

**КРАТКОСРОЧНОЕ ОПОЛЗНЕВОЕ ПРОГНОЗИРОВАНИЕ С
ИСПОЛЬЗОВАНИЕМ НЕЙРОСЕТЕВОЙ МОДЕЛИ****SHORT-TERM LANDSLIDE FORECASTING WITH USE OF NEURAL NETWORK
MODEL**

Мониторингдин маалыматтарын жана нейрондук моделдерди колдонуп узакка созулган көчкүлөрдү ыкчам алдын алуу ыкмасы сунуш кылынды. Моделдердин сапаттык көрсөткүчтөрүнө сапаттык изилдөө жүргүзүлүп, бу лалдын алуу ыкмасынын перспективдүүлүгү жана жыйынтыктарын да шексиздик жок экени далилденип берилди.

***Ачык сөздөр:** жол инфраструктурасы, көчкүлөр, божомол жүргүзүү, көчкүлөрдү болжолдоо жана иликтөө.*

Предложен метод оперативного прогнозирования активности оползней длительного смещения с использованием данных мониторинга и нейросетевых моделей. Проведено исследование качественных характеристик моделей и доказана удовлетворительная достоверность результатов и перспективность метода прогнозирования.

***Ключевые слова:** дорожная инфраструктура, оползни, прогнозирование, прогноз и мониторинг оползней.*

The method of expeditious forecasting of activity of landslides of long shift with use of data of monitoring and neural network models is offered. Research of qualitative characteristics of models is conducted and satisfactory reliability of results and prospects of a method of forecasting is proved.

***Keywords:** travelling infrastructure, landslides, prognostication with the use of model, prognosis and monitoring of landslides.*

Автодорожная сеть Кыргызстана проложена в сложных горно-геологических условиях. Крупные ее участки пролегают в местах активного воздействия опасных геологических процессов: селей, паводков, оползней, камнепадов, снежных лавин, которые угрожают целостности дорожной инфраструктуры, автотранспорту, жизни водителей и пассажиров. Краткосрочный прогноз времени резкой активизации этих процессов позволил бы на короткое время прекратить эксплуатацию коротких участков автодорог, сохранить технику и жизнь людей, в тех случаях, пока не будут устранены причины развития подобных ЭГП, проведены инженерные мероприятия защиты или сам опасный процесс стабилизируется. Системы регулярного оперативного мониторинга, даже самые простейшие, могут существенно повысить безопасность автодорожного движения в горных условиях. Подобный мониторинг смещения крупного оползня «Тектоник», который создавал опасность для инфраструктуры горно-промышленной территории и движению по автодороге Майлуу-Суу-Сары-Бээ (Рис.1.), был реализован в 1997-2003гг. сотруниками НИЦ «Геоприбор» при ИГиОН АН Кыргызской Республики [1].

t - первый день пятидневки на протяжении которой осуществляется усреднение влияющих факторов и откликов регрессионной модели; $t = 0$ соответствует началу пятидневки, включающий дату 1 января каждого года; сутки;

$\sum h_t$ - сумма атмосферных осадков на момент времени t_t начиная с 26 января предыдущего года, мм; h_t - средняя интенсивность осадков за пятидневный период времени накануне t_t , мм/сутки; h_{t-S} -то же, но стретоспективным сдвигом на S суток, S=5,10,15 суток;

$\sum T^0$ - сумма среднесуточных температур воздуха на момент времени t_t начиная с 26 ноября предыдущего года, град. C; T_t^0 - среднесуточная температура воздуха на протяжении 5 суток, предшествующих моменту времени t_t , град. C; T-то же, но стретоспективным сдвигом на S суток, S=5,10,15 суток;

