

مدلسازی گیاه پالایی نمک در وتلندهای مصنوعی حاوی گیاهان شورزیست با استفاده از شبکه عصبی مصنوعی

ابوالفضل فرزی^{۱*}، سید مهدی برقهی^۲

^{۱*} - نویسنده مسئول، گروه مهندسی عمران، واحد اسفراین، دانشگاه آزاد اسلامی، اسفراین، ایران

^۲ - دانشکده مهندسی شیمی و نفت، دانشگاه صنعتی شریف، تهران، ایران

ایمیل نویسنده مسئول: farzi@iauesf.ac.ir شماره موبایل نویسنده مسئول: ۰۹۱۵۱۷۱۰۶۳۷

تاریخ پذیرش: ۹۸/۳/۱۱

تاریخ دریافت: ۹۸/۳/۴

چکیده

گیاه پالایی نمک از آبهای شور به عنوان یک روش طبیعی شوری زدایی در سالهای اخیر مورد توجه برخی محققین قرار گرفته است. بدین منظور از گیاهان شورزیست در وتلندهای مصنوعی استفاده می شود. با توجه به پیچیدگی پدیده های حاکم بر عملکرد وتلندهای مصنوعی، برای مدلسازی آنها را اغلب به صورت جعبه سیاه در نظر می گیرند. در این مقاله با این رویکرد، مدلسازی گیاه پالایی نمک در وتلند مصنوعی با استفاده از شبکه عصبی مصنوعی پرسپترون چند لایه انجام شد. لایه های ورودی و خروجی شبکه شامل پنج متغیر هدایت الکتریکی و غلظت یونهای کلسیم، منیزیم، سدیم و کلراید آب ورودی و خروجی وتلند مورد مطالعه بود. این داده ها که شامل ۲۴ سری بود با گزینش تصادفی به دو دسته داده های آموزش و آزمون تقسیم شد. شبکه های ۱ و ۲ لایه پنهان و تعداد مختلف نرون با استفاده از داده های آموزش، آموزش داده شدند و دو شبکه بهینه انتخاب گردید. شبکه های انتخاب شده با استفاده از داده های آزمایش شبیه سازی شدند. نتایج حاکی از آن بود که این دو شبکه با تقریب خوبی قادر به پیش بینی نتایج گیاه پالایی نمک در وتلند مصنوعی بودند.

کلمات کلیدی

"گیاه پالایی نمک"، "وتلند مصنوعی"، "شورزیست"، "شبکه عصبی"، "مدلسازی"

Modeling of salt phytoremediation in constructed wetlands containing halophytic plants using Artificial Neural Network

Abolfazl Farzi^{1,*}, Seyed Mehdi Borghei²

¹ Department of Civil Engineering, Esfarayen Branch, Islamic Azad University, Esfarayen, Iran

² Faculty of Chemical and Petroleum Engineering, Sharif University of Technology, Tehran, Iran

*Email Address: farzi@iauesf.ac.ir

*Mobile Phone: +989151710637

Abstract

Salt phytoremediation from saline waters has been considered by some researchers in recent years as a natural method of desalination. For this purpose, halophytic plants are used in constructed wetlands. Due to the complexity of the phenomena governing the performance and constructed wetlands, they are often considered as black boxes for modeling. In this paper, the modeling of salt phytoremediation in constructed wetlands was performed using a multi-layer perceptron artificial neural network. The input and output layers of the networks, included five variables of Electrical Conductivity and concentration of calcium, magnesium, sodium and chloride of the influent and effluent of the studied Constructed Wetland. The data of 24 series, was randomly divided into two categories of training and test data. The networks with 1, 2 hidden layers and different number of neurons were trained and two optimal networks were selected. Selected networks were simulated using experimental data. The results indicated that the two networks were able to predict the results of the salt phytoremediation in constructed wetlands with good approximation.

Keywords

"Salt Phytoremediation", "Constructed Wetlands", "Halophyte", "Artificial Neural Network", "Modelling"

۱- مقدمه

افزایش جمعیت جهان باعث افزایش نیاز به تولید غذا و توسعه کشاورزی گردیده است. پوشش دادن این نیاز به معنی نیاز بیشتر به آب و منابع جدید آب می باشد. با توجه به کمبود منابع آب برای این نیاز جهانی، امروزه توجه بشر به استفاده از منابع نامتعارف آب مانند آبها و فاضلابهای شور معطوف گشته است [۱]. استفاده از آبهای شور برای آبیاری باعث وقوع شوری ثانویه خاک [۲] و در نتیجه کاهش تولید کشاورزی و ضربه به کشاورزی پایدار خواهد بود [۳]. بنابراین روی آوردن به روشهای کاهش شوری آب برای استفاده در کشاورزی و سایر نیازها به عنوان یک ضرورت رخ می نماید. از سوی دیگر استفاده از روشهای رایج شوری زدایی مانند تقطیر و اسمز معکوس مستلزم مصرف انرژی بالا بوده و اقتصادی نمی باشد. لذا روی آوردن به تکنولوژی های ارزان و دوستدار محیط زیست مانند وتلند مصنوعی برای کاهش شوری آب، می تواند نویدبخش تحولی عظیم در این زمینه باشد [۴].

