for uncertainty estimation in hydrological modelling, *Hydrology and Earth System Sciences*, 7(5), 680-692.
- Kleijnen, J. P. C. (2009), Kriging metamodeling in simulation: A review, *European Journal of Operational Research*, 192(3), 707-716.
- Koudouris, G., Dimitriadis, P., Iliopoulou, T., Mamassis, N., and Koutsoyiannis D. (2017) Investigation of the stochastic nature of solar radiation process, *Energy Procedia*, 125, 398–404. European Geosciences Union General Assembly 2017, Division Energy Resources & Environment.
- Koutsoyiannis, D., Makropoulos, C., Langousis, A., Baki, S., Efstratiadis, A., Christofides, A., Karavokiros, G. and Mamassis, N. *Climate, hydrology, energy,*

- water: recognizing uncertainty and seeking sustainability, *Hydrology and Earth System Sciences*, 13, 247–257, doi:10.5194/hess-13-247-2009, 2009.
- Koutsoyiannis, D., Scale of water resources development and sustainability: Small is beautiful, large is great, *Hydrological Sciences Journal*, 56(4), 553–575, doi:10.1080/02626667.2011.579076, 2011.
- Leary, S. J., A. Bhaskar, and A. J. Keane (2003), A knowledge-based approach to response surface modelling in multifidelity optimization, *Journal of Global Optimization*, 26(3), 297-319.
- Leshno, M., V. Y. Lin, A. Pinkus, and S. Schocken (1993), Multilayer feedforward networks with a non-polynomial activation function can approximate any function, *Neural Networks*, 6(6), 861-867.
- Liong, S. Y., S. T. Khu, and W. T. Chan (2001), Derivation of Pareto front with genetic algorithm and neural network, *Journal of Hydrologic Engineering*, 6(1), 52-61.
- Madsen, J. I., and M. Langthjem (2001), Multifidelity response surface approximations for the optimum design of diffuser flows, *Optimization and Engineering*, 2, 453-468.
- Maier, H. R., and G. C. Dandy (2000), Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications, *Environmental Modelling & Software*, 15(1), 101-124.
- Mavroyeoryos, K., Engonopoulos, I., Tyrallis, H., Dimitriadis, P., Koutsoyiannis, D. (2017), Simulation of electricity demand in a remote island for optimal planning of a hybrid renewable energy system, *Energy Procedia*, 125, 435–442. European Geosciences Union General Assembly 2017, Division Energy Resources & Environment.
- McKay, M. D., R. J. Beckman, and W. J. Conover (1979), A comparison of three methods for selecting values of input variables in the analysis of output from a computer code, *Technometrics*, 21(2), 239-245.
- Montgomery, D. C. (2008), *Design and analysis of experiments*, 7th ed., Wiley.
- Moschos E., Manou G., Georganta C., Dimitriadis P., Iliopoulou T., Tyrallis H., Koutsoyiannis D., and Tsoukala V. (2017) Investigation of the stochastic nature of wave processes for renewable resources management: a pilot application in a remote island in the Aegean Sea, European Geosciences Union General Assembly 2017, *Geophysical Research Abstracts*, Vol. 19, Vienna, 19, EGU2017-10225-3, European Geosciences Union.

- Mugunthan, P., and C. A. Shoemaker (2006), Assessing the impacts of parameter uncertainty for computationally expensive groundwater models, *Water Resources Research*, 42(10).
- Mugunthan, P., C. A. Shoemaker, and R. G. Regis (2005), Comparison of function approximation, heuristic, and derivative-based methods for automatic calibration of computationally expensive groundwater bioremediation models, *Water Resources Research*, 41(11), 1-17.
- O'Hagan, A. (2006), Bayesian analysis of computer code outputs: A tutorial, *Reliability Engineering & System Safety*, 91(10-11), 1290-1300.
- Papoulakos, K., Pollakis, G., Moustakis, Y., Makropoulos, A., Iliopoulou, T., Dimitriadis, P., Koutsoyiannis, D., and Efstratiadis, A. (2017), Simulation of water – energy fluxes through small – scale reservoir systems under limited data availability, *Energy Procedia*, 125, 405–414. European Geosciences Union General Assembly 2017, Division Energy Resources & Environment
- Razavi, S., B. A. Tolson and D. H. Burn (2012a), Review of surrogate modeling in water resources, *Water Resources Research*, 48, W07401, doi:10.1029/2011WR011527.
- Razavi, S., B. A. Tolson and D. H. Burn (2012b), Numerical assessment of metamodelling strategies in computationally intensive optimization, *Environmental Modelling & Software*, 34, 67-86.
- Rehman, S., Al-Hadhrami, L. M., Alam, M. M. (2015), Pumped hydro energy storage system: A technological review, *Renewable and Sustainable Energy Reviews*, 44, 586–598.
- Rumelhart, D. E., Hinton, G. E. and McClelland, J. L. (1986), A general framework for parallel distributed processing, *Parallel Distributed Processing: explorations in the microstructure of cognition*, Vol. I, pp. 45-76, MIT Press.
- Schultz, M. T., M. J. Small, P. S. Fischbeck, and R. S. Farrow (2006), Evaluating response surface designs for uncertainty analysis and prescriptive applications of a large-scale water quality model, *Environmental Modeling & Assessment*, 11(4), 345-359.
- Schultz, M. T., M. J. Small, R. S. Farrow, and P. S. Fischbeck (2004), State water pollution control policy insights from a reduced-form model, *Journal of Water Resources Planning and Management*, 130(2), 150-159.

- Shrestha, D. L., N. Kayastha, and D. P. Solomatine (2009), A novel approach to parameter uncertainty analysis of hydrological models using neural networks, *Hydrology and Earth System Sciences*, 13(7), 1235-1248.
- Simpson, T. W., V. Toropov, B. V., and F. A. C. Viana (2008), Design and analysis of computer experiments in multidisciplinary design optimization: a review of how far we have come - or not paper presented at 12th AIAA/ISSMO multidisciplinary analysis and optimization conference, Victoria, British Columbia, Canada.
- Sun, G., G. Li, M. Stone, and Q. Li (2010), A two-stage multi-fidelity optimization procedure for honeycomb-type cellular materials, *Computational Materials Science*, 49(3), 500-511.
- Tamura, S., and M. Tateishi (1997), Capabilities of a four-layered feedforward neural network: Four layers versus three, *IEEE Transactions on Neural Networks*, 8(2), 251-255.
- Tegos, A., Malamos, N., Efstratiadis, A., Tsoukalas, I., Karanasios, A., and Koutsoyiannis, D. (2017), Parametric Modelling of Potential Evapotranspiration: A Global Survey, *Water*, 9 (10), 795, doi:10.3390/w9100795.
- Tsoukalas, I. and Makropoulos, C. (2015), Multiobjective optimisation on a budget: Exploring surrogate modelling for robust multi-reservoir rules generation under hydrological uncertainty, *Environmental Modelling & Software*, 69, 396-413.
- Tsoukalas, I., Kossieris, P., Efstratiadis, A. and Makropoulos, C. (2016), Surrogate-enhanced evolutionary annealing simplex algorithm for effective and efficient optimization of water resources problems on a budget, *Environmental Modelling & Software*, 77, 122-142.
- Viana, F. A. C., and R. T. Haftka (2008), Using multiple surrogates for metamodeling, *Proceedings of the 7th ASMOUKISSMO International Conference on Engineering Design Optimization*, Pages: 1-18, edited.
- Viana, F. A. C., V. Steffen, Jr., S. Butkewitsch, and M. d. F. Leal (2009), Optimization of aircraft structural components by using nature-inspired algorithms and multi-fidelity approximations, *Journal of Global Optimization*, 45(3), 427-449.
- Xiang, C., S. Q. Ding, and T. H. Lee (2005), Geometrical interpretation and architecture selection of MLP, *IEEE Transactions on Neural Networks*, 16(1), 84-96.
- Yan, S., and B. Minsker (2006), Optimal groundwater remediation design using an Adaptive Neural Network Genetic Algorithm, *water resources research*, 42(5).

Yan, S., and B. Minsker (2011), Applying Dynamic Surrogate Models in Noisy Genetic Algorithms to Optimize Groundwater Remediation Designs, *Journal of Water Resources Planning and Management*, 137(3), 284-292.

Ye, K. Q., W. Li, and A. Sudjianto (2000), Algorithmic construction of optimal symmetric Latin hypercube designs, *Journal of Statistical Planning and Inference*, 90(1), 145-159.

Zhang, J., Wangb, X., Liu, P., Lei, X., Li, Z., Gong, W., Duan, Q. and Wang H. (2017), Assessing the weighted multi-objective adaptive surrogate model optimization to derive large-scale reservoir operating rules with sensitivity analysis, *Journal of Hydrology*, 544, 613–627.

