



Моделирование вероятности изменений в землепользовании под воздействием природных факторов на основе искусственной модели многослойных персептронов

Чинь Куок Хюи¹✉, В.А. Малинников¹

¹ Московский государственный университет геодезии и картографии,
Москва, Россия

✉ quochuy9xnb@gmail.com

ЦИТИРОВАНИЕ Чинь Куок Хюи, Малинников В.А. Моделирование вероятности изменений в землепользовании под воздействием природных факторов на основе искусственной модели многослойных персептронов // Известия вузов «Геодезия и аэрофотосъемка». 2025. Т. 69. № 1. С. 23–35. DOI:10.30533/GiA-2025-002.

КЛЮЧЕВЫЕ СЛОВА изменение в землепользовании, многослойные персептроны, искусственные нейронные сети, V Крамера, алгоритм обратного распространения ошибки, природный фактор

АННОТАЦИЯ Искусственные нейронные сети (Artificial Neural Network) — это усовершенствованные алгоритмы распознавания образов, способные извлекать сложные нелинейные зависимости между переменными. В данной статье описано применение искусственных нейронных сетей, в частности нейронных сетей Multi-Layer Perceptron (MLP) из модели Land Change Modeler (LCM), для моделирования вероятности изменений в землепользовании под воздействием природных факторов. В качестве иллюстрации применения этого метода приводится исследование, проведенное в округе Зяотхюи провинции Намдинь (Вьетнам). Данные о состоянии землепользования за период с 2001 по 2013 год были дешифрованы с использованием спутниковых изображений Landsat. Процесс анализа данных проводился с помощью программного обеспечения TerrSet для получения простой нейронной сети MLP, состоящей из входного слоя (3 нейрона), скрытого слоя (7 нейронов) и выходного слоя (2 нейрона). Результаты исследования показывают, что сети MLP работают с высокой надежностью. Общая (со всеми переменными) эффективность (0,6858) и точность (84,29 %) модели значительно превышают допустимые минимальные значения, позволяющие использовать ее для обучения. Результаты исследований показывают, что три фактора, влияющие на изменения в землепользовании, могут быть ранжированы по уменьшению влияния в следующем порядке: почвы, геоморфология и расстояние до береговой линии.

1 Введение

Земля является природным капиталом, определяющим социальную жизнь людей. В последние годы экологические угрозы, такие как изменение климата, опустынивание, вырубка лесов и утрата биоразнообразия, а также изменения в землепользовании и земельном покрове, привлекают внимание экологов [1]. Изменения в землепользовании происходят вследствие взаимодействия социальных и культурных факторов и ресурсов земли и отличаются большей интенсивностью в развивающихся странах. Изменения в землепользовании бывают естественными и антропогенными, вызванными нерациональной эксплуатацией ресурсов. Исследования показали, что изменения в землепользовании и природные условия тесно взаимосвязаны.

Для эффективного управления экосистемами и долгосрочного планирования необходимо моделировать изменения в землепользовании. В последние два десятилетия было разработано множество моделей Land Use Change (LUC), которые помогают управлять земельными ресурсами и оценивать влияние таких изменений на земельные системы [2]. Модели изменений и их анализа в землепользовании особенно важны для развивающихся стран, где имеют место такие изменения, как вырубка лесов, неравномерное освоение земель и деградация пастбищ, усиливающие опустынивание [3]. Использование данных дистанционного зондирования для обнаружения и моделирования LUC способствует лучшему пониманию процессов изменений в землепользовании и предоставляет инструменты для управления ими.