وتلندهای مصنوعی یک تکنولوژی طبیعی، کم هزینه و بیولوژیک برای تصفیه فاضلاب است که برگرفته از اکوسیستم تالاب های طبیعی بوده و امروزه به عنوان یک سیستم جایگزین بالقوه و یا به عنوان سیستم تکمیلی برای تصفیه فاضلاب در نظر گرفته می شود [۵]. استفاده از وتلندهای مصنوعی برای تصفیه فاضلابهای شور با تکیه و تمرکز بر حذف مواد مغذی از فاضلاب حاصل از مزارع پرورش ماهی و میگوی آب شور، فاضلاب برخی از صنایع مانند دباغی و فاضلاب شهری بعضی از مناطق که به عنوان فاضلاب های شور شناخته می شوند در تحقیقات مختلفی مورد مطالعه قرار گرفته است [۶-۹]. نکته قابل توجه در این میان این است که شوری فاضلاب در وتلند مصنوعی اثر بازدارندگی دارد [۱۰] بنابراین گیاهان معمول مورد استفاده در وتلندهای مصنوعی تحمل شرایط شوری بالا را نداشته و قابل کاربرد برای این منظور نیستند. بنابراین از وتلندهای مصنوعی کاشته شده با هالوفیتها برای این منظور استفاده می شود. هالوفیتها گیاهانی هستند که قادرند چرخه زندگی خود را در غلظت نمک حداقل ۲۰۰ Mm NaCl تحت شرایطی مشابه محیط زیست طبیعی تکمیل نمایند [۱۱].

گیاهان هالوفیتی از مکانیزمهای مختلفی برای مقاومت در برابر استفاده می کنند [۱۲] و از آن جمله مکانیزم جذب و اندوزش نمک در بافتها می باشد. این مکانیزم الهام بخش تعدادی از محققین برای مواجهه و یافت راه حلی طبیعی برای مساله

شور شدن زمینهای کشاورزی بوده است. این ایده ابتدا برای خارج سازی نمک از خاک های شور در برخی تحقیقات مورد مطالعه و آزمایش توسط گیاهان مختلف قرار گرفت [۱۳-۱۵]. در سال های اخیر نیز برای گیاه پالایی نمک از آبها و فاضلابهای شور توسط وتلندهای مصنوعی، توسط شلف و همکاران (۲۰۱۲) مطرح و با استفاده از گیاه هالوفیتی باسیا ایندیکا مورد آزمایش قرار گرفته است [۴] و در کارهای محققان دیگر ادامه یافته است [۱۶-۱۸].

هرچند تحقیقات مربوط به گیاه پالایی نمک در وتلندهای مصنوعی در ابتدای راه است ولی مدلسازی آن به عنوان یک پدیده طبیعی می تواند راهگشای تحقیقات بعدی باشد. از دیدگاه مدلسازی، رفتار وتلندهای مصنوعی در تصفیه فاضلاب، اغلب به صورت یک جعبه سیاه ملاحظه گردیده است [۱۹]. فهم جزئی شده از عملکرد وتلند هنوز به عنوان یک امر مطلوب در حال پیگیری است، چون تعداد زیادی از فرایندهای فیزیکی، شیمیایی و بیولوژیکی به طور موازی در وتلند اتفاق افتاده و همدیگر را تحت تاثیر قرار می دهند. مدل های موجود در این ارتباط به دو گروه کلی ۱- مدل های جعبه سیاه و ۲- مدل های مبتنی بر فرایند قابل تقسیم بندی می باشند. مدل های جعبه سیاه شامل مدل های رگرسیون، مدل های مرتبه اول، مدل تاخیری وابسته به زمان، مدل تانکهای سری، مدل های موند، مدل های شبکه عصبی و رهیافتهای آماری می باشند و مدل های مبتنی بر فرایند شامل مدل های Fitovert، مدل دو بعدی وتلند مصنوعی، Stella، Phwat، مدل دو بعدی مکانیتیک و Cwm1 می باشد [۱۹].