Zhang, X. S., R. Srinivasan, and M. Van Liew (2009), Approximating SWAT model using artificial neural network and support vector machine, *Journal of the American Water Resources Association*, 45(2), 460-474.

Zhang, X. S., R. Srinivasan, and M. Van Liew (2009), Approximating SWAT model using artificial neural network and support vector machine, *Journal of the American Water Resources Association*, 45(2), 460-474.

Zou, R., W. S. Lung, and J. Wu (2007), An adaptive neural network embedded genetic algorithm approach for inverse water quality modeling, *Water Resources Research*, 43(8).

Δήμας Π., Πλαίσιο στοχαστικής προσομοίωσης για το βέλτιστο σχεδιασμό υβριδικού συστήματος υδροηλεκτρικής – αιολικής ενέργειας. Διερεύνηση με βάση το υδροσύστημα Αλιάκμονα, Διπλωματική εργασία, Τομέας Υδατικών Πόρων και Περιβάλλοντος – Εθνικό Μετσόβιο Πολυτεχνείο, Δεκέμβριος 2013.

Κ/Ξ Υδατοσυστημάτων Αιγαίου, Νήσος Αστυπάλαια: Συλλογή, Επεξεργασία και Διαχείριση Δεδομένων, Ανάπτυξη Συστημάτων και Εργαλείων Διαχείρισης Υδατικών Πόρων Υδατικού Διαμερίσματος Νήσων Αιγαίου, Α΄ Φάση, Τεύχος 1, Υπουργείο Ανάπτυξης, Δεκέμβριος 2005.

## Παράρτημα

### Μοντέλο βροχής - απορροής

Ο αλγόριθμος που περιγράφει το μοντέλο βροχής-απορροής σε ένα βήμα προσομοίωσης είναι ο ακόλουθος:

*if*  $Rain(t) > Ia$

$$Qov(t) = \frac{(Rain(t) - Ia)^2}{Rain(t) - Ia + K - S(t-1)}$$

*else*

$$Qov(t) = 0$$

*end*

$$ETd(t) = \min(PET(t), (Rain(t) - Qov(t)))$$

$$INF(t) = Rain(t) - Qov(t) - ETd(t)$$

$$S(t) = S(t - 1) + INF(t)$$

$$ETs(t) = (PET(t) - ETd(t)) * \tanh\left(\frac{S(t)}{K}\right)$$

$$S(t) = S(t) - ETs(t)$$

$$L(t) = S(t) * a$$

$$S(t) = S(t) - L(t)$$

$$Qs(t) = \max(0, (S(t) - K))$$

$$S(t) = S(t) - Qs(t)$$

$$Q(t) = Qov(t) + Qs(t)$$

$$ET(t) = ETd(t) + ETs(t)$$

Επεξήγηση συμβόλων:



## Μοντέλο προσομοίωσης λειτουργίας του ταμιευτήρα

Ο αλγόριθμος που περιγράφει την προσομοίωση λειτουργίας του υβριδικού συστήματος σε ένα χρονικό βήμα είναι ο ακόλουθος:

*% αποθέματα στην αρχή του χρονικού βήματος*

$$S2(t) = S2(t - 1) \text{ % απόθεμα της δεξαμενής}$$

$$S1tot(t) = S1tot(t - 1) \text{ % ολικό απόθεμα του ταμιευτήρα}$$

*% ανανέωση αποθέματος μετά την είσοδο των καθαρών εισροών*

$$S1tot(t) = S1tot(t) + I(t) \text{ % συνολικό απόθεμα}$$

$$S1net(t) = \max(0, S1tot(t) - Vmin) \text{ % ωφέλιμο απόθεμα}$$

*% παροχτευτικότητα στροβίλου στην αρχή του χρονικού βήματος*

$$Qmax1(t) = QMAX1$$

*% εκροή για την κάλυψη της ύδρευσης από τον ταμιευτήρα*

$$R1supply(t) = \min(Dsupply(t), \min(S1net(t), Qmax1(t)))$$

*% έλεγχος ελλείμματος νερού ύδρευσης*

$$DEFsupply(t) = Dsupply(t) - R1supply(t)$$

*% παροχτευτικότητα αντλιοστροβίλου στην αρχή του χρονικού βήματος*

$$Qmax23(t) = QMAX23$$

*% πρόσθετη εκροή από τη δεξαμενή για την κάλυψη της ύδρευσης*

$$R2supply(t) = \min(DEFsupply(t), \min(S2(t), Qmax23(t)))$$

*% επικαιροποίηση ωφέλιμου αποθέματος ταμιευτήρα*

$$S1net(t) = S1net(t) - R1supply(t)$$

*% υπολογισμός συνολικών εκροών για την κάλυψη της ύδρευσης*

$$R1supply(t) = R1supply(t) + R2supply(t)$$

*% επικαιροποίηση παροχτευτικότητας στροβίλου*

$$Qmax1(t) = Qmax1(t) - R1supply(t)$$

*% εκροή για την κάλυψη της άρδευσης από τον ταμιευτήρα*

$$R1irrig(t) = \min\left(Dirrig(t), \min(S1net(t), Qmax1(t))\right)$$

*% επικαιροποίηση ωφέλιμου αποθέματος ταμιευτήρα και δεξαμενής*

$$S1net(t) = S1net(t) - R1irrig(t)$$

$$S2(t) = S2(t) - R2supply(t)$$

*% επικαιροποίηση παροχетеυτικότητων στροβίλου και αντλιοστροβίλου*

$$Qmax1(t) = Qmax1(t) - R1irrig(t)$$

$$Qmax23(t) = Qmax23(t) - R2supply(t)$$

*% υπολογισμός περίσσειας αποθέματος*

$$EXC(t) = \max(0, S1net(t) - K1)$$

*% υπολογισμός ποσότητας προς άντληση*

$$R3(t) = \min\left(EXC(t), \min(Qmax23(t), K2 - S2(t))\right)$$

*% επανυπολογισμός περίσσειας αποθέματος*

$$EXC(t) = EXC(t) - R3(t)$$

*% υπολογισμός πρόσθετης εκροής από τον ταμιευτήρα*

$$R1excess(t) = \min(EXC(t), Qmax1(t))$$

*% υπολογισμός όγκου υπερχείλισης*

$$Spill(t) = EXC(t) - R1excess(t)$$

*% επικαιροποίηση αποθεμάτων ταμιευτήρα και δεξαμενής*

$$S1net(t) = S1net(t) - R1excess(t) - R3(t) - Spill(t)$$

$$S2(t) = S2(t) + R3(t)$$

*% επικαιροποίηση παροχетеυτικότητων στροβίλου και αντλιοστροβίλου*

$$Qmax1(t) = Qmax1(t) - R1excess(t)$$

$$Qmax23(t) = Qmax23(t) - R3(t)$$

*% υπολογισμός συνολικών εκροών από τον ταμιευτήρα*

$$R1total(t) = R1supply(t) + R1irrig(t) + R1excess(t)$$

*% υπολογισμός συνολικών ροών από και προς τη δεξαμενή*

$$R2total(t) = R2supply(t)$$

$$R3total(t) = R3(t)$$

*% υπολογισμός συνολικού όγκου ταμιευτήρα*

*if S1tot(t) > Vmin*

$$S1tot(t) = S1net(t) + Vmin$$

*else*

$$S1tot(t) = S1tot(t) + S1net(t)$$

*end*

*% υπολογισμός στάθμης ταμιευτήρα και δεξαμενής*

$$z1(t) = (S1tot(t)/2000)^{(1/1.806)}$$

$$z2(t) = z + S2(t)/Etank$$

*% υπολογισμός καθαρού ύψους πτώσης από τον ταμιευτήρα και την δεξαμενή και  
μανομετρικού ύψους άντλησης*

$$H1n(t) = z1(t) * (1 - an1)$$

$$H2n(t) = z2(t) * (1 - an2)$$

$$H2m(t) = z2(t) * (1 + an2)$$

*% υπολογισμοί ενέργειας*

*% παραγωγή ενέργειας από το στρόβιλο*

$$E1(t) = n1 * g * H1n(t) * \frac{R1total(t)}{3600}$$

*% παραγωγή ενέργειας από τον αντλιοστρόβιλο*

$$E2(t) = n2 * g * H2n(t) * \frac{R2total(t)}{3600}$$

*% κατανάλωση ενέργειας από τον αντλιοστρόβιλο*

$$E3(t) = \frac{(g * R3total(t) * H2m(t))}{3600 * n_{pump}}$$

*% επικαιροποίηση ισοζυγίου ενέργειας*

$$Denergy_{final}(t) = Denergy(t) - E1(t) - E2(t) + E3(t)$$

*% έλεγχος ισοζυγίου*

*if Denergy\_{final}(t) >= 0 % περίπτωση ελλείμματος ενέργειας*

$$Dwater(t) = \frac{(Denergy_{final}(t) * 3600)}{g * H2n(t) * n2} \quad \text{\% μετατροπή ζήτησης ενέργειας σε ζήτηση νερού}$$