В последние годы эксперты использовали такие модели, как Geographical Model (GEOMOD), Conversion of Land Use and its Effects (CLUE), Land Change Modeler (LCM) и Cellular Automata Markov (CA-Markov), для прогнозирования изменений в землепользовании и планирования. Исследователи часто применяют модель нейронной сети многослойного персептрона для моделирования процессов LUC в разных регионах. Например, С. Маитхани (S. Maithani) разработал модель на основе искусственных нейронных сетей (Artificial Neural Network — ANN) для предсказания пространственных изменений в городе Сахаранпуре за 1993–2001 годы [4]. Эта модель использовала данные дистанционного зондирования для выявления изменений в землепользовании, ГИС — для подготовки карты городского землепользования, различные входные переменные — для работы нейронной сети. В работе [5] исследователи применили LCM для моделирования деградации и восстановления мексиканских тропических лиственных лесов. Когда восприимчивости к каждому переходу объединяются для составления общей карты потенциальных изменений, использование LCM является более предпочтительным, поскольку выходные данные нейронных сетей способны более адекватно выражать потенциальные изменения для различных типов земельного покрова, чем отдельные вероятности, полученные с помощью метода весов доказательств [5].

LCM представляет собой инструмент, объединяющий анализ и моделирование изменений в землепользовании с природными факторами. Модуль моделирования изменений основан на картах вероятности перехода, вычисляемых с помощью логистической регрессии или ANN. Эта модель эффективно моделирует сложные процессы, сочетая возможности модели цепи Маркова, нейронной сети Multi-Layer Perceptron (MLP) с обучением обратному распространению ошибки, логистической регрессии и многоцелевому распределению земель (Multi-Objective Land Allocation — MOLA) [6]. В своих исследованиях мы показали, что связь каждого типа землепользования с природными факторами можно описать с помощью модели полиномиальной логистической регрессии. Однако результаты были представлены только на статистическом уровне, а не пространственно. Целью данного исследования является определение вероятности изменений в землепользовании на единицу природных условий в пространстве и времени с использованием модели MLP.

2 Материалы и методы

2.1 Переменные исследования

Данные о состоянии землепользования в округе Зяотхюи провинции Намдинь во Вьетнаме за 2001–2013 годы были дешифрированы с использованием спутниковых изображений Landsat и проверены на точность классификации.

Геоморфологические особенности: внешняя часть дамбы — приливные отмели (ДМ4); внутренняя часть дамбы — современные речные илистые отмели (ДМ1), современные отложения рек, морей и болот (ДМ2), смешанная современная речная и морская аккумуляция (ДМ3), накопление морского песка (ДМ5), аккумуляция морского песка в результате штормовых заплесков (ДМ6).

Типы почв: песчаная почва, прибрежные песчаные дюны (Cc) распространены в основном за пределами дамбы, где растут деревья казуарины; почвы низкой и умеренной засоленности (Mi) встречаются на осоковых, соляных полях, участках для аквакультуры; очень соленая почва (Mn) распространена в мангровых лесах и на участках для аквакультуры; аллювиальная почва без ежегодных отложений (Ph), аллювиальная почва с ежегодными отложениями (Phb) и потенциальная щелочная почва (S) часто распределяются по таким типам землепользования, как земли под жилую застройку, земли для выращивания риса.

Расстояние до береговой линии (морская дамба). Береговая линия имеет очень тесную связь с изменениями в землепользовании в прибрежной зоне дельты Красной реки. Кроме того, если допустить, что береговая линия не меняется, связь между изменениями в землепользовании и береговой линией все равно сохранится, поскольку на землепользование в прибрежных зонах большое влияние оказывают засоленность почвы и водный режим, которые зависят от удаленности территории от береговой линии. Расстояние равномерно рассчитывается от морской дамбы с шагом 800 м. На рис. 1 представлены переменные исследования.


Рис. 1 ✓

Переменные исследования
(см. также с. 26)

Fig. 1

Variables involved in the research
process (see also p. 26)

Геоморфология / Geomorphology




Условные обозначения

- DM1 — современные речные илистые отмели
- DM2 — современные отложения рек, морей и болот
- DM3 — смешанная современная речная и морская аккумуляция
- DM4 — приливные отмели
- DM5 — накопление морского песка
- DM6 — аккумуляция морского песка в результате штормовых заплесков
- other — водная поверхность