$\sum S_t$ - смещение оползня на момент времени t_t , начиная с 26 ноября предыдущего года, мм; v_t - средняя скорость смещения оползня в течении 5 суток, начиная с момента времени t_t , мм/сутки; $v_{t-5}; v_{t-10}; v_{t-15}; v_{t-20}; v_{t-25}; v_{t-30}$ - то же, но с ретроспективным сдвигом времени на 5,10,15,20,25 и 30 суток соответственно мм/сутки; K - кодировка характера оползневой активности в предстоящие 15 суток, при этом: $K = A_1$ - активность оползня по величине скорости падает на протяжении 15 суток; $K = B_1$ - активность падает в интервале ближайших от 5 до 10 суток, оставаясь неизменной в интервале от 10 до 15 суток; $K = C_1$ - активность оползня в интервале будущего времени от 5 до 10 суток падает, а в интервале от 10 до 15 суток – возрастает; $K = D_1$ - активность оползня остаётся неизменной в интервале будущего времени до 10 суток, а затем падает в интервале от 10 до 15 суток; $K = E_1$ - активность оползня остается неизменной на всем интервале горизонта прогноза до 15 суток; $K = F_1$ - активность оползня постоянная (скорость смещения неизменная) на протяжении предстоящих 10 суток, а в интервале времени от 10 до 15 суток возрастает; $K = G_1$ - активность оползня в интервале прогноза от 5 до 10 суток возрастает, а в интервале от 10 до 15 суток – падает; $K = L_1$ -активность оползня в период времени от 5 до 15 суток возрастает, а с 10 до 15 суток остается неизменной; $K = M_1$ -активность оползня непрерывно возрастает во всем интервале времени с горизонтом прогноза 15 суток.

На базе имеющихся данных мониторинга сформулируем две прогнозные задачи:

-*задача классификации*, когда по ретроспективным данным факторов требуется дать оценку (прогноз) оползневой активности на предстоящие 15 суток по значению индекса K ;

-*задача регрессии*, когда по ретроспективным данным факторов требуется дать прогноз абсолютного значения средней скорости смещения оползня на предстоящие 5 суток.

Для решения указанных задач нами использован многослойный (трехслойный) перцептрон (MLP). Эта архитектура нейросети используется в настоящее время наиболее часто [2]. Каждый элемент этой сети строит взвешенную сумму своих входов с поправкой в виде слагаемого, а затем пропускает эту величину активации через передаточную функцию; таким образом формируется выходное значение этого элемента. Последние организованы в постоянную топологию с прямой передачей сигнала. Подобную сеть можно интерпретировать как модель многополюсника, в которой веса и пороговые значения (смещения) являются свободными параметрами модели, и такая сеть может моделировать прогнозную функцию практически любой степени сложности, при этом число элементов в каждом слое определяют сложность функции, которая в общем случае является существенно нелинейной.

Значительным преимуществом сети MLP по сравнению с другим (например RBF-радиальных базисных функции) заключается в том, что сеть MLP выдает более определенные решения при обработке сильно отклоняющихся данных. Для сравнения можно отметить “неумение” сетей RBF экстраполировать свои выводы за область известных данных: при удалении от обучающего множества значение функции отклика быстро падает до нуля. В целом склонность сети MLP к некритическому экстраполированию результатов считается её слабостью, однако в обсуждаемом нами случае, когда возможны редкие, но весьма значительные по величине оползневые подвижки, это свойство имеет свои положительные качества, уменьшая вероятность пропуска опасной ситуации.

Количество элементов во входном и выходном слоях определяются условиями задачи: в задаче классификации соответственно 16 и 2 элемента, в задаче регрессии соответственно 15 и 1 элемент из того перечня факторов, которые изложены выше. Сомнения, возникающие в отношении того, какие выходные значения необходимо использовать для решения прогнозной задачи (возможно их общее число должно быть меньше 15 или 16 раз) решаются нами на этапе обучения нейросети после анализа ее чувствительности к входным воздействиям. Во всяком случае, этот показатель должен быть заметно больше 1.

Вопрос о том, сколько использовать промежуточных слоев и элементов в них, решается поэтапно в качестве начального приближения нами, используется один промежуточный слой с числом элементов, в нем от 5 до 12. Здесь мы используем простое практическое правило: число элементов промежуточного слоя приблизительно равно половине элементов входного и выходного слоев. Использование этого правила позволяет создавать в общем простую сеть, которая, возможно, не обеспечивает минимальную ошибку прогнозирования, но застрахована от переобучения.

