

УДК 681.518.25

DOI: 10.18698/2542-1468-2018-1-31-35

НЕЙРОНЕЧЕТКАЯ МОДЕЛЬ ДЛЯ ПРОГНОЗА СЕМЕНОШЕНИЯ ЛЕСНЫХ КУЛЬТУР В УСЛОВИЯХ ТЕХНОГЕННЫХ ЛАНДШАФТОВ

О.М. Полещук, С.Б. Васильев

МГТУ им. Н.Э. Баумана (Мытищинский филиал), 141005, Московская область, г. Мытищи, ул. 1-я Институтская, д. 1
poleshchuk@mgul.ac.ru

Разработана нейронечеткая модель для прогноза семеношения лесных культур в условиях техногенных ландшафтов на примере семеношения сосны Банка на рекультивационных ландшафтах Егорьевского месторождения фосфоритов. Выбор нейронечеткой модели является оправданным, поскольку стандартные методы прогноза не дают удовлетворительных результатов и не позволяют учесть неполноту и нечеткость исходной информации. Проведен сравнительный анализ классических регрессионных моделей, нейронных сетей и разработанной нейронечеткой модели, который показал эффективность и адекватность нейронечеткой модели.

Ключевые слова: экспертная информация, лингвистическая переменная, функция принадлежности, нейронечеткая модель, семеношение в условиях техногенных ландшафтов

Ссылка для цитирования: Полещук О.М., Васильев С.Б. Нейронечеткая модель для прогноза семеношения лесных культур в условиях техногенных ландшафтов // Лесной вестник / Forestry Bulletin, 2018. Т. 22. № 1. С. 31–35. DOI: 10.18698/2542-1468-2018-1-31-35

Для использования в хозяйстве нарушенных земель и предотвращения вредного влияния их на окружающую среду проводится рекультивация, под которой понимают искусственное восстановление земель и растительного покрова после техногенного нарушения ландшафта. Мировой опыт по рекультивации земель насчитывает приблизительно 90 лет. Первые работы по рекультивации земель были проведены в 1926 г. на участках, нарушенных горными работами (США, штат Индиана). Наиболее перспективным видом преобразования техногенных ландшафтов, как правило, является лесная рекультивация земель, которая занимает более 75 % общего объема рекультивации. Введение в искусственные лесные насаждения ценных интродуцированных пород имеет существенное лесоэкологическое значение. Расширяются ареалы ценных лесообразователей, увеличивается породное разнообразие насаждений, повышаются возможности их функционального использования.

Общеизвестна многогранная роль лесов в стабилизации природных процессов и регулировании их интенсивности. Леса, создаваемые на нарушенных землях, очень важны в масштабах экономики и общества, поскольку имеют лесохозяйственно-сырьевое назначение, выполняют почвозащитную, водоохранную и рекреационную функции, играют большую роль в улучшении санитарно-гигиенических условий окружающей среды.

К основным причинам, сдерживающим процесс интродукции, следует отнести отсутствие региональных семенных баз, создание которых невозможно без анализа результатов первичного испытания древесных растений, прогноза семен-

ной продуктивности и качества семян по результатам этих испытаний. В большинстве областей Российской Федерации нет ни продуцирующих постоянных лесосеменных участков ни, тем более, лесосеменных плантаций. Из-за отсутствия семян их заготовка иногда ведется даже в городских посадках. Таким образом, проблема создания семенной базы лесных пород, используемых для рекультивации техногенных ландшафтов в зависимости от их специфики, крайне актуальна.

Не менее актуальна проблема обработки данных и получения адекватных результатов, которые являются основополагающими в задачах принятия решений по использованию лесных культур в процессах интродукции. Необходимо проводить анализ и прогноз семеношения лесных пород, осуществлять мониторинг их жизнеспособности, а также принимать обоснованные решения с учетом особенностей техногенных ландшафтов [1].