*% υπολογισμός νερού για παραγωγή επιπλέον ενέργειας από τη δεξαμενή*

$$R2(t) = \min \left( Dwater(t), \min \left( Qmax23(t), \min(S2(t), K1 - S1net(t)) \right) \right)$$

*R3(t) = 0 % υπολογισμός νερού που αντλείται από τον ταμιευτήρα προς τη δεξαμενή*

*else % περίπτωση ελλείμματος ενέργειας περίσσειας ενέργειας*

$$Dwater(t) = \frac{(abs(Denergy_{final}(t)) * 3600 * n_{pump})}{g * H2m(t)} \quad \text{\% μετατροπή ζήτησης ενέργειας σε ζήτηση νερού}$$

*R2(t) = 0 % υπολογισμός νερού που αντλείται από τον ταμιευτήρα προς τη δεξαμενή*

*% υπολογισμός νερού που αντλείται από τον ταμιευτήρα προς τη δεξαμενή*

$$R3(t) = \min \left( Dwater(t), \min \left( Qmax23(t), \min(S1net(t), K2 - S2(t)) \right) \right)$$

*end*

*% επικαιροποίηση αποθεμάτων ταμιευτήρα και δεξαμενής*

$$S1net(t) = S1net(t) + R2(t) - R3(t)$$

$$S2(t) = S2(t) - R2(t) + R3(t)$$

$$E2(t) = g * R2(t) * H2n(t) * \frac{n2}{3600} \quad \text{\% παραγωγή επιπλέον ενέργειας από το νερό της δεξαμενής}$$

$$E3(t) = \frac{(g * R3(t) * H2m(t))}{3600 * n_{pump}} \quad \text{\% καταστροφή ενέργειας μέσω άντλησης}$$

*% επικαιροποίηση ισοζυγίου ενέργειας*

$$Denergy_{final}(t) = Denergy_{final}(t) - E2(t) + E3(t)$$

*% διαχωρισμός ισοζυγίου ενέργειας σε περίσσεια και έλλειμμα*

*if Denergy\_{final}(t) >= 0*

$$DEF_{final}(t) = Denergy_{final}(t)$$

$$SUR_{final}(t) = 0$$

*else*

$$DEF_{final}(t) = 0$$

$$SUR_{final}(t) = abs(Denergy_{final}(t))$$

*end*

*% υπολογισμός συνολικού όγκου ταμειυτήρα*

*if S1tot(t) > Vmin*



$$S1tot(t) = S1net(t) + Vmin$$




*else*




$$S1tot(t) = S1tot(t) + S1net(t)$$

*end*

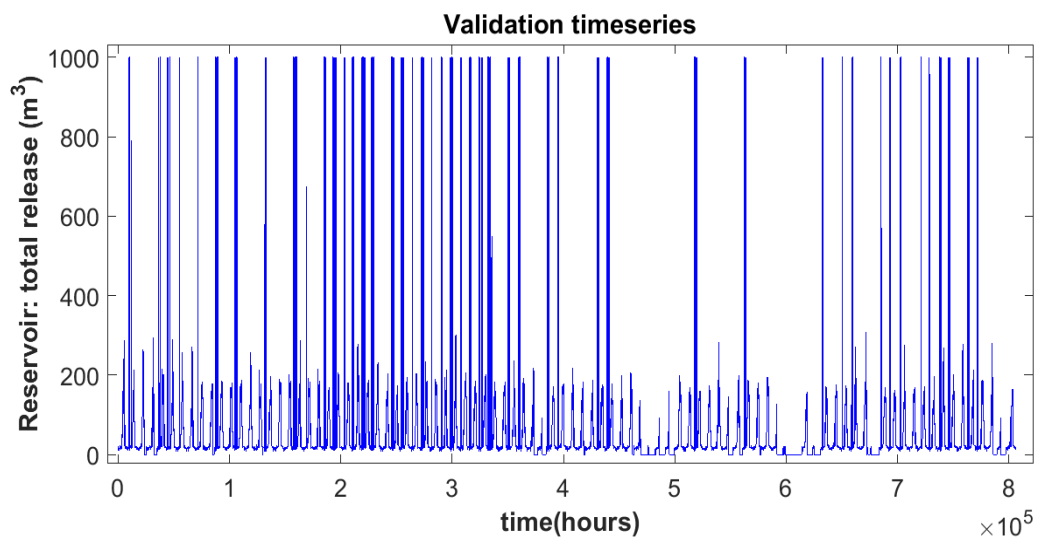

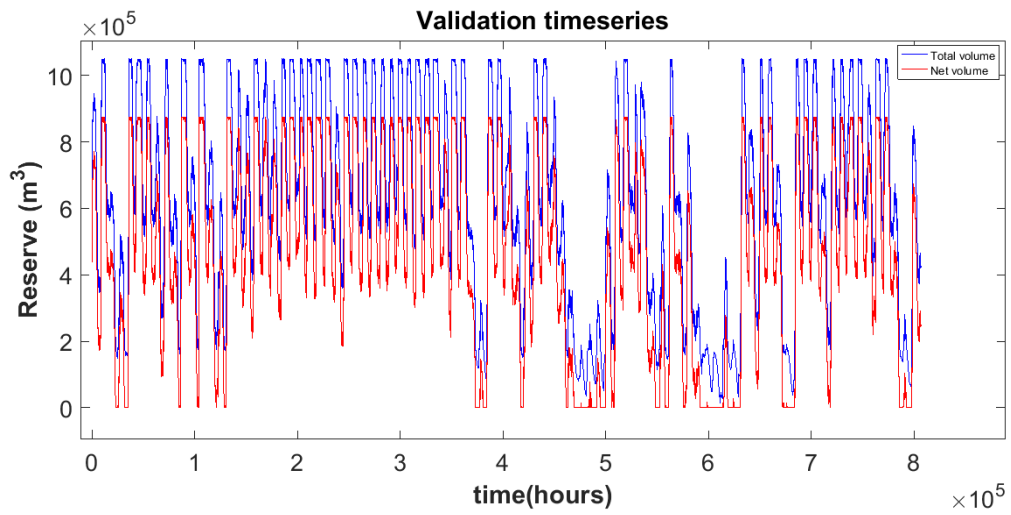
## Αποτελέσματα αναλυτικής προσομοίωσης για παραγωγή δεδομένων αξιολόγησης