Значения весов и порогов сети, которые минимизируют ошибку прогноза, устанавливались нами автоматически в процессе обучения сети при использовании пакета STNeuralNetworks по критерию минимума среднеквадратичной ошибки (RMS), нормированной на число наблюдений и переменных. Процесс обучения содержал несколько тысяч эпох и из них отбирались 10 лучших результатов по критерию минимума ошибок обучения контрольной и тестовой подвыборок, при этом контрольная и тестовая подвыборки не участвовали в процессе обучения, а использовались для независимого контроля результатов. Имея ввиду недостаточно большой объем базы данных ($N=324$) нами было установлено следующие соотношения обучающей, контрольной и тестовой подвыборок: 80:10:10% соответственно.

В качестве алгоритма обучения использован мощный алгоритм Бройден-Флетчер-Гольдфарб-Шанно (BFGS) второго порядка с очень быстрой сходимостью, но с большими затратами памяти, обусловленными необходимостью сохранять матрицу Гессе. *Задача классификации* характера оползневой активности в рамках распознавания 9 классов решена неудовлетворительно. Достоверность прогнозов в среднем по всем классам при анализе 10 наиболее качественных сетей не превышает 50%. При этом наиболее опасная ситуация: непрерывного возрастания скорости смещения оползня на протяжении 15 предстоящих суток (класс $K=I$) прогнозируется разными (лучшими) сетями с достоверностью D_I от 0 до 25 % в то время как класс ($K=G$), характеризующий снижение и стабилизацию оползневой активности, прогнозируется с достоверностью $D_G = 65,8 \dots 73,1\%$. Система предикторов оказалось недостаточно информативной для решения задачи столь дробной классификации.

Для повышения эффективности распознавания сформируем всего два класса оползневой активности:

$K_1 = A = A_1 \mid B_1 \mid D_1 \mid G_1$ -класс относительно низкой оползневой активности или снижающейся с течением времени на интервале прогноза $\Delta t = 15$ суток;

$K_2 = C = C_1 | F_1 | H_1 | I_1$ - класс относительно высокой оползневой активности или повышающейся с течением времени на интервале прогноза $\Delta t - 15$ суток.

Результаты обучения нейросети, характеристики и качество прогнозирования проведены в нижеследующих таблицах и на рис.2. Существенно возросла как общая (средняя) достоверность правильного прогнозирования (76,54%), так и прогнозирования наибольшей и возрастающей оползневой активности (78,35%).

Интересными представляются результаты анализа чувствительности нейросети к воздействию тех или иных предикторов. Здесь выделяется три группы факторов:

Текущее календарное время t , сумма среднесуточных температур (кумулятивная температура $\sum T$) и, в порядке убывания, среднесуточная температура за 15 суток и менее ($T_{t-15}; T_{t-10}; T_{t-5}; T_t$);

Кумулятивное смещение оползня $\sum S$, кумулятивные осадки $\sum h$ и интенсивность осадков полумесячной давности h_{t-15} ;

Таблица 2. Итоговое описание нейросетевой модели прогнозирования активности оползня "Тектоник" (1996-2002) в рамках двух обобщенных классов.

Интенсивности осадков 10 дневной давности и выпавшие накануне ($h_{t-10}; h_{t-5}; h_t$), а также вся группа показателей ретроспективных скоростей смещения оползня ($v_t \dots v_{t-15}$);

Чувствительность нейросети в прогнозной модели оползня "Тектоник" наибольшая по отношению к факторам первой группы, что вполне объяснимо: началу мая каждого года соответствует подъем уровня грунтовых вод (УГВ), совпадающей с максимумом атмосферных осадков в этот же период времени. С этими же связана температурная цикличность воздуха.

Таблица 3 - Итоговые статистики распознавания обобщенных классов оползневой активности А и С (оползень "Тектоник"; 1996-2002 г.г.)