Следует отметить специфику и сложность рассматриваемой проблемной области. Это связано с наличием: нечеткости (размытости) определения ряда характеристик; случайного фактора в их оценке; неопределенности в рассматриваемых условиях и целях; субъективной составляющей в поступающей экспертной информации, которую необходимо учитывать. Все это в совокупности приводит к тому, что традиционно используемые методы классического регрессионного анализа не позволяют решать задачи анализа и прогноза данных семеношения с целью получения адекватных конечных результатов и выработки эффективных управленческих решений [2].

С целью устранения недостатков методов классического регрессионного анализа с середи-

ны 90-х гг. XX в. стали применять прогнозные модели с использованием нечеткой логики и нейронных сетей. Технологии искусственного интеллекта, созданные с помощью методов нечеткой логики и нейронных сетей, получили название нейронечетких технологий. Стремление объединить нечеткую логику и нейронные сети вызвано желанием преодолеть ограничения, присущие каждому из методов в отдельности. В основе нейронечетких сетей лежит аппарат нечеткой логики, на базе которого делаются окончательные выводы, а соответствующие функции принадлежности настраиваются на базе алгоритмов обучения нейронных сетей, например алгоритма обратного распространения ошибки или метода рекуррентного спуска.

Основные понятия

Нейроном в информатике называют вычислительную единицу, которая получает информацию, производит над ней простые вычисления и передает ее дальше. Нейроны подразделяют на три типа: входные, скрытые и выходные. У каждого из нейронов есть два основных параметра: входные данные и выходные данные. Синапсом называют связь между двумя нейронами. У синапсов параметром является вес. При инициализации вес нейронов расставляется случайно. Выходная информация для нейрона — сумма всех входных данных, умноженных на соответствующие веса [2].

Нечетким множеством A [3] называется множество пар вида $\{(x, \mu_{\tilde{A}}(x)) : x \in X\}$, где $\mu_{\tilde{A}}(x) : X \rightarrow [0, 1]$.

Нечетким числом \tilde{A} называется нечеткое множество [3], имеющее функцию принадлежности $\mu_{\tilde{A}}(x) : R \rightarrow [0, 1]$.

Лингвистической переменной [4] называется пятерка

$$\{X, T(X), U, V, S\},$$

где X — название переменной;

$T(X) = \{X_i, i = \overline{1, m}\}$ — терм-множество переменной X , т. е. множество термов, или названий, лингвистических значений переменной X (каждое из этих значений — нечеткая переменная со значениями из универсального множества U);

V — синтаксическое правило, порождающее названия значений лингвистической переменной X ;

S — семантическое правило, которое ставит в соответствие каждой нечеткой переменной с названием из $T(X)$ нечеткое подмножество универсального множества U .

Рассмотрим нейронечеткую сеть, которая называется адаптивной нейронечеткой системой вывода (ANFIS). Эта сеть состоит из пяти слоев. Опишем кратко функции каждого слоя.

Первый слой — входные нейроны, которые представляют собой числовые значения определенных термов лингвистических переменных. Узлами первого слоя являются функции принадлежности этих лингвистических переменных. Число узлов первого слоя соответствует числу термов входных лингвистических переменных. Выходом каждого узла является степень принадлежности числового входного значения к определенному терму лингвистических переменных. Первый слой называется слоем фаззификации входных данных.

Второй слой — входные нейроны, которые представляют собой значения функций принадлежности лингвистических переменных. Узлами второго слоя являются нечеткие правила. Число узлов соответствует числу нечетких правил. Каждый узел отвечает за одно правило. Нейроны второго слоя связаны только с теми нейронами первого слоя, которые входят в это правило.

Третий слой — входные нейроны, реализовавшие нечеткие правила узлов второго слоя. Узлами третьего слоя являются операции треугольной нормы (T -нормы). Частным случаем этой операции является, например, широко используемая операция взятия минимума, или умножения. Число узлов третьего слоя равно числу строк — конъюнкций (логическая операция «И») в системе нечетких правил. Выходными нейронами третьего слоя являются результаты операций T -нормы.