در میان مدل های جعبه سیاه، شبکه عصبی مصنوعی یک ابزار قدرتمند برای شبیه سازی فرایندهای غیر خطی پیچیده از قبیل پدیده های زیست محیطی است [۲۰]. شبکه های عصبی مصنوعی کارایی خود را در مدل های مختلف زیست محیطی، از جمله پیش بینی و مدلسازی آلودگیهای زیست محیطی از قبیل منابع آب سطحی و زیرزمینی [۲۱-۲۳] و آلودگی هوا [۲۴] نشان داده اند. همچنین، شبکه های عصبی مصنوعی با موفقیت در مسائل مختلف مربوط به هیدرولوژی استفاده شده اند [۲۵، ۲۶]. در زمینه مدلسازی روشهای مختلف تصفیه آب و فاضلاب نیز استفاده از شبکه های عصبی مصنوعی به ابزاری رایج تبدیل گشته است [۲۷-۳۰].

در زمینه مدلسازی وتلندهای مصنوعی با استفاده از شبکه های عصبی مصنوعی نیز تحقیقاتی انجام شده است که می توان در این قسمت به برخی از تحقیقاتی که از این روش برای مدلسازی وتلند مصنوعی استفاده کرده اند، اشاره کرد. تومنکو و

خروجی از آن بود. بدین ترتیب داده های ورودی و خروجی اندازه گیری شده شامل ۲۴ سری از ۵ متغیر مورد مطالعه بود. برای مدل سازی، از شبکه عصبی مصنوعی پرسپترون چند لایه (MLP) استفاده شد. داده های ورودی و خروجی مورد استفاده در مدل شبکه عصبی، در واقع همان مشخصه های اندازه گیری شده در مطالعه تجربی بود. بدین ترتیب لایه های ورودی و خروجی شبکه همانطور که در شکل ۱ مشاهده می شود، شامل ۵ متغیر فوق الذکر می باشد. با توجه به اینکه داده های ورودی و خروجی شبکه محدوده های متفاوتی را شامل می شدند؛ به منظور کاهش خطای مدل سازی، داده های ورودی و خروجی شبکه با استفاده از رابطه زیر به بازه صفر و یک نرمال سازی شدند.

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

که در آن x_{normal} مقدار داده نرمال شده، x مقدار داده خام، x_{min} حداقل مقدار داده ها و x_{max} حداکثر مقدار داده ها هستند.

داده های مورد استفاده که شامل ۲۴ سری داده بودند به دو گروه داده های آموزش (۷۵ درصد معادل ۱۸ سری) و آزمایش (۲۵ درصد معادل ۶ سری) تقسیم شدند. به منظور تضمین کیفیت آموزش، داده های آموزش و تست به صورت تصادفی انتخاب شدند. شبکه مورد استفاده از نوع پرسپترون چند لایه پیشرو با انتشار برگشتی بود. برای آموزش شبکه از الگوریتم TRAINLM استفاده شد. تابع تحریک لایه های میانی تانژانت سیگموئید و لایه خروجی خطی بود. تابع عملکرد خطا MSE و الگوریتم خطایابی انتشار برگشتی و تابع بهینه سازی لورنبرگ-مارکواردت بود.

برای دستیابی به معماری مناسب شبکه، شبکه های مختلف با تعداد ۱ و ۲ لایه پنهان و با تعداد نرونهای مختلف ساخته و آموزش داده شدند. برای این منظور ابتدا شبکه با یک لایه پنهان با تعداد نرونهای بین ۵ تا ۱۵ ساخته و آموزش داده شد. سپس شبکه با دو لایه پنهان در نظر گرفته شد. در شبکه با دو لایه پنهان به دلیل تعدد حالتها، برای اولین لایه پنهان سه حالت با تعداد نرونهای ۵، ۱۰ و ۱۵ انتخاب و تعداد نرونهای لایه پنهان دوم بین ۵ تا ۱۵ در هر حالت تغییر داده شد. این شبکه ها نیز آموزش داده شدند تا شبکه بهینه به دست آید. مبنای انتخاب شبکه بهینه، تابع عملکرد خطا (MSE) کمتر و رگرسیون (R) بالاتر بود.

