

Л.И. Великанова

Институт автоматики и информационных технологий НАН КР

КРАТКОСРОЧНЫЙ ПРОГНОЗ ПАВОДКОВОЙ И СЕЛЕВОЙ ОПАСНОСТИ В ГОРНЫХ РАЙОНАХ С УЧЕТОМ ВЛАЖНОСТИ ГРУНТА

Предложен метод краткосрочного прогнозирования паводковых расходов воды и вероятности прохождения селя на горных реках на базе нейронных сетей с использованием данных наблюдения гидрометеослужбы и прогноза влажности грунта.

Ключевые слова: краткосрочное прогнозирование, катастрофические паводки, селеобразующие факторы, нейросетевые технологии, влажность грунта.

Введение. Такие явления природы, как катастрофические паводки и сели, относятся к разряду стихийных бедствий. Как и другие стихийные бедствия, они вызывают внезапные нарушения нормальной жизнедеятельности населения, разрушение и уничтожение материальных ценностей, а также оказывают отрицательное воздействие на окружающую среду.

В настоящее время методов прогноза катастрофических гидрологических явлений с достаточно высокой вероятностью не существует. Для некоторых селевых районов установлены определенные критерии, позволяющие оценить вероятность возникновения селей. Так, для районов с большой вероятностью возникновения селей ливневого происхождения определяется критическая сумма осадков за 1—3 суток, селей гляциального происхождения — критическая средняя температура воздуха за 10—15 суток или сочетание этих двух критериев. Но такой прогноз является весьма неточным, т. к. на формирование катастрофических паводков и селей оказывают влияние и многие другие факторы.

В высокогорной зоне Кыргызстана чрезвычайно распространены селевые и паводковые явления. Здесь отмечено шесть крупных селеопасных районов: бассейн р. Талас, бассейн р. Чу (реки Ала-Арча, Аксай, Адыгене, Карабалты, Аксу, Сокулук и др.), бассейн озера Иссык-Куль, бассейны Чаткальского хребта, бассейн р. Нарын (реки Узунхалат, Чичкан) и северный склон Алайского хребта. Поэтому задача прогноза паводковой и селевой опасности в этих регионах является очень актуальной.

Постановка задачи краткосрочного прогнозирования селя. Согласно [1], для формирования селей необходимо выполнение трех условий.

1. Наличие на склонах и в руслах достаточного количества продуктов разрушения горных пород, которые могли бы составить твердую фазу селевого потока. Если объем рыхлообломочного материала мал, то происходят обычные горные потоки небольшой насыщенности.

2. Наличие достаточного количества воды для смыва или сноса и перемещения по руслам рыхлообломочного материала. При отсутствии соответствующих водных масс будут иметь место гравитационные склоновые процессы — осьпи, обвалы, оползни и т.д., а не сели. Главным водным источником селей служат дожди и ливни, а также интенсивное таяние льда и снега.

3. Сильно расчлененный горный рельеф, обуславливающий наличие круtyх уклонов, склонов и русел, т.е. обеспечивающий одновременное движение значительных объемов водно-грунтовых масс с большими скоростями.

Серьезным индикатором возможного селеопасного периода является сильное увлажнение почво-грунтов в результате длительных затяжных дождей. Каждый из них ни по длительности, ни по интенсивности, ни по сумме выпавших осадков не может вызвать селеобразование, но суммарно такой период способствует образованию селя.

Учет влажности почво-грунтов при прогнозировании паводковой и селевой опасности имеет очень большое, иногда решающее значение. Влажность грунтов влияет на впитывающую способность, следовательно, на объем стоковых вод. Кроме того, переувлажненный грунт может вызвать сползание поверхностного слоя грунта в русло реки, чем спровоцировать формирование селя.

Неоднозначно влияние температуры воздуха на формирование селя. Повышение температуры воздуха, как правило, не способствует выпадению больших осадков – обычно интенсивным дождям предшествует понижение температуры. Но высокая температура вызывает более интенсивное таяние ледников и снежников и способствует накоплению водных масс в полостях ледников и увеличению расхода воды в русле реки.