Треугольной нормой, или T -нормой, называется действительная двухместная функция $T : [0, 1] \times [0, 1] \rightarrow [0, 1]$, удовлетворяющая следующим условиям [5]:

- 1) $T(0, 0) = 0, T(\mu_{\tilde{A}}, 1) = T(1, \mu_{\tilde{A}}) = \mu_{\tilde{A}}$ (ограниченность);
- 2) $T(\mu_{\tilde{A}}, \mu_{\tilde{B}}) \leq T(\mu_{\tilde{C}}, \mu_{\tilde{D}})$, если $\mu_{\tilde{A}} \leq \mu_{\tilde{C}}, \mu_{\tilde{B}} \leq \mu_{\tilde{D}}$ (монотонность);
- 3) $T(\mu_{\tilde{A}}, \mu_{\tilde{B}}) = T(\mu_{\tilde{B}}, \mu_{\tilde{A}})$ (коммутативность);
- 4) $T(\mu_{\tilde{A}}, T(\mu_{\tilde{B}}, \mu_{\tilde{C}})) = T(T(\mu_{\tilde{A}}, \mu_{\tilde{B}}), \mu_{\tilde{C}})$ (ассоциативность).

Четвертый слой — входные нейроны после выполнения операции треугольной нормы третьего слоя. Узлами четвертого слоя являются операции треугольной конормы. Частным случаем этой операции является, например, широко используемая операция взятия максимума, или сложения. Число узлов четвертого слоя соответствует числу лингвистических термов выходной переменной.

Треугольной конормой называется действительная двухместная функция $K : [0, 1] \times [0, 1] \rightarrow [0, 1]$, удовлетворяющая следующим условиям [6]:

- 1) $K(0, 0) = 0, K(\mu_{\tilde{A}}, 0) = K(0, \mu_{\tilde{A}}) = \mu_{\tilde{A}}$ (ограниченность);
- 2) $K(\mu_{\tilde{A}}, \mu_{\tilde{B}}) \leq K(\mu_{\tilde{C}}, \mu_{\tilde{D}})$, если $\mu_{\tilde{A}} \leq \mu_{\tilde{C}}, \mu_{\tilde{B}} \leq \mu_{\tilde{D}}$ (монотонность);

3) $K(\mu_{\bar{A}}, \mu_{\bar{B}}) = K(\mu_{\bar{B}}, \mu_{\bar{A}})$ (коммутативность);

4) $K(\mu_{\bar{A}}, K(\mu_{\bar{B}}, \mu_{\bar{C}})) = K(K(\mu_{\bar{A}}, \mu_{\bar{B}}), \mu_{\bar{C}})$ (ассоциативность).

Пятый слой суммирует вклад каждого правила и находит четкое выходное значение. Пятый слой называется слоем дефаззификации.

Цель работы

Настоящая работа посвящена изучению вопроса семеношения сосны Банкса на рекультивационных ландшафтах Егорьевского месторождения фосфоритов. Выбор сосны Банкса для исследования не случаен, поскольку она мирится с суровым климатом и обладает быстрым ростом (дает по 2–3 прироста в год).

Была поставлена задача изучения зависимости между выходной и входными переменными с целью прогноза веса семян после сушки.

Методы и объекты исследования

В качестве исходного материала были взяты данные этой сосны по урожаю шишек. В качестве выходной переменной y рассматривался вес семян после сушки (в граммах), в качестве входных переменных рассматривались: x_1 — масса шишки до сушки (в граммах), x_2 — длина шишки до сушки (в сантиметрах), x_3 — диаметр шишки до сушки (в сантиметрах), x_4 — масса шишки после сушки (в граммах), x_5 — количество семян после сушки.

Для построения зависимостей были выбраны следующие регрессионные модели:

- 1) классическая линейная регрессионная модель;
- 2) классическая квадратичная регрессионная модель;
- 3) классические нейронные сети (многослойный персептрон);
- 4) нейронечеткая модель.