Масштаб 1 : 100 000

0 12 4 6 8 км

Почва / Soil




Условные обозначения

- Cc — песчаная почва, прибрежные песчаные дюны
- Mi — почвы низкой и умеренной засоленности
- Mn — очень соленая почва
- Ph — аллювиальная почва без ежегодных отложений
- Phb — аллювиальная почва с ежегодными отложениями
- S — потенциальная щелочная почва
- other — водная поверхность

Масштаб 1 : 100 000

0 12 4 6 8 км

Расстояние до береговой линии / Distance to the coastline



Условные обозначения

0 м (море)	4800–5600 м
0–800 м	5600–6400 м
800–1600 м	6400–7200 м
1600–2400 м	7200–8000 м
2400–3200 м	8000–8800 м
3200–4000 м	8800–9600 м
4000–4800 м	

Масштаб 1 : 100 000

0 12 4 6 8 км

Состояние землепользования в 2001 г. / Land Use in 2001



Условные обозначения

жилая застройка
рисовые поля
водная поверхность
земли для аквакультуры
мангровые леса
соляные поля
пустующие земли
осоковые поля

Масштаб 1 : 100 000

0 12 4 6 8 км

Состояние землепользования в 2013 г. / Land Use in 2013



Условные обозначения

жилая застройка
рисовые поля
водная поверхность
земли для аквакультуры
мангровые леса
соляные поля
пустующие земли
осоковые поля

Масштаб 1 : 100 000

0 12 4 6 8 км

2.2 Методика исследования

На рис. 2 представлена общая схема методики, с помощью которой исследуется вероятность изменений в землепользовании. Конечным результатом исследования является модель изменений в землепользовании, предназначенная для понимания и определения изменений земного покрова, а также для составления требований к охране окружающей среды (если эти изменения вызывают необходимость охраны окружающей среды).

Основные этапы исследования:


1. Определение роли переменных, влияющих на изменения в землепользовании, путем расчета общего коэффициента V Крамера (мера силы связи между двумя номинальными переменными).
2. Подготовка карт переходного потенциала на основе карт изменений в землепользовании предыдущего периода и его эффективных переменных с использованием MLP-ANN.

Рис. 2 ➤

Общая схема методики исследования вероятности изменений в землепользовании

Fig. 2

General scheme of the methodology for conducting a study of the possibility of land use changes



Во-первых, роль и вероятность каждой пространственной вариации были оценены в прогнозировании возможных изменений землепользования путем расчета коэффициента V Крамера. Эти изменения использовались для определения корреляции между двумя номинальными переменными или одной номинальной и одной порядковой переменными. Значение этого коэффициента не превышает единицы и рассчитывается по формуле

1 ➤

$$V = \sqrt{\frac{\chi^2}{N \min(k-1, l-1)}},$$

где χ^2 — статистика хи-квадрат;

N — количество выборок;

k, l — количество строк и столбцов в таблице соответственно.

Значения, приближающиеся к 0,3, и выше считаются подходящими для переменной, а значения меньше 0,15 указывают на низкий уровень корреляции [6].

Существует несколько методов моделирования потенциала перехода, но исследования показывают, что ANN является самым эффективным [7]. ANN близки к характеристикам человеческого мозга и часто представляют собой параллельные системы, состоящие из множества элементов, связанных между собой весами переменных [8]. Эти связанные элементы расположены слоями (входной слой, выходной слой, один или несколько промежуточных слоев, называемых скрытыми слоями). Элементы в разных слоях связаны либо абсолютно, либо полуабсолютно. Ссылки между элементами имеют веса. Вес каждой из ссылок можно регулировать. Вес 0 указывает на отсутствие связи, а отрицательный вес указывает на очень слабую связь между двумя элементами. Нейронные сети нелинейны, и их можно понимать как сложную математическую формулу для преобразования входных данных (прошлый статус землепользования, природные факторы) в желаемые выходные данные (например, будущее землепользование)¹ [9]. MLP использует алгоритм обратного распространения ошибки, который широко применяется в моделях нейронных сетей [10, 11]. Модель сети многослойного персептрона показана на рис. 3.