Дополнительным индикатором селеопасности является устойчивость температуры воздуха в течение 5 – 6 суток, предшествующих селю [2].

Многофакторность задачи и неоднозначность влияния некоторых параметров на формирование селевого потока вызывает большие сложности при попытках описания ее с помощью традиционного математического аппарата. В отличие от таких методов нейросетевые технологии позволяют при условии неполноты изначальных данных закладывать оценку взаимозависимости целиком, без ее разложения на части. Такой подход используется при затруднении детально описать сложные геопространственные явления. Возможность применения технологий нейронных сетей при прогнозировании природных катастроф была показана в [3]. В данной работе исследуется возможность применения нейросетевых технологий для прогнозирования паводковой и селевой опасности.

Формирование обучающего массива на базе информационно значимых параметров. При решении задачи с помощью нейросетевых технологий необходимо собрать данные для обучения. Обучающий набор данных представляет собой набор наблюдений, для которых указаны значения входных и выходных переменных. Сеть учится устанавливать связь между первыми и вторыми. Обычно обучающие данные берутся из результатов наблюдений.

Апробация метода проводилась на примере горной реки Ала-Арча и ее притоков. В процессе обучения нейронной сети прогнозированию селевой опасности были использованы архивные данные гидрометеослужбы (ГМС) за более чем полувековой период. Специфика ГМС такова, что в этом архиве отсутствуют такие информационно значимые для прогнозирования селя параметры, как объемы рыхлообломочного материала на селеопасных склонах (необходимое условие 1) и влажность грунтов в предпрогнозный период. Как было указано выше, без учета этих параметров, прогноз селя является односторонним и неполноценным.

Если объемы рыхлообломочных материалов в селеопасных зонах поддаются визуальной оценке, хотя бы приблизительно, то определение влажности грунтов в горной местности вызывает значительные затруднения в связи с большим разнообразием классов грунтов: рыхлые, плотные, смешанные. К тому же зачастую грунты различных классов в пределах одной селеопасной зоны располагаются в перемешку, «языками». Влажности грунтов в соседних «языках» могут сильно отличаться. Устанавливать датчики влажности грунта в различных зонах представляется нерациональным. К тому же увеличение сигналов на входах нейросети может уменьшить точность ее прогноза. Возможным выходом в этой ситуации является определение класса погодных условий, влияющих на состояние влажности грунта [4] и учет этого класса при прогнозе паводковой и

селевой опасности. При таком подходе можно вообще отказаться от использования датчиков влажности грунтов, или, по крайней мере, резко сократить их количество.

Такая чрезвычайная ситуация, как прохождение селя, не возникает мгновенно, она определяется предысторией гидротермического режима за несколько дней. По рекомендации, предложенной в [5], это – временной интервал из шести предшествующих суток.

Для контролируемого створа за исследуемый период было зарегистрировано 30 ситуаций с высокими паводками и селевыми проявлениями. Каждая ситуация отслеживалась в течение 10 дней. Таким образом, в пакет данных было включена информация по трем стадиям реализации. С учетом предыстории получилось множество из 120 сценариев. На основе данных натурных наблюдений было создано виртуальное обучающее множество с шумами различных дисперсий.

В соответствии с принятым алгоритмом прогнозирование селевой опасности осуществляется в четыре этапа.

1. Осуществляется классификация совокупности параметров, оказывающих наибольшее влияние на состояние влажности грунтов (нейронная сеть НСВ). Создается и обучается нейронная сеть НСР, прогнозирующая максимальный (Q_{max}) и среднесуточный (Q_{cp}) расходы воды в контролируемом створе с заблаговременностью N суток. Создается и обучается нейронная сеть НСС, прогнозирующая вероятность прохождения селя на прогнозируемый период N суток. Этот этап является предварительным и выполняется однократно.

2. Прогнозируется класс влажности грунтов на прогнозируемый период с помощью обученной нейросети НСВ.

3. Прогнозируются максимальный и среднесуточный расходы воды в контролируемом створе с помощью обученной нейросети НСР. При этом учитываются моделированное НСВ значение класса влажности грунтов. В свою очередь, моделированные результаты прогноза Q_{max} и Q_{cp} наряду с другими данными являются входной информацией для нейронной сети НСС, осуществляющей прогноз селевой опасности.