Результаты и обсуждение

1. Классическая линейная регрессионная модель. Построены две классические линейные регрессионные модели. Для обучения первой регрессионной модели использовались 20 % исходных данных, предсказывались 80 % данных. Получены следующие результаты: $R^2 = 0,481241853$, процент верного прогноза — 11,25. Вид регрессионной модели:

$$y = 0,0000582 - 0,000798265x_1 + 0,003710811x_2 - 0,014598138x_3 + 0,004301971x_4 + 0,00553x_5.$$

Для обучения второй линейной регрессионной модели использовались 100 % исходных данных, предсказывались 100 % данных. Результаты: $R^2 = 0,881389$, процент верного прогноза — 30.

Вид регрессионной модели:

$$y = 0,0311209 + 0,001109068x_1 - 0,001022821x_2 - 0,03644694x_3 + 0,008924664x_4 + 0,005191x_5.$$

2. Классическая квадратичная регрессия.

Аналогично линейной были построены две классические квадратичные регрессионные модели. Для обучения первой регрессионной модели использовались 20 % исходных данных, предсказывались 80 % данных. Получены следующие результаты: $R^2 = 0,45$, процент верного прогноза — 8,75. Вид регрессионной модели:

$$y = 0,118787 + 0,107328x_1 + 0,6789x_2 - 1,6891x_3 - 0,121274x_4 + 0,0249012x_5 + 0,104395x_1^2 - 0,152918x_2^2 + 0,630976x_3^2 + 0,0787074x_4^2 + 0,0000831281x_5^2 - 0,0902681x_1x_2 - 0,00216325x_1x_3 - 0,222472x_1x_4 - 0,00143429x_1x_5 + 0,00967899x_2x_3 + 0,236338x_2x_4 + 0,0000398561x_2x_5 - 0,11937x_3x_4 - 0,0182906x_3x_5 + 0,00484114x_4x_5.$$

Для обучения второй регрессионной модели использовались 100 % исходных данных, предсказывались 100 % данных. Результаты: $R^2 = 0,903111$, процент верного прогноза — 25. Вид регрессионной модели:

$$y = 0,0858584 - 0,0948945x_1 + 0,0145514x_2 - 0,315832x_3 + 0,178576x_4 + 0,0119976x_5 - 0,0000126253x_1^2 + 0,00359926x_2^2 + 0,141342x_3^2 + 0,0131169x_4^2 + 0,0000121809x_5^2 + 0,0160592x_1x_2 + 0,0295964x_1x_3 - 0,00576666x_1x_4 + 0,0000318313x_1x_5 - 0,0317832x_2x_4 + 0,000543361x_2x_5 - 0,0733748x_3x_4 - 0,0061723x_3x_5 + 0,000565499x_4x_5.$$

3. Классические нейронные сети (многослойный персептрон). Известным и весьма целесообразным способом представления зависимости одной переменной от других являются нейронные сети. Для решения данной задачи рассматривали классические нейронные сети (многослойный персептрон — MLP). Сети построены в программе Statistica 8 при помощи мастера построения сетей. Программой определены 5 различных вариантов сетей с минимальной ошибкой, которые представлены в таблице.

Для обучения использовались 100 % данных, предсказывали 100 % данных. Результаты: для первой сети $R^2 = 0,886341$, процент верного прогноза — 39; для второй сети $R^2 = 0,891925$, процент верного прогноза — 41; для третьей сети $R^2 = 0,865737$, процент верного прогноза — 34; для четвертой сети $R^2 = 0,871172$, процент верного прогноза — 37; для пятой сети $R^2 = 0,900684$, процент верного прогноза — 39.