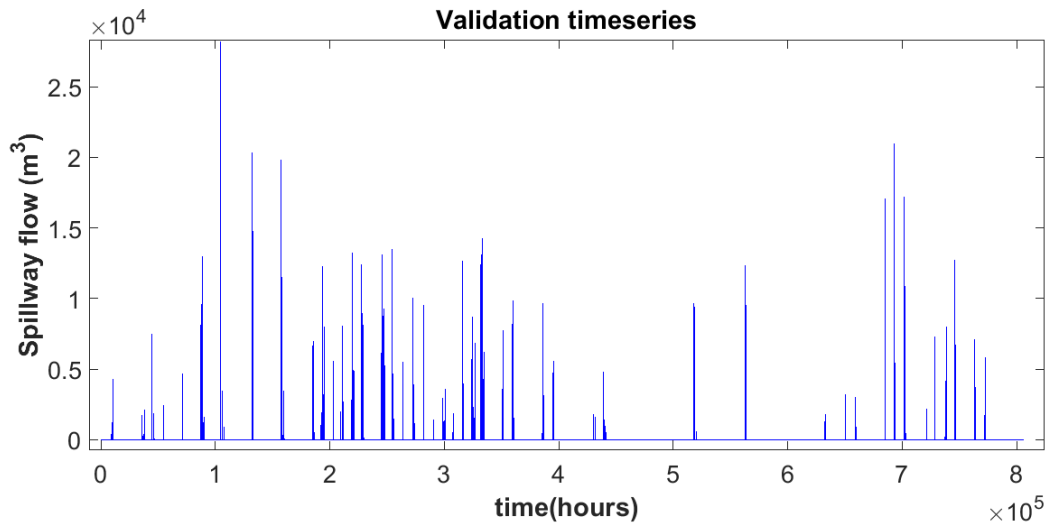













Validation timeseries



## Αποτελέσματα αξιολόγησης νευρωνικών δικτύων για το υδρολογικό μοντέλο

Ομάδα Β	εκπαίδευση			αξιολόγηση		
	Q	ET	S	Q	ET	S
myNeuralNetworkHydro_1	0,03	0,26	0,59	0,01	0,06	0,44
myNeuralNetworkHydro_2	0,04	0,39	0,62	0,02	0,07	0,47
myNeuralNetworkHydro_3	0,04	0,52	0,66	0,01	0,22	0,46
myNeuralNetworkHydro_4	0,14	0,43	0,66	0,08	0,09	0,50
myNeuralNetworkHydro_5	0,29	0,43	0,68	0,26	0,14	0,47
myNeuralNetworkHydro_6	0,13	0,43	0,68	0,06	0,14	0,49
myNeuralNetworkHydro_7	0,37	0,43	0,68	0,44	0,14	0,47
myNeuralNetworkHydro_8	0,15	0,53	0,69	0,13	0,22	0,40
myNeuralNetworkHydro_9	0,64	0,60	0,69	0,55	0,24	0,46
myNeuralNetworkHydro_10	0,31	0,57	0,69	0,20	0,20	0,46
myNeuralNetworkHydro_11	0,14	0,69	0,70	0,04	0,49	0,49
myNeuralNetworkHydro_12	0,34	0,57	0,70	0,31	0,25	0,45
myNeuralNetworkHydro_13	0,60	0,61	0,70	0,51	0,33	0,47
myNeuralNetworkHydro_14	0,43	0,61	0,70	0,36	0,29	0,47
myNeuralNetworkHydro_15	0,59	0,63	0,70	0,40	0,30	0,45
myNeuralNetworkHydro_16	0,67	0,61	0,70	0,56	0,31	0,47
myNeuralNetworkHydro_17	0,53	0,63	0,70	0,36	0,31	0,43
myNeuralNetworkHydro_18	0,60	0,62	0,71	0,39	0,32	0,47
myNeuralNetworkHydro_19	0,67	0,68	0,71	0,54	0,42	0,42
myNeuralNetworkHydro_20	0,69	0,63	0,71	0,49	0,36	0,42
myNeuralNetworkHydro_21	0,68	0,71	0,71	0,49	0,47	0,41
myNeuralNetworkHydro_22	0,62	0,72	0,71	0,47	0,52	0,43
myNeuralNetworkHydro_23	0,67	0,71	0,71	0,37	0,45	0,44
myNeuralNetworkHydro_24	0,60	0,68	0,71	0,39	0,43	0,41
myNeuralNetworkHydro_25	0,66	0,67	0,71	0,43	0,37	0,38
myNeuralNetworkHydro_26	0,59	0,66	0,71	0,47	0,34	0,42
myNeuralNetworkHydro_27	0,70	0,67	0,71	0,54	0,38	0,26
myNeuralNetworkHydro_28	0,65	0,77	0,72	0,49	0,59	0,39
myNeuralNetworkHydro_29	0,72	0,70	0,71	0,48	0,44	0,03
myNeuralNetworkHydro_30	0,72	0,73	0,72	0,43	0,51	0,33
myNeuralNetworkHydro_31	0,72	0,69	0,71	0,45	0,41	0,33
myNeuralNetworkHydro_32	0,61	0,65	0,72	0,47	0,36	0,29
myNeuralNetworkHydro_33	0,66	0,68	0,72	0,46	0,42	0,27
myNeuralNetworkHydro_34	0,69	0,68	0,72	0,54	0,43	0,32
myNeuralNetworkHydro_35	0,71	0,75	0,72	0,32	0,55	-0,02

myNeuralNetworkHydro_36	0,64	0,68	0,72	0,43	0,43	0,05
myNeuralNetworkHydro_37	0,72	0,71	0,72	0,48	0,47	0,18
myNeuralNetworkHydro_38	0,72	0,73	0,73	0,47	0,48	0,11
myNeuralNetworkHydro_39	0,69	0,76	0,72	0,33	0,53	0,26
myNeuralNetworkHydro_40	0,73	0,70	0,72	0,53	0,44	0,18
myNeuralNetworkHydro_41	0,76	0,71	0,72	0,42	0,46	0,15
myNeuralNetworkHydro_42	0,74	0,73	0,72	0,43	0,53	0,02
myNeuralNetworkHydro_43	0,69	0,72	0,73	0,43	0,48	-0,07
myNeuralNetworkHydro_44	0,71	0,73	0,72	0,49	0,51	0,21
myNeuralNetworkHydro_45	0,74	0,71	0,72	0,47	0,43	0,09
myNeuralNetworkHydro_46	0,73	0,74	0,72	0,52	0,53	0,20
myNeuralNetworkHydro_47	0,73	0,70	0,72	0,51	0,40	0,25
myNeuralNetworkHydro_48	0,79	0,73	0,73	0,42	0,52	0,14
myNeuralNetworkHydro_49	0,75	0,72	0,72	0,49	0,48	0,22
myNeuralNetworkHydro_50	0,76	0,73	0,73	0,40	0,50	0,07
myNeuralNetworkHydro_51	0,76	0,76	0,73	0,44	0,54	0,02
myNeuralNetworkHydro_52	0,74	0,73	0,72	0,43	0,50	-0,03
myNeuralNetworkHydro_53	0,74	0,73	0,72	0,50	0,48	0,21
myNeuralNetworkHydro_54	0,77	0,77	0,73	0,37	0,57	0,04
myNeuralNetworkHydro_55	0,76	0,77	0,72	0,38	0,56	0,25
myNeuralNetworkHydro_56	0,72	0,75	0,72	0,51	0,56	0,25
myNeuralNetworkHydro_57	0,76	0,74	0,72	0,52	0,52	0,04
myNeuralNetworkHydro_58	0,73	0,71	0,73	0,48	0,48	0,24
myNeuralNetworkHydro_59	0,74	0,71	0,71	0,45	0,44	0,06
myNeuralNetworkHydro_60	0,75	0,74	0,73	0,47	0,52	0,12
myNeuralNetworkHydro_61	0,71	0,77	0,72	0,53	0,59	0,25
myNeuralNetworkHydro_62	0,76	0,75	0,72	0,46	0,55	0,12
myNeuralNetworkHydro_63	0,76	0,71	0,73	0,41	0,44	0,11
myNeuralNetworkHydro_64	0,75	0,74	0,73	0,53	0,54	0,08
myNeuralNetworkHydro_65	0,74	0,75	0,73	0,50	0,54	-0,09
myNeuralNetworkHydro_66	0,74	0,76	0,74	0,50	0,54	-0,22
myNeuralNetworkHydro_67	0,75	0,73	0,73	0,51	0,50	0,13
myNeuralNetworkHydro_68	0,73	0,70	0,72	0,39	0,41	0,20
myNeuralNetworkHydro_69	0,74	0,76	0,72	0,50	0,56	0,20
myNeuralNetworkHydro_70	0,78	0,74	0,73	0,45	0,52	0,07
myNeuralNetworkHydro_71	0,73	0,76	0,72	0,42	0,58	0,01
myNeuralNetworkHydro_72	0,76	0,77	0,72	0,46	0,56	0,09
myNeuralNetworkHydro_73	0,76	0,74	0,73	0,49	0,51	-0,08
myNeuralNetworkHydro_74	0,77	0,79	0,72	0,44	0,64	-0,05
myNeuralNetworkHydro_75	0,72	0,78	0,73	0,54	0,61	0,07
myNeuralNetworkHydro_76	0,74	0,77	0,72	0,51	0,60	-0,01

myNeuralNetworkHydro_77	0,75	0,75	0,72	0,50	0,53	0,08
myNeuralNetworkHydro_78	0,73	0,73	0,71	0,38	0,48	0,06
myNeuralNetworkHydro_79	0,75	0,71	0,72	0,44	0,48	0,03
myNeuralNetworkHydro_80	0,73	0,75	0,72	0,53	0,55	0,24
myNeuralNetworkHydro_81	0,72	0,73	0,72	0,55	0,49	0,07
myNeuralNetworkHydro_82	0,72	0,77	0,72	0,54	0,58	0,27
myNeuralNetworkHydro_83	0,75	0,74	0,72	0,48	0,53	0,24
myNeuralNetworkHydro_84	0,77	0,75	0,73	0,44	0,53	-0,50
myNeuralNetworkHydro_85	0,74	0,76	0,72	0,53	0,56	0,15
myNeuralNetworkHydro_86	0,73	0,73	0,72	0,51	0,44	0,32
myNeuralNetworkHydro_87	0,75	0,76	0,72	0,49	0,56	0,22
myNeuralNetworkHydro_88	0,73	0,78	0,72	0,51	0,61	-0,14
myNeuralNetworkHydro_89	0,76	0,69	0,72	0,42	0,44	0,22
myNeuralNetworkHydro_90	0,76	0,76	0,73	0,48	0,56	0,24
myNeuralNetworkHydro_91	0,75	0,73	0,73	0,46	0,51	0,15
myNeuralNetworkHydro_92	0,77	0,74	0,74	0,42	0,54	-0,73
myNeuralNetworkHydro_93	0,75	0,77	0,72	0,50	0,58	-0,27
myNeuralNetworkHydro_94	0,74	0,72	0,72	0,48	0,49	0,09
myNeuralNetworkHydro_95	0,76	0,73	0,72	0,44	0,52	0,08
myNeuralNetworkHydro_96	0,75	0,79	0,71	0,47	0,63	-0,12
myNeuralNetworkHydro_97	0,73	0,73	0,72	0,46	0,51	0,18
myNeuralNetworkHydro_98	0,78	0,79	0,72	0,44	0,62	-1,45
myNeuralNetworkHydro_99	0,75	0,78	0,72	0,50	0,56	-0,01
myNeuralNetworkHydro_100	0,73	0,77	0,73	0,53	0,57	0,13