4. Прогнозируется вероятность прохождения селя на период N суток с помощью обученной нейросети НСС.

Рассмотрим подробнее функционирование алгоритма на каждом из этапов.

Классификация погодных условий, определяющих влажность грунтов. Для распределения сценариев, обуславливающих распределение погодных условий по классам, была применена самоорганизующаяся нейронная сеть – слой Кохонена [6]. Нейроны самоорганизующейся сети могут быть обучены выявлению групп (кластеров) векторов входа, обладающих некоторыми общими свойствами. Обучение (без учителя) проводится на виртуальном множестве и данных натурных наблюдений. Затем создается радиальная базисная нейронная сеть НСВ [7] и обучается по данным кластеризации слоя Кохонена. Выходной информацией НСВ является вектор индексов классов влажности грунта для всех сценариев

По данным ГМС была обработана информация по 300 паводковым ситуациям. С учетом шестидневной предыстории было создано 120 сценариев. В качестве информативно значимых параметров для определения состояния влажности грунта были приняты:

- Среднесуточная температура воздуха, наблюдение и прогноз (7 сигналов);
- Среднесуточная влажность воздуха, наблюдение и прогноз (7 сигналов);
- Суточное количество осадков, наблюдение и прогноз (7 сигналов);
- Среднесуточная скорость ветра, наблюдение и прогноз (7 сигналов).

Итого 28 сигналов.

Результатом моделирования является индексный вектор

V_ind=2 2 1 1 2 1 4 4 3 3 3 3 5 5 5 5 1 4 4 4 1 1 4 4 3 3 3 3 3 5 5 5 2 2 1 3 3 3 3
 3 3 3 3 3 3 3 1 1 4 4 5 5 1 2 1 4 4 4 3 1 1 5 3 3 1 1 5 5 5 2 5 1 1 4 2 1 2 2
 2 1 1 1 3 1 1 5 2 1 5 5 4 4 4 4 1 5 5 5 2 2 2 2 2 2 4 4 4 4 4 4 4 2 2 2

Результат соответствия классов влажности их весовым значениям, основанный на проведении анализа погодных условий, приведен в таблице 1.

Таблица 1 – Соответствие классов влажности грунта весовым значениям

№ класса	1	2	3	4	5
Весовое значение	0.8	0.4	0.2	1.0	0.6

Используя классификацию грунтов по водонасыщенности, классы 2 и 3 можно отнести к маловлажным, класс 5 – к влажным, классы 1 и 4 – к насыщенным водой. Именно последние представляют наибольшую паводковую/сезонную опасность. После установки контрольного датчика влажности грунта появится возможность корректировки весовых значений указанных классов.

На основании таблицы 1 индексному вектору *V_ind* ставится в соответствие вектор значений весов классов влажности грунта:

Прогнозирование класса влажности грунтов

Формируется входной вектор, включающий в себя вышеперечисленные сигналы. По значениям этих сигналов обученная на предыдущем этапе НСВ моделирует класс влажности грунтов. Затем по таблице соответствия определяется его весовое значение, которое будет использоваться на следующих этапах прогнозирования паводковой и сезонной опасности.

Прогнозирование максимальных и среднесуточных паводковых расходов

Для прогнозирования максимальных и среднесуточных паводковых расходов была создана нейросеть НСР на базе двухслойного персептрона. Выбор архитектуры нейронной сети определяется набором входных и выходных сигналов. Из множества информативных паводкоформирующих характеристик при краткосрочном прогнозировании расходов воды были выбраны наиболее значимые:

1. Расход воды в реке (среднесуточный и максимальный);
2. Температура воздуха (среднесуточная и максимальная);
3. Суточное количество осадков;
4. Класс влажности почвы.