4. Нейронечеткая модель. Построена с помощью программы MATLAB 7.11. Исходная информация — выборка из 300 наблюдений со

Классические нейронные сети
Classical neural networks

Вариант	Тип сети	Ошибка на обучающей выборке	Ошибка на тестовой выборке	Метод обучения	Функции активации скрытого слоя	Функции активации выходного слоя
1	MLP 5-34-1	0,003776	0,002532	BFGS 10	Exponential	Exponential
2	MLP 5-30-1	0,002574	0,002800	BFGS 77	Logistic	Sine
3	MLP 5-11-1	0,003140	0,002595	BFGS 25	Exponential	Identity
4	MLP 5-23-1	0,002917	0,002802	BFGS 41	»	Logistic
5	MLP 5-30-1	0,002931	0,002239	BFGS 54	Tanh	Tanh

следующими параметрами: 1) mass before — масса до просушки, 2) length — длина, 3) width — ширина, 4) mass after — масса после просушки, 5) seeds_count — количество семян. Первые четыре параметра являются входными, пятый — выходным. Выборку из исходных 300 наблюдений случайным образом разбивали на две части, 250 наблюдений использовали для обучения, а оставшиеся 50 наблюдений — для проверки построенной модели. Сформирована система нечетких правил вывода с 75 правилами и весами, определенными в процессе итерационного обучения с помощью нейронной сети. Получены следующие результаты: $R^2 = 0,994013$, процент верного прогноза — 89. Таким образом, нейронечеткая модель дает лучший прогноз по сравнению с классическими регрессионными моделями (линейной и квадратичной) и классическими нейронными сетями.

Выводы

Разработана нейронечеткая модель для прогноза семеношения сосны Банкса на рекультивированных землях Егорьевского месторождения фосфоритов. Построение новой модели понадобилось из-за неудовлетворительных выходных результатов классических регрессионных моделей и классических нейронных сетей, которые не позволяют учесть неполноту и нечеткость исходной

информации. Сравнительный анализ классических регрессионных моделей, нейронных сетей и разработанной нейронечеткой модели показал эффективность и адекватность нейронечеткой модели, что позволяет рекомендовать нейронечеткие модели для решения ряда задач исследования лесных культур.

Список литературы

- [1] Васильев С.Б. Минеральное питание древесных пород на рекультивируемых землях. Интродукция сосны Банкса при рекультивации техногенного ландшафта Егорьевского месторождения фосфоритов // Вестник МГУЛ — Лесной вестник, 2006. № 3. С. 92–93.
- [2] Хайкин С. Нейронные сети. Полный курс. М.: Вильямс, 2008. 1101 с.
- [3] Заде Л.А. Понятие лингвистической переменной и его применение к принятию приближенных решений. М.: Мир, 1976. 165 с.
- [4] Полещук О.М. О развитии систем обработки нечеткой информации на базе полных ортогональных семантических пространств // Вестник МГУЛ — Лесной вестник, 2003. № 1. С. 112–117.
- [5] Домрачев В.Г., Полещук О.М., Ретинская И.В. Прогнозирование показателей качества образовательных услуг на основе успеваемости // Качество. Инновации. Образование, 2002. № 4. С. 49–52.
- [6] Полещук О.М. Некоторые подходы к моделированию системы управления образовательным процессом // Телекоммуникации и информатизация образования, 2002. № 3. С. 4.

Сведения об авторах

Полещук Ольга Митрофановна — д-р техн. наук, профессор кафедры «Высшая математика» МГТУ им. Н.Э. Баумана (Мытищинский филиал), poleshchuk@mgul.ac.ru

Васильев Сергей Борисович — канд. с.-х. наук, доцент, заведующий кафедрой искусственного лесовыращивания и механизации лесохозяйственных работ МГТУ им. Н.Э. Баумана (Мытищинский филиал)

Статья поступила в редакцию 23.10.2017.