Ομάδα Γ	Q		ET		S	
	εκπαίδευση	αξιολόγηση	εκπαίδευση	αξιολόγηση	εκπαίδευση	αξιολόγηση
myNeuralNetworkHydro_1	0,64	0,54	0,62	0,43	0,59	0,44
myNeuralNetworkHydro_2	0,67	0,55	0,76	0,59	0,63	0,45
myNeuralNetworkHydro_3	0,73	0,22	0,78	0,65	0,64	0,41
myNeuralNetworkHydro_4	0,78	0,35	0,80	0,65	0,66	0,50
myNeuralNetworkHydro_5	0,78	0,41	0,80	0,65	0,66	0,49
myNeuralNetworkHydro_6	0,80	-0,12	0,81	0,64	0,67	0,50
myNeuralNetworkHydro_7	0,79	0,38	0,82	0,68	0,69	0,49
myNeuralNetworkHydro_8	0,81	0,30	0,82	0,63	0,69	0,46
myNeuralNetworkHydro_9	0,86	-1,77	0,83	0,63	0,69	0,46
myNeuralNetworkHydro_10	0,85	-4,61	0,83	0,60	0,69	0,48
myNeuralNetworkHydro_11	0,84	0,26	0,83	0,63	0,70	0,46
myNeuralNetworkHydro_12	0,84	0,24	0,82	0,63	0,70	0,47
myNeuralNetworkHydro_13	0,83	-2,24	0,83	0,60	0,70	0,47
myNeuralNetworkHydro_14	0,86	-2,70	0,84	0,67	0,70	0,47
myNeuralNetworkHydro_15	0,88	-7,64	0,84	0,67	0,70	0,45
myNeuralNetworkHydro_16	0,87	-1,61	0,84	0,66	0,70	0,47
myNeuralNetworkHydro_17	0,86	-5,90	0,84	0,64	0,70	0,45
myNeuralNetworkHydro_18	0,92	-1,35	0,84	0,55	0,70	0,45
myNeuralNetworkHydro_19	0,89	-6,17	0,84	0,58	0,71	0,46
myNeuralNetworkHydro_20	0,90	-10,15	0,84	0,67	0,71	0,46
myNeuralNetworkHydro_21	0,91	-11,92	0,84	0,64	0,71	0,44
myNeuralNetworkHydro_22	0,90	-17,39	0,84	0,61	0,71	0,43
myNeuralNetworkHydro_23	0,91	-5,81	0,84	0,66	0,71	0,40
myNeuralNetworkHydro_24	0,86	-15,66	0,84	0,62	0,71	0,42
myNeuralNetworkHydro_25	0,90	-4,19	0,84	0,66	0,71	0,42
myNeuralNetworkHydro_26	0,90	-38,47	0,84	0,66	0,70	0,47
myNeuralNetworkHydro_27	0,91	-4,95	0,84	0,64	0,71	0,40
myNeuralNetworkHydro_28	0,88	-10,40	0,85	0,67	0,71	0,36
myNeuralNetworkHydro_29	0,89	-8,91	0,85	0,62	0,71	0,37
myNeuralNetworkHydro_30	0,75	-6,15	0,85	0,65	0,72	0,36
myNeuralNetworkHydro_31	0,81	-6,44	0,85	0,62	0,72	0,31
myNeuralNetworkHydro_32	0,91	-3,36	0,84	0,64	0,72	0,36
myNeuralNetworkHydro_33	0,91	-9,21	0,85	0,65	0,72	0,35
myNeuralNetworkHydro_34	0,87	-8,00	0,84	0,65	0,72	0,28

myNeuralNetworkHydro_35	0,90	-2,77	0,84	0,62	0,72	0,39
myNeuralNetworkHydro_36	0,91	-9,73	0,85	0,60	0,71	0,43
myNeuralNetworkHydro_37	0,91	-13,14	0,84	0,59	0,72	0,39
myNeuralNetworkHydro_38	0,92	-9,35	0,85	0,45	0,72	0,34
myNeuralNetworkHydro_39	0,90	-3,72	0,84	0,60	0,71	0,38
myNeuralNetworkHydro_40	0,92	-8,03	0,85	0,61	0,71	0,29
myNeuralNetworkHydro_41	0,87	-4,15	0,85	0,63	0,72	0,37
myNeuralNetworkHydro_42	0,84	-5,92	0,84	0,60	0,71	0,38
myNeuralNetworkHydro_43	0,91	-2,84	0,84	0,65	0,71	0,39
myNeuralNetworkHydro_44	0,91	-6,56	0,85	0,61	0,72	0,42
myNeuralNetworkHydro_45	0,88	-5,85	0,84	0,61	0,71	0,41
myNeuralNetworkHydro_46	0,91	-11,00	0,85	0,63	0,71	0,39
myNeuralNetworkHydro_47	0,87	-7,06	0,85	0,57	0,71	0,44
myNeuralNetworkHydro_48	0,93	-5,82	0,84	0,65	0,70	0,48
myNeuralNetworkHydro_49	0,92	-2,56	0,84	0,55	0,71	0,39
myNeuralNetworkHydro_50	0,88	-8,80	0,85	0,54	0,71	0,45



Ομάδα Δ1	εκπαίδευση			αξιολόγηση		
	Q	ET	S	Q	ET	S
myNeuralNetworkHydro_1	0,44	0,62	0,71	0,31	0,37	0,46
myNeuralNetworkHydro_2	0,47	0,64	0,71	0,25	0,30	0,43
myNeuralNetworkHydro_3	0,34	0,57	0,73	0,25	0,28	0,46
myNeuralNetworkHydro_4	0,39	0,62	0,74	0,29	0,37	0,48
myNeuralNetworkHydro_5	0,31	0,54	0,75	0,21	0,21	0,48
myNeuralNetworkHydro_6	0,30	0,57	0,75	0,22	0,25	0,46
myNeuralNetworkHydro_7	0,39	0,55	0,77	0,29	0,23	0,49
myNeuralNetworkHydro_8	0,30	0,59	0,78	0,22	0,31	0,49
myNeuralNetworkHydro_9	0,31	0,53	0,78	0,22	0,23	0,51
myNeuralNetworkHydro_10	0,49	0,59	0,80	0,37	0,30	0,47
myNeuralNetworkHydro_11	0,26	0,51	0,80	0,19	0,23	0,50
myNeuralNetworkHydro_12	0,22	0,51	0,82	0,12	0,24	0,42
myNeuralNetworkHydro_13	0,36	0,53	0,83	0,28	0,25	0,50
myNeuralNetworkHydro_14	0,25	0,54	0,84	0,19	0,25	0,50
myNeuralNetworkHydro_15	0,36	0,57	0,85	0,24	0,30	0,45
myNeuralNetworkHydro_16	0,26	0,55	0,85	0,22	0,24	0,47
myNeuralNetworkHydro_17	0,29	0,57	0,86	0,20	0,31	0,12
myNeuralNetworkHydro_18	0,19	0,56	0,87	0,14	0,30	0,56
myNeuralNetworkHydro_19	0,32	0,58	0,88	0,24	0,33	0,49
myNeuralNetworkHydro_20	0,37	0,62	0,88	0,24	0,32	0,54
myNeuralNetworkHydro_21	0,30	0,56	0,89	0,28	0,27	0,53
myNeuralNetworkHydro_22	0,16	0,53	0,89	0,10	0,27	0,41
myNeuralNetworkHydro_23	0,22	0,59	0,88	0,17	0,32	0,57
myNeuralNetworkHydro_24	0,14	0,54	0,90	0,04	0,29	0,51
myNeuralNetworkHydro_25	0,20	0,58	0,90	0,09	0,29	0,51
myNeuralNetworkHydro_26	0,22	0,56	0,91	0,14	0,29	0,58
myNeuralNetworkHydro_27	0,20	0,57	0,91	0,11	0,30	0,54
myNeuralNetworkHydro_28	0,20	0,57	0,91	0,13	0,26	0,46
myNeuralNetworkHydro_29	0,21	0,58	0,92	0,17	0,26	0,54
myNeuralNetworkHydro_30	0,19	0,58	0,91	0,13	0,33	0,57
myNeuralNetworkHydro_31	0,26	0,55	0,92	0,19	0,30	0,53
myNeuralNetworkHydro_32	0,12	0,55	0,92	0,07	0,31	0,56
myNeuralNetworkHydro_33	0,14	0,57	0,93	0,07	0,27	0,53
myNeuralNetworkHydro_34	0,20	0,56	0,93	0,09	0,28	0,39
myNeuralNetworkHydro_35	0,22	0,56	0,93	0,15	0,30	0,50
myNeuralNetworkHydro_36	0,32	0,57	0,94	0,17	0,32	0,42
myNeuralNetworkHydro_37	0,33	0,64	0,93	0,28	0,42	0,58
myNeuralNetworkHydro_38	0,25	0,57	0,93	0,16	0,32	0,60
myNeuralNetworkHydro_39	0,18	0,59	0,93	0,11	0,31	0,46
myNeuralNetworkHydro_40	0,32	0,55	0,93	0,20	0,31	0,44