По каждой позиции используется архивный набор данных за 6 суток, предшествующих прогнозным. Кроме того, используется суточный прогноз по максимальной и среднесуточной температуре воздуха и ожидаемому количеству осадков (по данным наблюдения ГМС) и прогноз класса влажности грунта (моделированный НСВ). Таким образом, структура входных сигналов НСР имеет вид:

- Предыстория максимальных паводковых расходов (6 сигналов);
- Предыстория среднесуточных паводковых расходов (6 сигналов);
- Предыстория и прогноз максимальной температуры воздуха (7 сигналов);
- Предыстория и прогноз среднесуточной температуры воздуха (7 сигналов);
- Предыстория и прогноз суточного количества осадков (7 сигналов);
- Прогноз класса влажности грунта (1 сигнал).

ИТОГО 34 входных сигнала.

Структура выходных сигналов НСР имеет вид:

- Прогнозируемое значение максимального расхода;
- Прогнозируемое значение среднесуточного расхода.

ИТОГО 2 выходных сигнала.

Исходя из вышеизложенного, алгоритм краткосрочного прогнозирования катастрофических паводков на основе метеорологических и гидрологических данных с заблаговременностью одно сутки заключается в выполнении следующей последовательности действий:

1. Определение подсистемы информативных паводкоформирующих характеристик. На ее основе определение структуры входных и выходных сигналов НСР.
2. Выбор типа, архитектуры и алгоритмов обучения НСР: двухслойный персептрон; первый (скрытый) слой – 34 нейрона с функцией активации logsig; второй слой – 2 нейрона с той же функцией активации logsig; диапазон изменения входных и выходных сигналов после масштабирования (0; 1). Архитектура нейросети НСР приведена на рис. 1.
3. Создание виртуального обучающего множества на основе данных натурных наблюдений (масштабированные входные сигналы и значения функций цели).
4. Определение исходных параметров НСР.
5. Обучение НСР. Начальное обучение проводилось на обучающем множестве из 120 сценариев с нормальным шумом, имеющим минимальную дисперсию. Затем проводилось дообучение НСР. Проведено 10 циклов по 120 сценариев, каждый раз увеличивая дисперсию шума.
6. Тестирование обученной НСР на контрольном множестве, состоящем из 120 сценариев. Выходные сигналы нейросети были преобразованы в нужный формат путем умножения на масштабный множитель (этап пост-процессирования).