NEURO-FUZZY MODEL FOR THE PREDICTION OF FOREST REPRODUCTION IN CONDITIONS OF TECHNOGENIC LANDSCAPES

O.M. Poleshchuk, S.B. Vasil'ev

BMSTU (Mytishchi branch), 1 st. Institutskaya, 141005, Mytishi, Moscow reg., Russia

poleshchuk@mgul.ac.ru

A neuro-fuzzy model for the prediction of forest cultures seed production in the conditions of technogenic landscapes by the example of Banks pine on reclamation landscapes of Egorevsky Deposit of phosphorites is created in the paper. The choice of neuro-fuzzy model is justified because standard methods cannot give satisfactory results and do not take into account the incompleteness and fuzziness of initial information. The comparative analysis of the classical regression models, neural networks and the developed neuro-fuzzy model, which showed the effectiveness and adequacy of the neuro-fuzzy mode, is carried out in the article.

Keywords: expert information, linguistic variable, membership function, neuro-fuzzy model, forest reproduction of in the conditions of technogenic landscapes

Suggested citation: Poleshchuk O.M., Vasil'ev S.B. *Nejronechetkaya model' dlya prognoza semenosheniya lesnykh kul'tur v usloviyakh tekhnogennykh landshaftov* [Neuro-fuzzy model for the prediction of forest reproduction in conditions of technogenic landscapes]. *Lesnoy vestnik / Forestry Bulletin*, 2018, vol. 22, no. 1, pp. 31–35.

DOI: 10.18698/2542-1468-2018-1-31-35

References

- [1] Vasil'ev S.B. *Mineral'noe pitanie drevesnykh porod na rekul'tiviruemyykh zemlyakh. Introduktsiya sosny Banksa pri rekul'tivatsii tekhnogennogo landshafta Egor'evskogo mestorozhdeniya fosforitov* [Mineral nutrition of tree species on recultivated lands Introduction pine of banks in reclamation of man-made landscape of the Egor'evsky deposit of phosphorites]. *Vestnik MGUL — Lesnoy vestnik* [Forestry Bulletin], 2006, no. 3, pp. 92–93.
- [2] *Khaykin S. Neyronnye seti*. [Neural network]. Moscow: Vil'yams, 2008, 1101 p.
- [3] Zade L.A. *Ponyatie lingvisticheskoy peremennoy i ego primeneniye k prinyatiyu priblizitel'nykh resheniy* [Concept of a linguistic variable and its application to adoption of approximate decisions]. Moscow: Mir, 1976, 165 p.
- [4] Poleshchuk O.M. *O razvitiy sistem obrabotki nechetkoy informatsii na baze polnykh ortogonal'nykh semanticheskikh prostranstv*. [On the development of fuzzy information processing systems on the basis of complete orthogonal semantic spaces]. *Vestnik MGUL — Lesnoy vestnik* [Forestry Bulletin], 2003, no. 1 (26), pp. 112–117.
- [5] Domrachev V.G., Poleshchuk O.M., Retinskaya I.V. *Prognozirovaniye pokazateley kachestva obrazovatel'nykh uslug na osnove uspevaemosti* [Prediction of quality of educational services on the basis of academic excellence]. *Kachestvo. Innovatsii. Obrazovanie*, 2002, no. 4, pp. 49–52.
- [6] Poleshchuk O.M. *Nekotorye podkhody k modelirovaniyu sistemy upravleniya obrazovatel'nykh protsessom* [Some approaches to the modeling of the system of management of educational process]. *Telekommunikatsii i informatizatsiya obrazovaniya*, 2002, no. 3, pp. 4.

Authors' information

Poleshchuk Ol'ga Mitrofanovna — D-r Sci. (Tech.), Professor of Higher Mathematics Department of BMSTU (Mytishchi branch), poleshchuk@mgul.ac.ru

Vasil'ev Sergey Borisovich — Cand. Sci. (Agricultural), Associate Professor, Head of Department of Artificial Forest Regeneration and Mechanization of Forestry Works of BMSTU (Mytishchi branch), svasilyev@mgul.ac.ru

Received 23.10.2017.