myNeuralNetworkHydro_41	0,25	0,54	0,93	0,16	0,28	0,49
myNeuralNetworkHydro_42	0,12	0,55	0,93	0,09	0,32	0,60
myNeuralNetworkHydro_43	0,18	0,54	0,94	0,08	0,29	0,48
myNeuralNetworkHydro_44	0,19	0,55	0,93	0,04	0,29	0,45
myNeuralNetworkHydro_45	0,21	0,57	0,93	0,09	0,33	0,49
myNeuralNetworkHydro_46	0,26	0,54	0,94	0,20	0,31	0,55
myNeuralNetworkHydro_47	0,17	0,56	0,94	0,08	0,30	0,59
myNeuralNetworkHydro_48	0,26	0,58	0,94	0,18	0,34	0,58
myNeuralNetworkHydro_49	0,30	0,57	0,94	0,22	0,27	0,59
myNeuralNetworkHydro_50	0,31	0,55	0,94	0,19	0,32	0,49

Ομάδα Δ2	Q		Ομάδα Δ2	Q	
	εκπαίδευση	αξιολόγηση		εκπαίδευση	αξιολόγηση
myNeuralNetworkHydro_1	0,86	-0,31	myNeuralNetworkHydro_26	0,99	-66,45
myNeuralNetworkHydro_2	0,90	-3,22	myNeuralNetworkHydro_27	-0,83	-62,25
myNeuralNetworkHydro_3	0,91	-4,44	myNeuralNetworkHydro_28	0,33	-74,86
myNeuralNetworkHydro_4	0,92	-5,30	myNeuralNetworkHydro_29	0,61	-28,38
myNeuralNetworkHydro_5	0,90	-9,67	myNeuralNetworkHydro_30	-1,77	-77,82
myNeuralNetworkHydro_6	0,94	-1,98	myNeuralNetworkHydro_31	0,26	-101,92
myNeuralNetworkHydro_7	0,93	-4,31	myNeuralNetworkHydro_32	-5,62	-54,24
myNeuralNetworkHydro_8	0,95	-1,35	myNeuralNetworkHydro_33	0,43	-67,63
myNeuralNetworkHydro_9	0,94	-2,37	myNeuralNetworkHydro_34	-3,34	-68,77
myNeuralNetworkHydro_10	0,99	-2,77	myNeuralNetworkHydro_35	-0,80	-79,92
myNeuralNetworkHydro_11	0,97	-11,00	myNeuralNetworkHydro_36	0,86	-60,93
myNeuralNetworkHydro_12	0,92	-232,94	myNeuralNetworkHydro_37	0,94	-50,11
myNeuralNetworkHydro_13	0,98	-294,50	myNeuralNetworkHydro_38	0,98	-42,84
myNeuralNetworkHydro_14	-10,90	-375,86	myNeuralNetworkHydro_39	0,93	-34,99
myNeuralNetworkHydro_15	-5,15	-299,26	myNeuralNetworkHydro_40	0,79	-57,88
myNeuralNetworkHydro_16	0,04	-100,10	myNeuralNetworkHydro_41	0,56	-21,24
myNeuralNetworkHydro_17	-0,18	-200,52	myNeuralNetworkHydro_42	0,98	-41,26
myNeuralNetworkHydro_18	0,40	-146,33	myNeuralNetworkHydro_43	1,00	-25,68
myNeuralNetworkHydro_19	-2,16	-105,31	myNeuralNetworkHydro_44	0,92	-25,66
myNeuralNetworkHydro_20	-3,61	-199,55	myNeuralNetworkHydro_45	1,00	-22,49
myNeuralNetworkHydro_21	0,94	-112,05	myNeuralNetworkHydro_46	0,87	-21,95
myNeuralNetworkHydro_22	0,78	-229,84	myNeuralNetworkHydro_47	0,98	-35,53
myNeuralNetworkHydro_23	0,98	-112,17	myNeuralNetworkHydro_48	0,99	-7,95
myNeuralNetworkHydro_24	0,96	-86,48	myNeuralNetworkHydro_49	0,76	-17,28
myNeuralNetworkHydro_25	0,71	-46,80	myNeuralNetworkHydro_50	0,56	-26,44

**Αποτελέσματα αξιολόγησης νευρωνικών δικτύων για το μοντέλο λειτουργίας του υβριδικού σταθμού**

Ομάδα B.i	Denergy_final	
	εκπαίδευση	αξιολόγηση
myNeuralNetworkRes_1	0,67	0,36
myNeuralNetworkRes_2	0,67	0,38
myNeuralNetworkRes_3	0,70	0,28
myNeuralNetworkRes_4	0,70	0,26
myNeuralNetworkRes_5	0,69	0,09
myNeuralNetworkRes_6	0,70	0,21
myNeuralNetworkRes_7	0,71	0,25
myNeuralNetworkRes_8	0,71	0,31
myNeuralNetworkRes_9	0,71	0,01
myNeuralNetworkRes_10	0,71	0,35
myNeuralNetworkRes_11	0,71	0,39
myNeuralNetworkRes_12	0,71	0,23
myNeuralNetworkRes_13	0,71	0,09
myNeuralNetworkRes_14	0,71	-6,59
myNeuralNetworkRes_15	0,71	0,17
myNeuralNetworkRes_16	0,71	-0,26
myNeuralNetworkRes_17	0,71	-0,01
myNeuralNetworkRes_18	0,71	0,35
myNeuralNetworkRes_19	0,71	-0,45
myNeuralNetworkRes_20	0,71	0,25
myNeuralNetworkRes_21	0,71	0,17
myNeuralNetworkRes_22	0,71	0,01
myNeuralNetworkRes_23	0,71	-5,19
myNeuralNetworkRes_24	0,69	-0,25
myNeuralNetworkRes_25	0,71	-0,34
myNeuralNetworkRes_26	0,71	-0,84
myNeuralNetworkRes_27	0,71	-2,43
myNeuralNetworkRes_28	0,71	-0,04
myNeuralNetworkRes_29	0,71	0,11
myNeuralNetworkRes_30	0,70	0,06
myNeuralNetworkRes_31	0,70	-1,53
myNeuralNetworkRes_32	0,71	-9,47