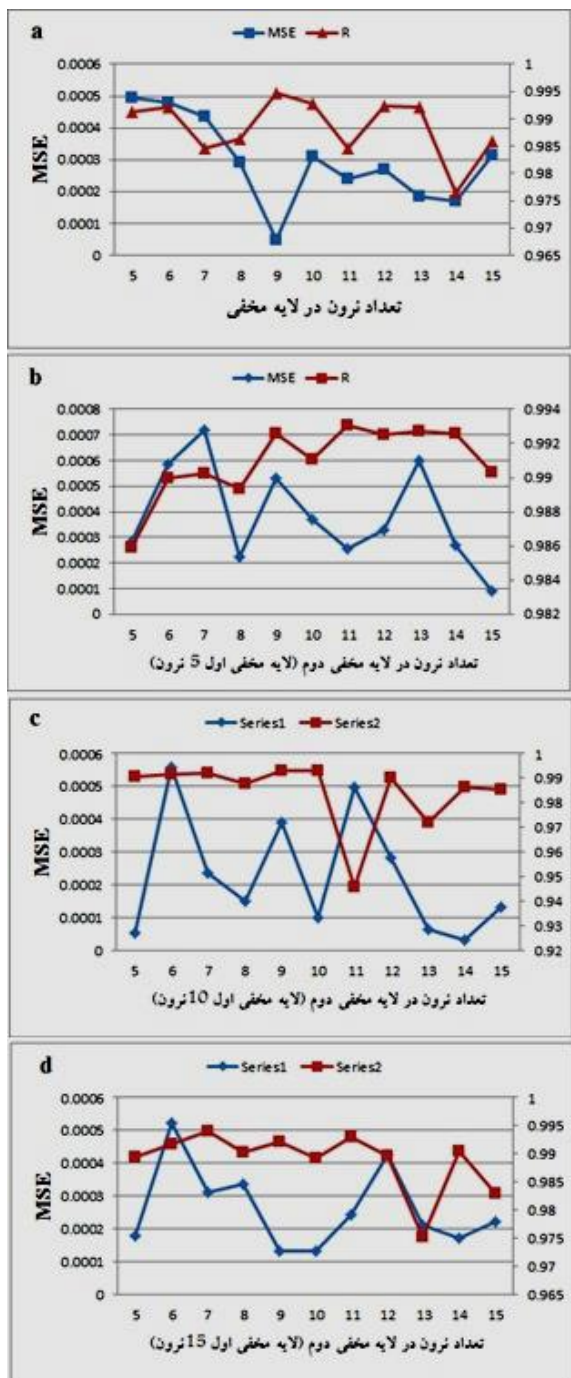
همکاران (۲۰۰۷) با استفاده از آنالیز رگرسیون چندگانه (MRA) و شبکه های عصبی مصنوعی پرسپترون چند لایه (MLP) و تابع پایه شعاعی (RBF) غلظت اکسیژن مورد نیاز بیوشیمیایی (BOD) را در پساب خروجی و نقاط میانی وتلند مصنوعی جریان زیر سطحی پیش بینی کردند [۳۱]. آکراتوس و همکاران (۲۰۰۹) به بررسی قابلیت شبکه های عصبی مصنوعی (ANNs) در پیش بینی حذف نیترژن در وتلند مصنوعی جریان زیر سطحی افقی پرداختند [۳۲]. لی و همکاران (۲۰۱۴) با استفاده از آنالیز رگرسیون چندگانه و شبکه های عصبی مصنوعی پرسپترون چند لایه و تابع پایه شعاعی، راندمان تصفیه فسفر کل (TP) را در وتلند مصنوعی جریان زیر سطحی افقی مدل کردند [۳۳]. همامین و همکاران (۲۰۱۴) با استفاده از سیستم استنتاج عصبی-فازی تطبیقی (ANFIS) به مدل سازی حذف اشریشیاکلی در وتلند مصنوعی تحت بارگذاری پالسی پرداختند [۳۴]. سونگ و همکاران (۲۰۱۳)، از شبکه عصبی مصنوعی برای شبیه سازی نرخ دینیتریفیکاسیون در وتلندهای مصنوعی پرداختند [۳۵]. همچنین چانگ و همکاران (۲۰۱۵) نیز به پیش بینی رژیم جریان در وتلندهای مصنوعی به منظور کنترل آلودگی آب باران با استفاده از شبکه های عصبی مصنوعی پرداختند [۳۶].

در این مقاله، با استفاده از شبکه های عصبی مصنوعی پرسپترون چند لایه، عملکرد وتلندهای مصنوعی حاوی گیاه هالوفیتی سالیکورنیا اروپایی از نظر گیاه پالایی نمک از آبهای شور مدل سازی شده است.

۲- روش انجام تحقیق


داده های مورد استفاده برای مدل سازی فرایند گیاه پالایی نمک در وتلندهای مصنوعی حاوی گیاه هالوفیت در این تحقیق از ست آپ آزمایشگاهی مربوط به تحقیق قبلی نویسنندگان اخذ شده است [۱۷]. با توجه به این که در تحقیق تجربی مذکور، گیاه سالیکورنیا اروپایی به نسبت دو گیاه دیگر، نتایج بهتری از خود نشان داد، در این مقاله کار مدل سازی با داده های مربوط به این گیاه انجام شده است.