¹ Нгуен Т.К. Применение искусственных нейронных сетей в прогнозировании (перевод с вьетнамского языка). [Электронный ресурс]. Режим доступа: <https://imech.ac.vn/upload/NewsImage/2021/1/12/ung-dung-mang-noron-nhan-tao-vao-bai-toan-du-bao-thuy-van.pdf> (дата обращения: 12.08.2024).

Рис. 3

Модель сети многослойного персептрона

Fig. 3

Model of a multilayer perceptron network



Примечание.

x_i — входы;
 w_{ji} — веса, соответствующие входным данным;
 Θ_j — отклонение;
 a_j — сетевой ввод;
 $g(a_j)$ — передаточная функция (функция активации);
 z_j — выход нейрона

Сетевой ввод рассчитывается по формуле

2

$$a_j = \sum_{k=0}^n w_{ji} x_i + \theta_j.$$

В нейронной сети есть три типа единиц:

- блоки ввода (принимают сигналы извне);
- блоки вывода (отправляют данные наружу);
- скрытые блоки (hidden units), их входные и выходные сигналы в сети.

3 Результаты

Потенциал перехода от одного вида землепользования к другому был смоделирован в соответствии с переменными, введенными в модель изменения земель, с помощью MLP-ANN. В табл. 1 представлены значения коэффициента Крамера V, которые показывают связь между переменными и классами землепользования. Как можно увидеть, значения коэффициента Крамера V больше 0,3 считаются подходящими для переменных.

Таблица 1

Корреляция между естественными переменными и изменениями в землепользовании

Table 1

Correlation between natural variables and land use changes

Независимая переменная	Значения коэффициента Крамера V
Геоморфология — изменения в землепользовании	0,368
Почва — изменения в землепользовании	0,341
Расстояние до береговой линии — изменения в землепользовании	0,342

Результатом работы ANN является определение вероятности перехода каждой пары изменений в землепользовании. Для каждой пары изменений в землепользовании вероятность преобразования распределяется в соответствии с природными факторами (почва, геоморфология и расстояние до береговой линии). Вероятность перехода имеет значение от 0 до 1. Чем выше значение, тем больше вероятность перехода. При этом значение 0 означает отсутствие вероятности перехода, значение 1 — уверенность в переходе. Ниже рассмотрены пары изменений в землепользовании.

Мангровые леса → земли для аквакультуры

Площадь и распределение мангровых лесов в прибрежной зоне дельты Красной реки в целом и в районе Зяотхюи в частности подвержены сильным изменениям. Мангровые леса развиваются естественным образом и в основном распространены на илистых равнинных участках. Однако площадь мангровых лесов стремительно сокращается. Одной из основных причин этого является их уничтожение для земель, используемых в целях аквакультуры. На рис. 4 показано, что наибольшая вероятность перехода (0,64–0,869) возникает на участках

с высокой соленостью (Mn) и приливных отменях (ДМ4). На участках с песчаной почвой, прибрежными песчаными дюнами очень низкая вероятность преобразования (0–0,097). Этот результат совместим с результатами при запуске модели логистической регрессии с отрицательными коэффициентами регрессии. На остальных территориях вероятность преобразования мангровых лесов в земли для аквакультуры практически отсутствует.

Рис. 4 ➔

Вероятность преобразования мангровых лесов в земли для аквакультуры с учетом природных условий

Fig. 4

Possibility of converting mangrove forests into aquaculture taking into account natural conditions




Рис. 5 ⬇


Вероятность преобразования рисовых полей в земли для аквакультуры с учетом природных условий

Fig. 5

Possibility of converting rice lands into aquaculture taking into account natural conditions

Рисовые поля → земли для аквакультуры

Благодаря политике экономического роста многие рисовые поля преобразуют в земли для аквакультуры. Однако этот переход не выходит за границы законов природы. На рис. 5 представлена карта потенциальных изменений в землепользовании, полученная с помощью модели MLP-ANN. Наибольшая вероятность перехода (0,869–0,999) возникает на участках с высокой соленостью (Mn) и современными отложениями рек, морей и болот (ДМ2). Область с меньшей вероятностью преобразования (0,445–0,64) охватывает территории с низкой



соленостью (Mi) и смешанной современной речной и морской аккумуляцией (DM3), особенно на расстоянии около 3 км от береговой линии. Другие районы не подходят для земель, используемых в целях аквакультуры.