Итоги классификации (Тектоник.sta) Выборки: Обучающая, Контрольная, Тестовая			
7.MLP 16-6-2	А	С	Все
Все	196	128	324
Правильно	172	76	248
Неправильно	24	52	76
Правильно (%)	87,7551	59,3750	76,5432
Неправильно (%)	12,2449	40,6250	23,4568

Таблица 4 - Чувствительность нейросети к воздействующим (учитываемым) факторам при решении задачи классификации в рамках двух классов оползневой активности: А и С а) классификации в рамках двух обобщенных классов

фактор/сеть	t	$\sum T$	T_{t-15}	T_{t-10}	T_{t-5}	T	$\sum S$	h_{t-15}	$\sum h$	v	h	h_{t-10}	h_{t-5}	V_{t-15}	V_{t-5}	V_{t-10}
7 MLP 16-6-2	3,548	2,791	2,621	1,531	1,184	1,181	1,147	1,133	1,109	1,089	1,079	1,065	1,061	1,047	1,037	1,005

б) регрессии при прогнозе скорости смещения

Индекс сети	Архитектура сети	Производительность			Алгоритм обучения	Функция ошибки	Функция активации нейронов									
		обучения	контроль	тестовая			скрытых	выходных								
а) активности оползня в рамках двух обобщенных классов																
7	MLP16-6-2	78,077	68,750	71,875	BFGS42	Сумма-квадрат	Гиперболическая	Экспоненциальная								
б) скорости смещения оползня																
4	MLP-15-7-1	0,965	0,993	0,955	BFGS27	Сумма-квадрат	Гиперболическая	Логистическая								
Фактор/сеть	V_{t-1}	V_{t-10}	$\sum h_t$	t	T_{t-5}	T	V_{t-15}	h_{t-10}	$\sum s_t$	T_{t-1}	h_{t-5}	h_{t-15}	T_{t-15}	h	$\sum l_t$	-
4 MLP-15-7-1	5,463	4,121	1,646	1,641	1,639	1,482	1,198	1,1075	1,085	1,079	1,069	1,050	1,046	1,032	1,000	-

Развитие оползневой процесс на склоне Главной анитиклинали в Майлуу-Суу осуществляется в условиях весьма скудного питания плоскости скольжения грунтовыми водами, что предопределяет низкую реакцию на кратковременные атмосферные осадки, а оползневой потенциал довольно быстро “срабатывается” при небольшом продвижении оползня. На это же указывает своеобразный “рванный” режим его продвижения вниз по склону. Это объясняет низкую чувствительность нейросети к факторам третьей группы. Одновременно это же объясняет невысокие показатели достоверности прогнозов оползневой активности имеющимся набором предикторов.

Задача регрессии, связанная с оперативным прогнозом средней скорости смещения оползня на ближайшую пятидневку, имеет удовлетворительное решение: в диапазоне действительных скоростей смещения от 0 до 51,3 мм/сутки средневзвешенная ошибка прогноза (RMS) составляет 1,124 мм/сутки по всем типам подвыборок, что обеспечивает коэффициент корреляции между прогнозируемыми и реальными показателями скорости смещения, равный 0,967.