در مطالعه تجربی مذکور، گیاه سالیکورنیا اروپایی در وتلندهای آزمایشگاهی از جنس پلی اتیلن حاوی ماسه کاشته شد. آزمایشها در سه سطح شوری مختلف و با زمان ماند یک هفته ای به مدت ۸ هفته انجام گردید و مشخصات آب ورودی و خروجی اندازه گیری شد. این مشخصات شامل هدایت الکتریکی و غلظت یونهای کلسیم، منیزیم، سدیم و کلراید در آب ورودی به وتلند و



شکل ۲- خلاصه نتایج بهترین شبکه های ساخته شده. (a) شبکه با یک لایه پنهان (b) شبکه با دو لایه پنهان و لایه پنهان اول با ۵ نرون (c) شبکه با دو لایه پنهان و لایه پنهان اول با ۱۰ نرون (d) شبکه با دو لایه پنهان و لایه پنهان اول با ۱۵ نرون. محور عمودی سمت راست در همه نمودارها نشانگر ضریب همبستگی (R) هستند.

در شبکه با دو لایه پنهان به دلیل تعدد حالتها، برای اولین لایه پنهان سه حالت با تعداد نرونهای ۵، ۱۰ و ۱۵ انتخاب و تعداد نرونهای لایه پنهان دوم بین ۵ تا ۱۵ در هر حالت تغییر داده شد (قسمت b تا d شکل ۲). همانطور که مشاهده می شود، افزایش تعداد لایه های پنهان بهبود قابل ملاحظه ای در نتایج ایجاد نمی کند. با این حال، شبکه با دو لایه پنهان و هر لایه



شکل ۱- ساختار نمونه شبکه عصبی پرسپترون چند لایه مورد استفاده

شبکه های انتخاب شده با استفاده از داده های آموزش، آموزش داده شده و پس از آن با استفاده از داده های آزمایش، شبیه سازی گردیدند تا کارایی شبکه تعیین گردد. بدین منظور داده های مشاهده با داده های حاصل از شبیه سازی با شبکه های منتخب با یکدیگر مقایسه شدند. برای بررسی میزان مطابقت داده های مشاهده و شبیه سازی از آماره ناش- ساتکلیف استفاده شد. این آماره که عمدتاً در ارزیابی مدل های هیدرولوژیکی کار برد دارد، با رابطه زیر تعریف می شود [۳۷]:

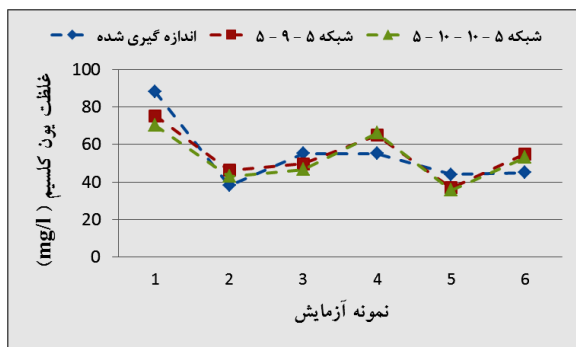
$$NSE = 1 - \frac{\sum_{i=1}^n (x_{s,i} - x_{o,i})^2}{\sum_{i=1}^n (x_{o,i} - \mu_o)^2}$$

که در آن $x_{s,i}$ مقادیر برآورد شده متغیر، $x_{o,i}$ مقادیر مشاهداتی، n تعداد نمونه ها و μ_o میانگین داده های مشاهداتی است. NSE بدون بعد بوده و به یک ختم می شود (از منفی بینهایت تا ۱، به طوری که عدد ۱ مربوط به مدلی است که کاملاً با واقعیت مطابقت دارد).

۳- نتایج

۳-۱- معماری شبکه


برای دستیابی به معماری مناسب شبکه، همانطور که گفته شد شبکه های با تعداد ۱ و ۲ لایه پنهان با تعداد نرونهای مختلف ساخته و آموزش داده شدند. خلاصه نتایج شبکه های با معماری های مختلف ساخته شده در شکل ۲ منعکس گردیده است. ابتدا شبکه با یک لایه پنهان با تعداد نرونهای بین ۵ تا ۱۵ ساخته و آموزش داده شد (قسمت a شکل ۲). مشاهده می شود که در بین این شبکه ها، شبکه با ۹ نرون در لایه پنهان، نتایج بهتری دارد.