Соляные поля → земли для аквакультуры


Соляные поля превращаются в земли для аквакультуры, поскольку производство соли экономически нецелесообразно. Однако на рис. 6 показано, что вероятность перехода только увеличивается и подходит для территорий с сильно засоленной почвой (0,64–0,869) и прибрежных зон в пределах 800 м до береговой линии (DM1). Чем дальше от береговой линии, тем меньше вероятность перехода.

Рис. 6 ➔

Вероятность перехода соляных полей в земли для аквакультуры

Fig. 6

Probability of conversion of salt land to aquaculture



Водная поверхность → мангровые леса

Мангровые леса в округе Зяотхюи претерпели изменения в площади и пространственном распределении. Несмотря на увеличение площади мангровых зарослей благодаря проектам по посадке мангровых деревьев и инновационной политике, изменения по-прежнему лежат в пределах естественных экологических законов и определяются геоморфологическими, почвенными и гидрологическими условиями, подходящими для роста мангровых деревьев.


На рис. 7 показана вероятность превращения водной поверхности в мангровый лес. Наибольшая вероятность перехода (0,81–0,896) распространяется на территории за пределами береговой линии, на участки с сильно засоленной почвой (Mn) и приливные отмели (DM4). Вероятность перехода от водной поверхности к мангровым лесам постепенно снижается (0,64–0,81) на участках с песчаной почвой, прибрежных песчаных дюнах (Cc).

Рис. 7 ▼


Вероятность перехода водной поверхности в мангровые леса

Fig. 7

Probability of water surface transition into mangrove forests



Геоморфология / Geomorphology



Почва / Soil



4 Обсуждение

Модель MLP-ANN связана с алгоритмом обратного распространения ошибки (backpropagation), при котором проходы вперед и назад продолжаются до тех пор, пока сеть не выучит характеристики всех классов. Поскольку выбор соответствующих переменных повлияет на точность обучения модели, оценка чувствительности модели имеет основополагающее значение перед любым моделированием изменения землепользования. Параметры и производительность модели были протестированы с использованием встроенного в классификатор MLP набора инструментов обработки изображений TerrSet.

Модель обучалась с использованием всех объясняющих переменных (рис. 1) и состояния землепользования в 2001, 2013 гг., затем система повторяет тесты навыков для относительной мощности объясняющих переменных, выборочно удерживая входные данные от выбранных переменных постоянными. Для измерения навыка S (3) были использованы три различных параметра чувствительности: принуждение одной независимой переменной быть постоянной (Forcing a Single Independent Variable to be Constant), принуждение всех независимых переменных, кроме одной, быть постоянными (Forcing All Independent Variables Except One to be Constant), обратный пошаговый механизм постоянного принуждения (Backwards Stepwise Constant Forcing). Статистика навыка варьируется от -1 до 1 , где навык 1 указывает на идеальное прогнозирование, навык -1 означает худший, а навык 0 указывает на случайный шанс. Приемлемое значение точности модели должно составлять 80% и выше, чтобы принять результат обучения [11].

3

$$S = \frac{A - E(A)}{1 - E(A)},$$

где A — измеренная точность;

$E(A)$ — ожидаемая точность.