myNeuralNetworkRes_33	0,71	0,01
myNeuralNetworkRes_34	0,71	-0,73
myNeuralNetworkRes_35	0,71	-0,16
myNeuralNetworkRes_36	0,71	0,09
myNeuralNetworkRes_37	0,71	-1,10
myNeuralNetworkRes_38	0,71	-0,12
myNeuralNetworkRes_39	0,71	-0,11
myNeuralNetworkRes_40	0,71	-7,41
myNeuralNetworkRes_41	0,71	-0,01
myNeuralNetworkRes_42	0,71	0,06
myNeuralNetworkRes_43	0,71	0,04
myNeuralNetworkRes_44	0,71	-0,43
myNeuralNetworkRes_45	0,65	-12,27
myNeuralNetworkRes_46	0,70	-0,16
myNeuralNetworkRes_47	0,71	-0,59
myNeuralNetworkRes_48	0,70	-1,16
myNeuralNetworkRes_49	0,72	-0,45
myNeuralNetworkRes_50	0,71	0,08
myNeuralNetworkRes_51	0,70	-0,25
myNeuralNetworkRes_52	0,71	0,13
myNeuralNetworkRes_53	0,71	-5,09
myNeuralNetworkRes_54	0,69	-1,72
myNeuralNetworkRes_55	0,72	0,30
myNeuralNetworkRes_56	0,71	-0,20
myNeuralNetworkRes_57	0,70	0,04
myNeuralNetworkRes_58	0,71	-0,86
myNeuralNetworkRes_59	0,71	-4,50
myNeuralNetworkRes_60	0,71	-2,30
myNeuralNetworkRes_61	0,71	-0,07
myNeuralNetworkRes_62	0,71	-1,22
myNeuralNetworkRes_63	0,72	0,38
myNeuralNetworkRes_64	0,71	-5,03
myNeuralNetworkRes_65	0,69	-4,00
myNeuralNetworkRes_66	0,71	0,26
myNeuralNetworkRes_67	0,71	-0,69
myNeuralNetworkRes_68	0,71	-0,80
myNeuralNetworkRes_69	0,71	-1,43
myNeuralNetworkRes_70	0,71	-0,67
myNeuralNetworkRes_71	0,71	0,27
myNeuralNetworkRes_72	0,71	-0,51
myNeuralNetworkRes_73	0,71	-4,33
myNeuralNetworkRes_74	0,70	-0,18

myNeuralNetworkRes_75	0,71	-0,06
myNeuralNetworkRes_76	0,62	-2,34
myNeuralNetworkRes_77	0,70	-0,47
myNeuralNetworkRes_78	0,71	0,14
myNeuralNetworkRes_79	0,72	-0,58
myNeuralNetworkRes_80	0,70	-1,00
myNeuralNetworkRes_81	0,71	-0,61
myNeuralNetworkRes_82	0,71	-0,85
myNeuralNetworkRes_83	0,71	0,18
myNeuralNetworkRes_84	0,66	-0,69
myNeuralNetworkRes_85	0,71	-0,05
myNeuralNetworkRes_86	0,71	0,11
myNeuralNetworkRes_87	0,70	0,16
myNeuralNetworkRes_88	0,71	-7,94
myNeuralNetworkRes_89	0,71	-0,15
myNeuralNetworkRes_90	0,70	-0,72
myNeuralNetworkRes_91	0,68	-1,01
myNeuralNetworkRes_92	0,72	-2,31
myNeuralNetworkRes_93	0,71	-0,10

Ομάδα Β.ii – Έλλειμμα	σετ 1		σετ 2	
	εκπαίδευση	αξιολόγηση	εκπαίδευση	αξιολόγηση
myNNDEF_1	0,77	-0,07	0,77	0,35
myNNDEF_2	0,76	-0,16	0,77	0,45
myNNDEF_3	0,77	0,39	0,77	0,28
myNNDEF_4	0,77	0,45	0,77	0,18
myNNDEF_5	0,77	-0,06	0,77	0,39
myNNDEF_6	0,77	0,17	0,77	0,35
myNNDEF_7	0,77	0,34	0,77	0,40
myNNDEF_8	0,77	0,31	0,77	0,37
myNNDEF_9	0,77	0,38	0,76	0,13
myNNDEF_10	0,77	-0,36	0,77	0,34
myNNDEF_11	0,77	0,27	0,74	-0,55
myNNDEF_12	0,41	-29,82	0,77	0,28
myNNDEF_13	0,77	0,32	0,77	0,39
myNNDEF_14	0,77	0,41	0,77	0,36
myNNDEF_15	0,77	0,38	0,77	0,38
myNNDEF_16	0,77	0,29	0,77	0,19
myNNDEF_17	0,77	0,38	0,77	0,39

myNNDEF_18	0,77	0,16	0,77	0,32
myNNDEF_19	0,77	0,35	0,77	0,21
myNNDEF_20	0,77	-0,14	0,77	0,38
myNNDEF_21	0,77	0,31	0,77	0,39
myNNDEF_22	0,77	0,35	0,77	0,14
myNNDEF_23	0,77	0,17	0,77	0,21
myNNDEF_24	0,77	0,12	0,77	0,16
myNNDEF_25	0,77	0,45	0,77	0,19
myNNDEF_26	0,77	0,16	0,77	0,39
myNNDEF_27	0,77	0,35	0,77	0,05
myNNDEF_28	0,77	0,26	0,77	0,28
myNNDEF_29	0,76	-0,87	0,77	0,37
myNNDEF_30	0,77	0,30	0,77	0,37
myNNDEF_31	0,77	0,00	0,77	0,17
myNNDEF_32	0,77	0,39	0,77	0,39
myNNDEF_33	0,77	0,34	0,77	0,13
myNNDEF_34	0,76	-0,45	0,77	0,18
myNNDEF_35	0,77	0,21	0,77	0,37
myNNDEF_36	0,77	0,36	0,77	0,20
myNNDEF_37	0,77	0,25	0,77	0,31
myNNDEF_38	0,77	0,33	0,77	0,36
myNNDEF_39	0,77	0,33	0,77	0,37
myNNDEF_40	0,77	0,34	0,77	-0,46
myNNDEF_41	0,77	0,09	0,77	0,22
myNNDEF_42	0,77	0,34	0,77	0,22
myNNDEF_43	0,77	0,23	0,77	0,38
myNNDEF_44	0,76	0,25	0,77	0,12
myNNDEF_45	0,77	0,36	0,77	0,21
myNNDEF_46	0,77	0,27	0,77	0,36
myNNDEF_47	0,77	0,19	0,77	0,27
myNNDEF_48	0,77	0,37	0,77	0,31
myNNDEF_49	0,77	0,00	0,77	0,09
myNNDEF_50	0,77	0,39	0,77	0,37
myNNDEF_51	0,77	0,09		
myNNDEF_52	0,77	0,35		
myNNDEF_53	0,77	0,34		
myNNDEF_54	0,77	0,29		
myNNDEF_55	0,77	0,32		
myNNDEF_56	0,77	0,28		
myNNDEF_57	0,77	0,33		
myNNDEF_58	0,77	0,34		
myNNDEF_59	0,77	0,32		

myNNDEF_60	0,77	0,31		
myNNDEF_61	0,77	0,38		
myNNDEF_62	0,77	0,35		
myNNDEF_63	0,77	0,23		
myNNDEF_64	0,77	0,36		
myNNDEF_65	0,77	0,21		
myNNDEF_66	0,77	0,35		
myNNDEF_67	0,77	0,24		
myNNDEF_68	0,77	-0,37		
myNNDEF_69	0,77	0,36		
myNNDEF_70	0,77	0,14		
myNNDEF_71	0,77	0,24		
myNNDEF_72	0,77	0,20		
myNNDEF_73	0,35	-7,59		
myNNDEF_74	0,77	0,35		
myNNDEF_75	0,77	0,37		
myNNDEF_76	0,77	0,41		
myNNDEF_77	0,77	-2,19		
myNNDEF_78	0,77	0,35		
myNNDEF_79	0,77	0,03		
myNNDEF_80	0,73	-5,63		
myNNDEF_81	0,77	0,34		
myNNDEF_82	0,77	0,29		
myNNDEF_83	0,68	-0,16		
myNNDEF_84	0,77	0,26		
myNNDEF_85	0,77	0,25		
myNNDEF_86	0,70	0,03		
myNNDEF_87	0,77	0,38		
myNNDEF_88	0,77	0,35		
myNNDEF_89	0,77	0,40		
myNNDEF_90	0,77	0,36		
myNNDEF_91	0,41	-3,28		
myNNDEF_92	0,77	0,39		
myNNDEF_93	0,77	0,42		
myNNDEF_94	0,77	0,31		
myNNDEF_95	0,77	0,22		
myNNDEF_96	0,77	0,35		
myNNDEF_97	0,77	0,32		
myNNDEF_98	0,77	0,43		
myNNDEF_99	0,77	0,28		
myNNDEF_100	0,77	0,10		