شکل 4- مقایسه نتایج شبیه سازی پارامتر غلظت کلسیم برای نمونه های آزمایش



شکل 5- مقایسه نتایج شبیه سازی پارامتر غلظت منیزیم برای نمونه های آزمایش



شکل 6- مقایسه نتایج شبیه سازی پارامتر غلظت سدیم برای نمونه های آزمایش


برای بررسی کمی تطابق مقادیر برآورد شده توسط شبکه عصبی و مقادیر مشاهده شده از آماره ناش ساتکلیف استفاده شد. مقادیر این آماره در مورد دو شبکه مورد استفاده برای هر کدام از متغیرهای مدل در جدول (۱) آورده شده است. همانطور که در این جدول دیده می شود، مقادیر آماره مذکور در مورد هر دو شبکه برای تمام متغیرها بین ۰.۵ تا ۱ است. کیفیت این مقادیر و در نتیجه کیفیت تطابق مقادیر پیش بینی شده توسط مدل های شبکه عصبی با مقادیر اندازه گیری شده، با توجه به رتبه بندی کیفی کارایی ارائه شده در مراجع [۳۷]، به صورت جدول (۲) تنظیم شده است. این جدول نشان می دهد که هر دو معماری

دارای ۱۰ نرون، نتایجی نزدیک به حالت بهینه شبکه با یک لایه پنهان (۹ نرون در لایه پنهان) دارد. بنابراین این دو شبکه یعنی شبکه با یک لایه پنهان دارای ۹ نرون که به اختصار آن را ۵-۹-۵ و شبکه با دو لایه پنهان هر کدام دارای ۱۰ نرون که آن را هم به اختصار ۵-۱۰-۵ می نامیم، انتخاب و برای شبیه سازی استفاده شد.

۳-۲- شبیه سازی شبکه

با توجه به نتایج بهتر دو شبکه ۵-۹-۵ و ۵-۱۰-۵، از این دو شبکه برای شبیه سازی استفاده شد. شبیه سازی، با استفاده از داده های ورودی آزمایش (۶ سری داده ورودی از ۲۴ سری که به صورت تصادفی برای آزمایش شبکه، جدا شده بود) انجام گردید. شبکه که با استفاده از داده های آموزش، آموزش دیده است با دریافت داده های تست، به عنوان ورودی، داده های خروجی نظیر را محاسبه و ارائه می کند.

مقایسه داده های خروجی حاصل از شبکه با داده های خروجی اندازه گیری شده (خروجی های داده های آزمایش)، نشان خواهد داد که آیا شبکه در مدلسازی پدیده کاهش شوری در وتلند مصنوعی به نحو مناسبی عمل کرده است یا نه. این مقایسه برای پارامتر هدایت الکتریکی در شکل ۳ و برای غلظت یونهای کلسیم، منیزیم، سدیم و کلراید در شکل ۴ آورده شده است که نشان می دهد هر دو شبکه انتخاب شده توانایی خوبی در تخمین نتایج مناسب برای پارامترهای خروجی دارند. هرچند که به نظر می رسد این تطابق در مورد پارامترهای هدایت الکتریکی و غلظت یونهای سدیم و کلر به نسبت دو پارامتر دیگر یعنی غلظت یونهای کلسیم و منیزیم، بیشتر است.



شکل ۳- مقایسه نتایج شبیه سازی پارامتر هدایت الکتریکی برای نمونه های آزمایش



شکل ۷- مقایسه نتایج شبیه سازی پارامتر غلظت کلراید برای نمونه های آزمایش

شبکه عصبی انتخاب شده در پیش بینی EC عملکرد خوب، در پیش بینی غلظت یونهای سدیم و کلراید عملکرد خیلی خوب داشته اند. همچنین عملکرد شبکه ۵-۹-۵ در پیش بینی غلظت یونهای کلسیم و منیزیم، خوب و عملکرد شبکه ۵-۱۰-۱۰-۵ در مورد این دو یون رضایت بخش بوده است.

جدول ۱) مقادیر آماره ناش- ساتکلیف برای متغیرهای مختلف و دو معماری شبکه

متغیرهای شبکه					معماری شبکه
Cl	Na	Mg	Ca	EC	
0.791	0.835	0.676	0.685	0.750	5-9-5
0.774	0.863	0.640	0.578	0.693	5-10-10-5

جدول ۲) تفسیر مقادیر آماره ناش- ساتکلیف برای متغیرهای مختلف و دو معماری شبکه

متغیرهای شبکه					معماری شبکه
Cl	Na	Mg	Ca	EC	
خیلی خوب	خیلی خوب	خوب	خوب	خوب	5-9-5
خیلی خوب	خیلی خوب	رضایت بخش	رضایت بخش	خوب	5-10-10-5