Ожидаемая точность определяется с использованием количества переходов в подмодели T и количества классов устойчивости P по формуле

Таблица 2

Параметры и результаты работы модели

Table 2

Correlation between natural variables and land use changes

Параметры	Значения
Нейроны входного слоя	3
Нейроны скрытого слоя	7
Нейроны выходного слоя	2
Запрошенные образцы по классу	5146
Окончательная скорость обучения	0,0005
Фактор импульса	0,5
Сигмовидная константа	1
Допустимое среднеквадратичное значение	0,01
Итерации	10 000
Среднеквадратичное значение обучения	0,3392
Среднеквадратичное значение тестирования	0,3543
Точность оценки, %	84,29
Общая эффективность	0,6858

4

$$E(A) = \frac{1}{T+P}.$$

В настоящем исследовании была разработана сеть MLP-ANN прямого распространения со слоем ввода, скрытым слоем и слоем вывода (табл. 2). Каждый слой содержит узлы (или нейроны), соединенные различными весами: слой ввода имел 3 узла, называемых переменными драйвера, 7 узлов были созданы в скрытом слое, а 2 узла были связаны с выходным слоем. Эффект и порядок влияния каждой переменной драйвера статистически проверялись по сравнению с навыком MLP-ANN с использованием 10 000 итераций. Целью обучения сети является получение надлежащих весов как для связей между входным и скрытым слоями, так и между скрытым и выходным слоями для классификации неизвестных пикселей. Общая (со всеми переменными) эффективность (0,6858) и точность (84,29 %) модели значительно превышают минимальные значения, позволяющие принять результат обучения (табл. 2).

5 Выводы

В исследовании представлена эмпирическая модель связи между зависимой переменной (изменение в землепользовании) и независимой переменной (природный фактор). При исследовании моделирования вероятности изменений в землепользовании под воздействием природных факторов был предложен и оценен метод многослойной искусственной нейронной сети MLP. В предлагаемом методе моделирования на основе геопространственных данных результаты экспериментов показывают, что модель MLP работает хорошо. Общая (со всеми переменными) (0,6858) эффективность и точность (84,29 %) модели значительно превышают минимальные значения, позволяющие принять результат обучения.

Результаты исследований также показывают, что природные факторы, такие как почва, геоморфология и расстояние до береговой линии, являются основными факторами изменений в землепользовании. Судя по результатам вероятностных преобразований в модели MLP, в данном исследовании почва оказывает наибольшее влияние на изменения в землепользовании, а расстояние до береговой линии — наименьшее.

БИБЛИОГРАФИЯ

1. Kuemmerle T., Chaskovskyy O., Knorn J., et al. Forest cover change and illegal logging in the Ukrainian Carpathians in the transition period from 1988 to 2007 // Remote Sensing of Environment. 2009. Vol. 113. No. 6. P. 1194–1207. DOI:10.1016/j.rse.2009.02.006.
2. Mas J.F., Kolb M., Paegelow M., et al. Inductive pattern-based land use/cover change models: A comparison of four software packages // Environmental Modelling & Software. 2014. Vol. 51. P. 94–111. DOI:10.1016/j.envsoft.2013.09.010.
3. Amiraslani F., Dragovich D. Combating desertification in Iran over the last 50 years: An overview of changing approaches // Journal of Environmental Management. 2011. Vol. 92. No. 1. P. 1–13. DOI:10.1016/j.jenvman.2010.08.012.
4. Maithani S. A Neural Network based Urban Growth Model of an Indian City // Journal of the Indian Society of Remote Sensing. 2010. Vol. 37. No. 3. P. 363–376. DOI:10.1007/s12524-009-0041-7.
5. Pérez Vega A., Mas J.F., Ligmann-Zielinska A. Comparing two approaches to land use/cover change modeling and their implications for the assessment of biodiversity loss in a deciduous tropical forest // Environmental Modelling & Software. 2012. Vol. 29. No. 1. P. 11–23. DOI:10.1016/j.envsoft.2011.09.011.
6. Fathizad H., Hakimzadeh Ardakani M.A., Taghizadeh Mehrjardi R.A., et al. Modeling Land Use Change Process by Integrating the MLP Neural Network Model in the Central Desert Regions of Iran // Desert. 2019. Vol. 24. No. 2. P. 241–254. DOI:10.22059/jdesert.2019.76364.
7. Shafizadeh-Moghadam H., Tayyebi A., Helbich M. Transition index maps for urban growth simulation: application of artificial neural networks, weight of evidence and fuzzy multi-criteria evaluation // Environmental Monitoring and Assessment. 2017. Vol. 189. No. 6. P. 189–300. DOI:10.1007/s10661-017-5986-3.
8. Nguyễn V.N., Nguyễn C.C. Ứng dụng mạng Nơ-ron nhân tạo đa lớp trong thành lập mô hình phân vùng lũ quét khu vực miền núi Tây Bắc, thực nghiệm tại tỉnh Yên Bái // Tạp Chí Khoa học Đo đạc Và Bản đồ. 2020. Số 44. T. 56–64. DOI:10.54491/jgac.2020.44.304.
9. Azari M., Tayyebi A., Helbich M., et al. Integrating Cellular Automata, Artificial Neural Network and Fuzzy Set Theory to Simulate Threatened Orchards: Application to Maragheh, Iran // GIScience & Remote Sensing. 2016. Vol. 53. No. 2. P. 183–205. DOI:10.1080/15481603.2015.1137111.
10. Girma R., Fürst Ch., Moges A. Land Use Land Cover Change Modeling by Integrating Artificial-Neural-Network with Cellular Automata-Markov Chain Model in Gidabo River Basin, Main Ethiopian Rift // Environmental Challenges. 2021. Vol. 6. No. 10. P. 100419. DOI:10.1016/j.envc.2021.100419.
11. Gharaibeh A., Shaamala A., Obeidat R., et al. Improving land-use change modeling by integrating ANN with Cellular Automata-Markov Chain model // Heliyon. 2020. Vol. 6. No. 9. P. 1–18. DOI:10.1016/j.heliyon.2020.e05092.