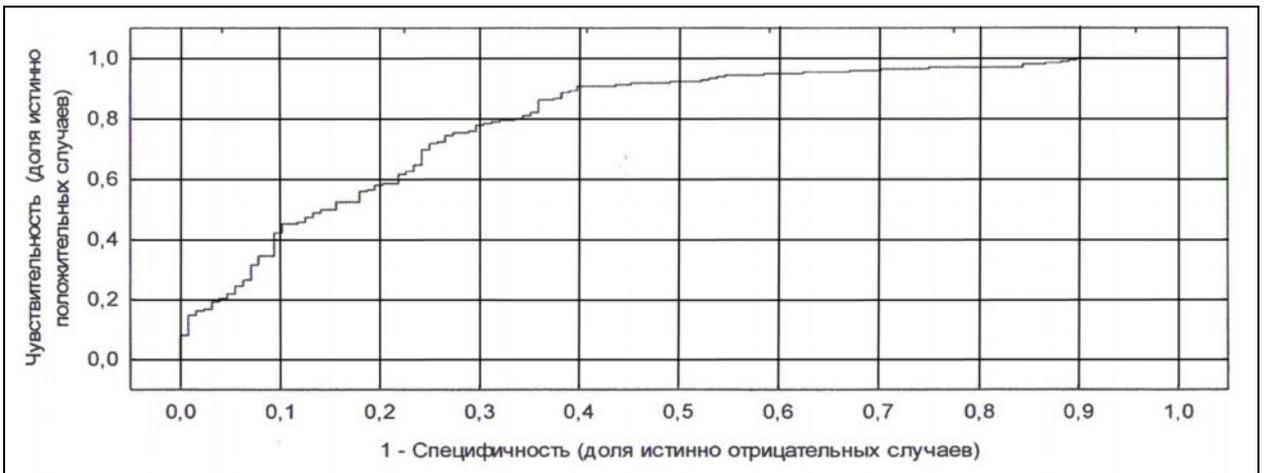


Рис.2. Кривая операционной характеристики (Рос-диаграмма) синтезированного нейросетевого автомата 7 MLP 16-6-2

Основные показатели нейросети для оперативного прогноза скорости смещения оползня “Тектоник” и качество прогнозирования представлены в таблицах 2, 4 и 5, а также на рис.3.

Таблица 5 - Итоговые статистики решения задачи регрессии нейросетевым автоматом(оползень “Тектоник”, 1996-2002 гг.)

Статистики предсказ. значений (Тектоник.sta) Целевая: Vcгл Исключенные наблюдения: 278:288	
	4.MLP 15-7-1
Минимум предсказ. знач. (Обучающая)	0,32862
Максимум предсказ. знач. (Обучающая)	46,67205
Минимум предсказ. знач. (Контрольная)	0,44395
Максимум предсказ. знач. (Контрольная)	46,87188
Минимум предсказ. знач. (Тестовая)	0,32142
Максимум предсказ. знач. (Тестовая)	11,84030
Минимум остатков (Обучающая)	-6,29593
Максимум остатков (Обучающая)	8,37922
Минимум остатков (Контрольная)	-1,76430
Максимум остатков (Контрольная)	4,46145
Минимум остатков (Тестовая)	-2,45105
Максимум остатков (Тестовая)	1,84276
Минимум стандар. остатков (Обучающая)	-5,69859
Максимум стандар. остатков (Обучающая)	7,58423
Минимум стандар. остатков (Контрольная)	-1,89214
Максимум стандар. остатков (Контрольная)	4,78471
Минимум стандар. остатков (Тестовая)	-3,27701
Максимум стандар. остатков (Тестовая)	2,46373

Коэффициенты корреляции (2013-04-09.sta) Включенные наблюдения: 5:112			
	v - Обучающая	v - Контрольная	v - Тестовая
4.MLP 15-7-1	0,965157	0,993278	0,954563

Обращает на себя внимание, что в данной задаче выстраивается совершенно иная иерархия чувствительность сети к предикторам. Здесь также можно выделить три группы (в порядке убывания чувствительности):

Скорости смещения оползня в предыдущих пятидневках;

Сумма осадков к моменту прогноза, начиная с 26 ноября предыдущего года $\sum h$, момент времени t формирования прогноза, температура воздуха текущая T_t и в предыдущую пятидневку T_{t-5} ;

Все другие предикторы, включая кумулятивное смещение, кумулятивную температуру $\sum T$, отдаленные от точки формирования прогноза интенсивности осадков $h_t, h_{t-5}, h_{t-10}, h_{t-15}$.