دو شبکه بهینه انتخاب گردید. یکی از این دو شبکه، شبکه با یک لایه پنهان متشکل از ۹ نرون و دیگری شبکه با دو لایه پنهان که هر کدام متشکل از ۱۰ نرون بودند. شبکه های انتخاب شده با استفاده از داده های آزمایش شبیه سازی شدند. برای مقایسه نتایج شبیه سازی با نتایج تجربی آماره ناش ساتکلیف برای دو شبکه انتخاب شده و برای متغیرهای مدل محاسبه و تفسیر شد. نتایج حاکی از آن بود که هر دو معماری شبکه عصبی انتخاب شده در پیش بینی EC عملکرد خوب، در پیش بینی غلظت یونهای سدیم و کلراید عملکرد خیلی خوب داشته اند. همچنین عملکرد شبکه ۵-۹-۵ در پیش بینی غلظت یونهای کلسیم و منیزیم، خوب و عملکرد شبکه ۵-۱۰-۱۰-۵ در مورد این دو یون رضایت بخش بوده است.

۴- نتیجه گیری

مدلسازی گیاه پالایی نمک در وتلند مصنوعی با استفاده از شبکه عصبی مصنوعی پرسپترون چند لایه انجام شد. داده های تجربی مورد نیاز برای مدلسازی با استفاده از نتایج تحقیق قبلی نویسندگان تامین شد. بنابراین متغیرهای ورودی و خروجی شبکه شامل هدایت الکتریکی و غلظت یونهای کلسیم، منیزیم، سدیم و کلر در آب ورودی به و خروجی از وتلندهای مصنوعی مورد استفاده در آزمایشها بود. این داده ها که شامل ۲۴ سری بود به طور تصادفی به دو دسته آموزش (۷۵ درصد) و آزمایش (۲۵ درصد) تقسیم شدند. برای مدلسازی شبکه های عصبی پرسپترون چند لایه با ۱ و ۲ لایه میانی و تعداد مختلف نرون ساخته شده و با استفاده از داده های آموزش، آموزش داده شد و

منابع

1. Waughray, D., Water Security: The Water–Food–Energy–Climate Nexus: The World Economic Forum Water Initiative. 2011, Island Press: Washington, DC : USA.
2. Zhou, D., et al., Assessing secondary soil salinization risk based on the PSR sustainability framework. *Journal of environmental management*, 2013. 128: p. 642-654.
3. Hillel, D., Salinity management for sustainable irrigation: integrating science, environment and economics. 2000, Washington, D.C., USA: World Bank Publications.
4. Shelef, O., A. Gross, and S. Rachmilevitch, The use of *Bassia indica* for salt phytoremediation in constructed wetlands. *Water Research* 2012. 46: p. 3967-3976.
5. UN-HABITAT, *Constructed Wetlands Manual 2008*, UN-HABITAT Water for Asian Cities Programme Nepal, Kathmandu.
6. Klomjek, P. and S. Nitorisavut, Constructed treatment wetland: a study of eight plant species under saline conditions. *Chemosphere* 2005. 58 p. 585–593.
7. Calheiros, C.S.C., et al., Use of constructed wetland systems with *Arundo* and *Sarcocornia* for polishing high salinity tannery wastewater. *Journal of Environmental Management* 2012. 95 p. 66-71.
8. Buhmann, A.K., et al., Optimization of culturing conditions and selection of species for use of halophytes as biofilter for nutrient-rich saline water. *Agricultural Water Management* 2015. 149 p. 102–114.
9. Webb, J.M., et al., Halophyte filter beds for treatment of saline wastewater from aquaculture. *Water Research* 2012 46: p. 5102-5114.
10. Nitorisavut, S. and P. Klomjek, Inhibition kinetics of salt-affected wetland for municipal wastewater treatment. *Water Research* 2005. 39 p. 4413–4419.
11. Flowers, T.J., M.A. Hajibagheri, and N.J.W. Clipson, Halophytes. *The Quarterly Review of Biology*, 1986. 61(3): p. 313-337.
12. Basra, A., *Mechanisms of environmental stress resistance in plants*. 1997: CRC Press.
13. KE-FU, Z., Desalination of saline soils by *Suaeda salsa*. *Plant and Soil*, 1991. 135: p. 303-305.
14. Hamidov, A., et al. Remediation of Saline Soils using *Apocynum Lancifolium* and *Chenopodium Album*. in the 3rd IASME/WSEAS Int. Conf. on Energy, Environment, Ecosystems and Sustainable Development. 2007. Greece.
15. Rabhi, M., et al., Phytodesalination of a salt-affected soil with the halophyte *Sesuvium portulacastrum* L. to arrange in advance the requirements for the successful growth of a glycophytic crop. *Bioresource Technology*, 2010. 101 p. 6822–6828.
16. Freedman, A., et al., Salt uptake and evapotranspiration under arid conditions in horizontal subsurface flow constructed wetland planted with halophytes. *Ecological Engineering*, 2014. 70: p. 282-286.
17. Farzi, A., S.M. Borghei, and M. Vossoughi, The Use of Halophytic Plants for Salt Phytoremediation in Constructed Wetlands. *International Journal of Phytoremediation*, 2017(just-accepted): p. 00-00.
19. Kumar, J. and Y. Zhao, A review on numerous modeling approaches for effective, economical and ecological treatment wetlands. *Journal of Environmental Management*, 2011. 92(3): p. 400-406.
20. Lek, S. and J.-F. Guégan, Artificial neural networks as a tool in ecological modelling, an introduction. *Ecological Modelling*, 1999. 120(2-3): p. 65-73.
21. Ostad-Ali-Askari, K., M. Shayannejad, and H. Ghorbanizadeh-Kharazi, Artificial neural network for modeling nitrate pollution of groundwater in marginal area of Zayandeh-rood River, Isfahan, Iran. *KSCE Journal of Civil Engineering*, 2017. 21(1): p. 134-140.
22. Sarkar, A. and P. Pandey, River water quality modelling using artificial neural network technique. *Aquatic Procedia*, 2015. 4: p. 1070-1077.
23. Keskin, T.E., M. Dügenci, and F. Kaçaroğlu, Prediction of water pollution sources using artificial neural networks in the study areas of Sivas, Karabük and Bartın (Turkey). *Environmental Earth Sciences*, 2015. 73(9): p. 5333-5347.
24. Azid, A., et al., Prediction of the level of air pollution using principal component analysis and artificial neural network techniques: A case study in Malaysia. *Water, Air, & Soil Pollution*, 2014. 225(8): p. 2063.
25. Senthil Kumar, A., et al., Rainfall-runoff modelling using artificial neural networks: comparison of network types. *Hydrological Processes*, 2005. 19(6): p. 1277-1291.
26. Deo, R.C. and M. Şahin, Application of the artificial neural network model for prediction of monthly standardized precipitation and evapotranspiration index using hydrometeorological parameters and climate indices in eastern Australia. *Atmospheric Research*, 2015. 161: p. 65-81.