АВТОРЫ **Чинь Куок Хюи**

ФГБОУ ВО «Московский государственный университет геодезии и картографии»
(МИИГАиК), Москва, Россия
кафедра космического мониторинга и экологии, картографический факультет
аспирант

 0009-0002-6752-0388

Малинников Василий Александрович

 malinnikov@mail.ru

ФГБОУ ВО «Московский государственный университет геодезии и картографии»
(МИИГАиК), Москва, Россия
кафедра космического мониторинга и экологии, картографический факультет
д-р техн. наук, профессор

 0000-0002-8663-755X

Поступила 19.09.2024. Принята к публикации 21.02.2025. Опубликовано 28.02.2025.



Modeling the possibility of land use changes under the influence of natural factors based on an artificial model of multilayer perceptrons

Trinh Quoc Huy¹✉, Vasily A. Malinnikov¹

¹ Moscow State University of Geodesy and Cartography, Moscow, Russia
✉ quochuy9xnb@gmail.com

CITATION Trinh Quoc Huy, Malinnikov VA. Modeling the possibility of land use changes under the influence of natural factors based on an artificial model of multilayer perceptrons. *Izvestia vuzov. Geodesy and Aerophotosurveying*. 2025;69(1): 23–35. DOI:10.30533/GiA-2025-002.

KEYWORDS land use change, multilayer perceptrons, artificial neural networks, Cramer's V, backpropagation algorithm, natural factors

ABSTRACT Artificial Neural Network (ANN) are advanced pattern recognition algorithms capable of extracting complex nonlinear relationships between variables. This paper presents the application of artificial neural networks, in particular the Multi-layer Perceptrons (MLP) neural networks from the Land Change Modeler (LCM) to model the potential for land use change under the influence of natural factors. A case study conducted in Giao Thuy district is used to illustrate this method. Land use data from 2001 to 2013 were decoded using Landsat satellite images. The data analysis process was carried out using TerrSet software to obtain a simple MLP neural network consisting of an input layer (3 neurons), a hidden layer (7 neurons), and an output layer (2 neurons). The results of the study show that the MLP network works with high reliability. The overall (with all variables) efficiency of 0.6858 and accuracy of 84.29 % of the model are well above the acceptable limit to be used for training. The results of the study show that the three factors influencing land use change can be ranked in order: soils, geomorphology and finally the distance to the coastline have the greatest influence.