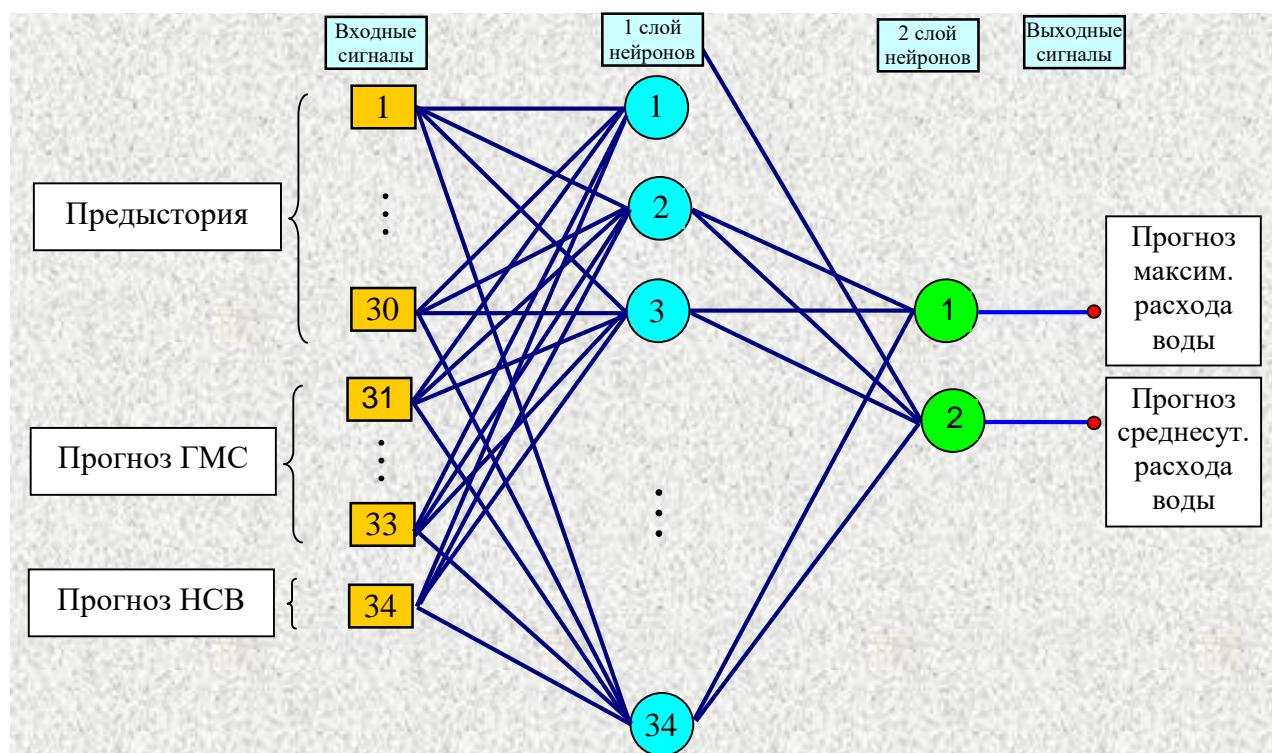


Рис. 1. Архитектура нейросети НСР для прогнозирования максимального и среднесуточного расходов воды в створах реки при прохождении паводка.

Результаты прогнозных значений и натурных наблюдений максимальных и среднесуточных расходов приведены в виде графиков (рис. 2, 3).

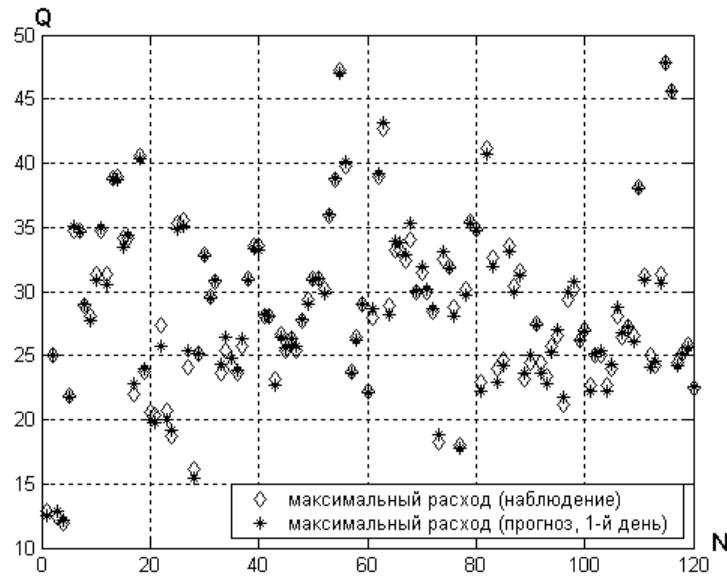


Рис. 2. Сигналы функции цели и выходные сигналы НСР (максимальный расход).

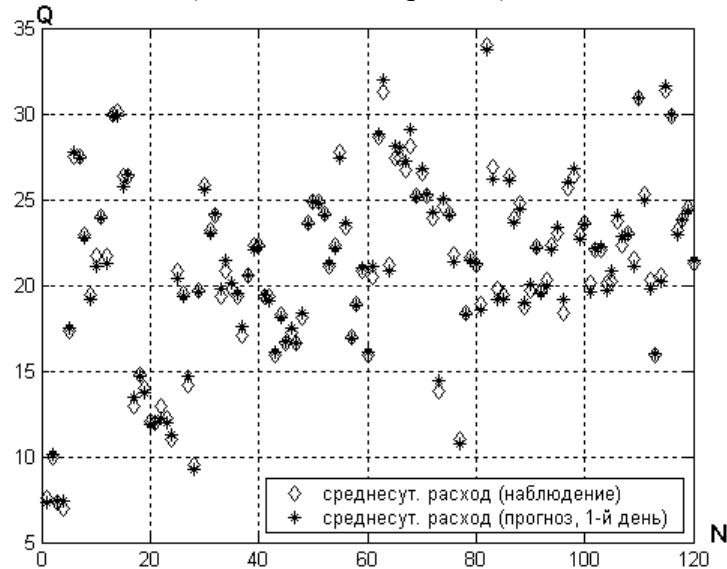


Рис. 3. Сигналы функции цели и выходные сигналы НСР (среднесуточный расход).