27. Dogan, E., et al., Application of artificial neural networks to estimate wastewater treatment plant inlet biochemical oxygen demand. *Environmental Progress & Sustainable Energy*, 2008. 27(4): p. 439-446.
28. Khataee, A.R. and M.B. Kasiri, Modeling of biological water and wastewater treatment processes using artificial neural networks. *CLEAN-Soil, Air, Water*, 2011. 39(8): p. 742-749.
29. López, M.E., et al., Modelling the removal of volatile pollutants under transient conditions in a two-stage bioreactor using artificial neural networks. *Journal of hazardous materials*, 2017. 324: p. 100-109.
30. Pendashteh, A.R., et al., Modeling of membrane bioreactor treating hypersaline oily wastewater by artificial neural network. *Journal of hazardous materials*, 2011. 192(2): p. 568-575.
31. Tomenko, V., S. Ahmed, and V. Popov, Modelling constructed wetland treatment system performance. *ecological modelling*, 2007. 205(3): p. 355-364.
32. Akrotos, C.S., J.N. Papaspyros, and V.A. Tsihrintzis, Total nitrogen and ammonia removal prediction in horizontal subsurface flow constructed wetlands: use of artificial neural networks and development of a design equation. *Bioresource technology*, 2009. 100(2): p. 586-596.
33. Li, W., et al., Statistical modeling of phosphorus removal in horizontal subsurface constructed wetland. *Wetlands*, 2014. 34(3): p. 427-437.
34. Hamaamin, Y.A., et al., Modeling *Escherichia coli* removal in constructed wetlands under pulse loading. *Water research*, 2014. 50: p. 441-454.
35. Song, K., et al., The application of Artificial Neural Network (ANN) model to the simulation of denitrification rates in mesocosm-scale wetlands. *Ecological informatics*, 2013. 16: p. 10-16.
36. Chang, N.-B., et al., Diagnosis of the artificial intelligence-based predictions of flow regime in a constructed wetland for stormwater pollution control. *Ecological informatics*, 2015. 28: p. 42-60.
37. Moriasi, D.N., et al., Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Transactions of the ASABE*, 2007. 50(3): p. 885-900.