- REFERENCES**
1. Kuemmerle T, Chaskovskyy O, Knorn J, et al. Forest cover change and illegal logging in the Ukrainian Carpathians in the transition period from 1988 to 2007. *Remote Sensing of Environment*. 2009;113(6): 1194–1207. DOI:10.1016/j.rse.2009.02.006.
 2. Mas JF, Kolb M, Paegelow M, et al. Inductive pattern-based land use/cover change models: A comparison of four software packages. *Environmental Modelling & Software*. 2014;51: 94–111. DOI:10.1016/j.envsoft.2013.09.010.

3. Amiraslani F, Dragovich D. Combating desertification in Iran over the last 50 years: An overview of changing approaches. *Journal of Environmental Management*. 2011;92(1): 1–13. DOI:10.1016/j.jenvman.2010.08.012.
4. Maithani S. A Neural Network based Urban Growth Model of an Indian City. *Journal of the Indian Society of Remote Sensing*. 2010;37(3): 363–376. DOI:10.1007/s12524-009-0041-7.
5. Pérez Vega A, Mas JF, Ligmann-Zielinska A. Comparing two approaches to land use/cover change modeling and their implications for the assessment of biodiversity loss in a deciduous tropical forest. *Environmental Modelling & Software*. 2012;29(1): 11–23. DOI:10.1016/j.envsoft.2011.09.011.
6. Fathizad H, Hakimzadeh Ardakani MA, Taghizadeh Mehrjardi RA, et al. Modeling Land Use Change Process by Integrating the MLP Neural Network Model in the Central Desert Regions of Iran. *Desert*. 2019;24(2): 241–254. DOI:10.22059/jdesert.2019.76364.
7. Shafizadeh-Moghadam H, Tayyebi A, Helbich M. Transition index maps for urban growth simulation: application of artificial neural networks, weight of evidence and fuzzy multi-criteria evaluation. *Environmental Monitoring and Assessment*. 2017;189(6): 189–300. DOI:10.1007/s10661-017-5986-3.
8. Nguyen VN, Nguyen CC. Application of multilayer artificial neural network in establishing a flash flood zoning model in the Northwestern mountainous region, experimentally in Yen Bai Province. *Journal of Mine Surveying and Cartographic Science*. 2020;44: 56–64. (In Vietnamese). DOI:10.54491/jgac.2020.44.304.
9. Azari M, Tayyebi A, Helbich M, et al. Integrating Cellular Automata, Artificial Neural Network and Fuzzy Set Theory to Simulate Threatened Orchards: Application to Maragheh, Iran. *GIScience & Remote Sensing*. 2016;53(2): 183–205. DOI:10.1080/15481603.2015.1137111.
10. Girma R, Fürst Ch, Moges A. Land Use Land Cover Change Modeling by Integrating Artificial-Neural-Network with Cellular Automata-Markov Chain Model in Gidabo River Basin, Main Ethiopian Rift. *Environmental Challenges*. 2021;6(10): 100419. DOI:10.1016/j.envc.2021.100419.
11. Gharaibeh A, Shaamala A, Obeidat R, et al. Improving land-use change modeling by integrating ANN with Cellular Automata-Markov Chain model. *Heliyon*. 2020;6(9): 1–18. DOI:10.1016/j.heliyon.2020.e05092.

AUTHORS**Trinh Quoc Huy**

Moscow State University of Geodesy and Cartography, Moscow, Russia
Department of Space Monitoring and Ecology, Faculty of Cartography

 0009-0002-6752-0388

Vasily A. Malinnikov

 malinnikov@mail.ru

Moscow State University of Geodesy and Cartography, Moscow, Russia
Department of Space Monitoring and Ecology, Faculty of Cartography
Dr. of Sci. (Engineering), Professor

 0000-0002-8663-755X

Submitted: September 19, 2024. Accepted: February 21, 2025. Published: February 28, 2025.