Ομάδα Β.ii – Περίσσεια	set 1		set 2	
	εκπαίδευση	αξιολόγηση	εκπαίδευση	αξιολόγηση
myNNSUR_1	0,31	-0,46	0,32	-1,29
myNNSUR_2	0,30	-0,20	0,32	-0,09
myNNSUR_3	0,31	0,06	0,31	0,28
myNNSUR_4	0,31	0,06	0,32	-3,90
myNNSUR_5	0,31	-1,24	0,31	-0,25
myNNSUR_6	-2,38	-0,61	0,32	0,07
myNNSUR_7	0,33	-0,06	0,31	-9,09
myNNSUR_8	0,30	-1,20	0,32	0,32
myNNSUR_9	0,31	-0,04	0,31	-2,47
myNNSUR_10	0,31	-0,15	0,32	-0,13
myNNSUR_11	0,32	0,12	0,32	-0,20
myNNSUR_12	0,31	-0,05	0,31	-0,15
myNNSUR_13	0,31	-0,15	-3,29	-11,70
myNNSUR_14	0,32	-1,07	0,19	-2,30
myNNSUR_15	0,32	-0,14		
myNNSUR_16	0,32	0,11		
myNNSUR_17	0,31	-0,57		
myNNSUR_18	0,32	0,06		
myNNSUR_19	0,00	-0,37		
myNNSUR_20	0,32	-0,67		
myNNSUR_21	0,31	-3,24		
myNNSUR_22	0,31	-0,39		
myNNSUR_23	-0,54	-1,98		
myNNSUR_24	0,32	-0,43		
myNNSUR_25	0,32	-0,58		
myNNSUR_26	0,32	-0,48		
myNNSUR_27	0,32	-0,09		
myNNSUR_28	0,32	0,04		
myNNSUR_29	0,18	-0,43		
myNNSUR_30	0,31	-0,11		
myNNSUR_31	0,31	-0,41		
myNNSUR_32	0,32	-0,19		
myNNSUR_33	0,31	-0,04		
myNNSUR_34	0,31	-0,13		
myNNSUR_35	0,30	-0,27		
myNNSUR_36	0,32	-1,32		
myNNSUR_37	0,32	-0,06		



myNNSUR_38	0,31	-0,11		
myNNSUR_39	0,31	-0,12		
myNNSUR_40	0,32	-9,28		
myNNSUR_41	0,31	0,08		
myNNSUR_42	0,32	-0,33		
myNNSUR_43	0,31	-0,06		
myNNSUR_44	0,30	-0,13		
myNNSUR_45	0,32	-0,51		
myNNSUR_46	0,26	-2,95		
myNNSUR_47	0,19	-3,94		
myNNSUR_48	0,32	-0,09		
myNNSUR_49	0,32	-4,07		
myNNSUR_50	0,32	-0,16		
myNNSUR_51	0,31	-0,02		
myNNSUR_52	-0,18	-4,80		
myNNSUR_53	0,32	0,29		
myNNSUR_54	0,32	-0,13		
myNNSUR_55	0,31	-0,13		
myNNSUR_56	0,31	-0,49		
myNNSUR_57	0,31	-0,61		
myNNSUR_58	0,31	-0,09		
myNNSUR_59	0,32	-0,70		
myNNSUR_60	0,28	-0,46		
myNNSUR_61	0,26	-7,41		
myNNSUR_62	0,32	-0,78		
myNNSUR_63	0,25	-0,39		
myNNSUR_64	0,31	-0,18		
myNNSUR_65	0,32	0,28		
myNNSUR_66	0,32	-0,31		
myNNSUR_67	0,31	-0,23		
myNNSUR_68	0,31	0,31		
myNNSUR_69	0,31	-0,48		
myNNSUR_70	0,32	-0,16		
myNNSUR_71	0,32	0,09		
myNNSUR_72	0,32	-1,00		
myNNSUR_73	0,32	0,22		
myNNSUR_74	0,32	-1,00		
myNNSUR_75	0,22	-1,04		
myNNSUR_76	0,31	-0,05		
myNNSUR_77	0,32	-5,81		
myNNSUR_78	0,31	-0,11		
myNNSUR_79	0,29	-0,90		



myNNSUR_80	0,30	-0,37		
myNNSUR_81	0,32	-0,25		
myNNSUR_82	0,32	-0,03		
myNNSUR_83	0,30	-0,05		
myNNSUR_84	0,32	-0,11		
myNNSUR_85	0,31	-0,11		
myNNSUR_86	0,28	-2,32		
myNNSUR_87	0,31	-0,61		
myNNSUR_88	0,23	-0,09		
myNNSUR_89	0,30	-0,04		
myNNSUR_90	0,31	-0,59		
myNNSUR_91	0,32	-0,35		
myNNSUR_92	0,33	0,12		
myNNSUR_93	0,32	-0,21		
myNNSUR_94	0,33	0,14		
myNNSUR_95	0,20	-13,85		
myNNSUR_96	0,27	-5,72		
myNNSUR_97	0,30	-0,79		
myNNSUR_98	0,32	-0,09		
myNNSUR_99	0,31	-3,56		
myNNSUR_100	0,32	0,14		
myNNSUR_101	0,31	-0,15		
myNNSUR_102	0,32	-0,12		
myNNSUR_103	0,30	-0,14		
myNNSUR_104	0,31	-0,20		
myNNSUR_105	0,31	-0,22		
myNNSUR_106	0,30	-0,25		
myNNSUR_107	0,32	-0,49		
myNNSUR_108	0,32	-0,38		
myNNSUR_109	0,32	0,19		
myNNSUR_110	0,31	0,05		
myNNSUR_111	0,32	-0,09		
myNNSUR_112	0,29	-0,28		
myNNSUR_113	0,31	-2,05		
myNNSUR_114	0,30	-0,27		
myNNSUR_115	0,31	-0,70		
myNNSUR_116	0,32	-0,53		
myNNSUR_117	0,31	-0,14		
myNNSUR_118	0,32	-0,44		
myNNSUR_119	0,31	-0,04		
myNNSUR_120	0,32	-1,29		
myNNSUR_121	0,29	-0,21		

myNNSUR_122	0,31	-1,45		
myNNSUR_123	0,32	-0,08		
myNNSUR_124	0,30	-2,56		
myNNSUR_125	0,32	-0,02		
myNNSUR_126	0,31	-0,06		
myNNSUR_127	0,32	0,32		
myNNSUR_128	0,32	-0,07		
myNNSUR_129	0,32	0,43		

Ομάδα Γ1	Denergy_final		Ομάδα Γ1	Denergy_final	
	εκπαίδευση	αξιολόγηση		εκπαίδευση	αξιολόγηση
myNNDenergy_final_1	0,93	0,76	myNNDenergy_final_26	-0,65	-1439,85
myNNDenergy_final_2	0,94	0,80	myNNDenergy_final_27	-659,57	-168,26
myNNDenergy_final_3	0,94	0,79	myNNDenergy_final_28	0,93	0,72
myNNDenergy_final_4	0,92	0,76	myNNDenergy_final_29	0,93	0,73
myNNDenergy_final_5	0,89	0,76	myNNDenergy_final_30	0,93	0,79
myNNDenergy_final_6	0,57	-7,80	myNNDenergy_final_31	0,95	0,84
myNNDenergy_final_7	0,93	0,77	myNNDenergy_final_32	0,91	0,70
myNNDenergy_final_8	0,94	0,76	myNNDenergy_final_33	0,96	0,90
myNNDenergy_final_9	0,92	0,75	myNNDenergy_final_34	0,96	0,90
myNNDenergy_final_10	0,76	-1,54	myNNDenergy_final_35	0,90	0,59
myNNDenergy_final_11	0,89	0,77	myNNDenergy_final_36	0,92	0,75
myNNDenergy_final_12	0,93	0,77	myNNDenergy_final_37	0,92	-66,82
myNNDenergy_final_13	0,88	0,76	myNNDenergy_final_38	0,88	0,31
myNNDenergy_final_14	0,93	0,79	myNNDenergy_final_39	0,93	0,51
myNNDenergy_final_15	0,94	0,79	myNNDenergy_final_40	-10,44	-9,69
myNNDenergy_final_16	0,82	-0,04	myNNDenergy_final_41	0,90	0,20
myNNDenergy_final_17	0,93	0,76	myNNDenergy_final_42	0,93	0,60
myNNDenergy_final_18	0,93	0,54	myNNDenergy_final_43	0,93	0,78
myNNDenergy_final_19	0,93	0,71	myNNDenergy_final_44	0,93	0,62
myNNDenergy_final_20	0,94	0,82	myNNDenergy_final_45	0,90	0,86
myNNDenergy_final_21	0,63	-1,69	myNNDenergy_final_46	0,92	0,49
myNNDenergy_final_22	0,75	-3,23	myNNDenergy_final_47	0,96	0,91
myNNDenergy_final_23	0,92	0,78	myNNDenergy_final_48	-450,95	-151,55
myNNDenergy_final_24	0,93	0,76	myNNDenergy_final_49	0,91	0,72
myNNDenergy_final_25	0,94	0,76	myNNDenergy_final_50	0,93	0,76


## Διαγράμματα αποτελεσμάτων νευρωνικών δικτύων για την ομάδα A του υβριδικού συστήματος


Για την ολική εκροή από τον ταμιευτήρα



Για την ολική εκροή από τη δεξαμενή

1<sup>η</sup> δομή





2<sup>η</sup> δομή