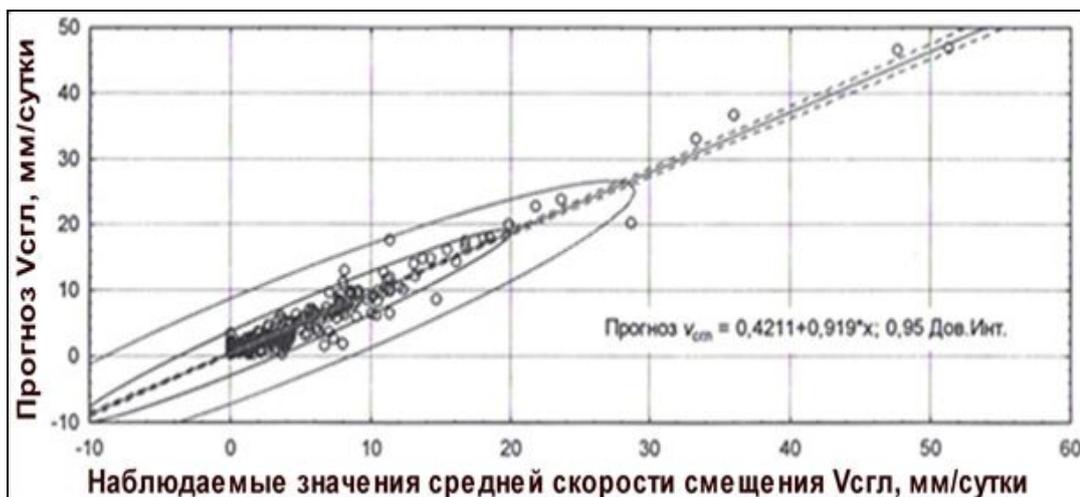


Рис.3. Корреляционный график взаимосвязи действительных (наблюдаемых) и прогнозных значений средних за 5 суток скоростей смещения оползня “Тектоник” в период с 1996 по 2002 год

Большое влияние первой группы факторов связано с инерционностью развития оползневой активности, что подтверждается характером функции автокорреляции процесса оползневой активности: радиус автокорреляции составляет в среднем 15 суток. Низкое влияние третьей группы, в которой сосредоточены практически все показатели ретроспективных атмосферных осадков от h_t до h_{t-15} , объясняется преимущественным влиянием на оползневую активность гидрогеологического режима, формирующегося в дальних зонах питания за счет осадков зимне-ранневесеннего периода года, когда невелики еще показатели испаряемости выпавшей влаги и ее транспирации растениями. Предложенная методика адаптивного оперативного прогнозирования с использованием нейросетевого автомата с немедленной обработкой данных по мере их поступления и коррекцией оползневого прогноза может быть использована в условиях чрезвычайной ситуации, в том числе на ранее неизученных оползнях. Методика включает в себе два нейросетевых алгоритма: прогноза уровня оползневой активности на ближайшие 15 суток и прогноза скорости смещения оползня. В качестве предикторов в этих прогнозирующих алгоритмах используются ретроспективные с различным горизонтом гидрометеорологические данные и реальные показатели оползневого смещения- всего 15-16 предикторов.

Эффективность алгоритмов проверена при прогнозе показателей оползневой активности оползня «Тектоник» в Майлуу-Суу за период с 1996 по 2002 год. Средняя достоверность правильного предсказания оползневой активности на ближайшие 15 суток составила от 76 до 78%. При оперативном прогнозе скорости оползневого смещения на ближайшие 15 суток в диапазоне реальных скоростей от 0 до 51,3 мм/сутки средневзвешенная ошибка прогноза (RMS) составила 1,12 мм/сутки, что обеспечивает коэффициент корреляции $R=0,967$ между прогнозируемыми и реальными показателями скорости смещения.

Список литературы

1. Торгоев И.А. Геоэкологическая безопасность и риск природно-техногенных катастроф на территории Кыргызстана [Текст] / И.А.Торгоев, Ю.Г. Алешин, Б.Б. Молдобаева. - Бишкек: Изд-во ЖЭКА, 1999. - 288 с.
2. Хайкин С. Нейронные сети: полный курс [Текст] 2-е изд., испр./Пер. с англ. // С.Хайкин. - М.: ООО «И.Д. Вильямс», 2006. - 1104 с.