На этих графиках N – номер сценария, Q – расход воды (m^3/c). Графики демонстрируют приемлемую точность прогноза максимальных и среднесуточных расходов воды в паводковый период в бассейне р. Ала-Арча. Среднеквадратическая погрешность по 120 сценариям для максимальных расходов $\sigma_{max}=0.0509$, для среднесуточных – $\sigma_{cp}=0.0180$.

С помощью обученной нейросети можно получать прогноз расхода на интервале времени до N суток, последовательно вытесняя более ранние данные наблюдения и применяя прогноз гидрометеослужбы и моделированные значения Q_{max} и Q_{cp} .

Прогноз вероятности прохождения селя

Этот этап является заключительным при прогнозировании паводковой/селевой опасности. Его целью является краткосрочное прогнозирование вероятности схода селя гляциально-ливневого генезиса с использованием нейросетевых технологий и данных наблюдений и прогноза гидрометеослужбы.

Выше были перечислены три необходимых условия формирования селя:

1. Достаточные массы рыхлообломочных материалов (MPM);
2. Достаточное количество воды для смыва и перемещения этих масс;
3. Достаточная крутизна горных склонов.

Рассмотрим учет этих факторов при формировании входных векторов нейросети для ее обучения и моделирования.

1. Большинство работ по прогнозированию селевой опасности основано лишь на гидрометеорологическом прогнозировании условий формирования селей и не содержит попыток количественной оценки геологического-почвенных условий, без которых любой прогноз селеобразования является односторонним и, следовательно, недостаточно точным. В [8] были предложены методы приближенного прогнозирования селеопасного периода с учетом массы рыхлообломочного материала на склонах гор рассматриваемого региона. Автор предлагает специальные таблицы, в которых даются балловые индексы накопления рыхлообломочного материала (от +2 для весьма большого накопления продуктов разрушения горных пород до – 2 для незначительного их накопления). Подобная же таблица предложена им и для оценки увлажнения почвы. Но эти индексы не введены автором в расчетные формулы и представляют собой лишь косвенные показатели селеопасности. Предлагаемый им метод учитывает лишь три фактора (осадки, предварительное увлажнение почв и накопление рыхлообломочного материала). И хотя такие попытки являются шагом вперед по сравнению с методами прогнозирования селя лишь по гидрометеорологическим показателям, данный метод может рассматриваться лишь как предварительный, грубо приближенный метод оценки селеопасного периода.

В развитие предыдущих этапов прогнозирования селевой опасности [9], в настоящей работе осуществлен учет массы рыхлообломочных материалов путем создания соответствующих сигналов во входных векторах. Поскольку точный учет MPM в селеопасных регионах не проводился и требует развития служб наблюдения и контроля обстановки, значения этого параметра будем оценивать в диапазоне (0, 1). По аналогии с определением класса влажности грунта введем понятие класс MPM . Каждому классу поставим в соответствие весовое значение от нуля до единицы. Предположим, что в селеопасной зоне находятся N селеопасных участков. Распределим значения $MPMi$, $i=1,N$ по классам

в	соответствии	с
---	--------------	---

таблицей 2.

Таблица 2.– Весовые значения классов MPM .

№ класса	1	2	3	4	5
Весовое значение	0 – 0.2	0.2 – 0.4	0.4 – 0.6	0.6 – 0.8	0.8 – 1.0

Значения MPM в интервале (0.8 – 1) соответствуют их критическим массам, при которых ранее происходили селевые проявления. При наличии притоков исследуемой реки их селеопасные участки также оцениваются. Для обучения и моделирования нейросети НСС, прогнозирующей вероятность схода селя, используется $MPM=\max MPM_i$, $i=1,N$. При отсутствии критической величины MPM можно говорить не о селе, а о крупном паводке или грязевом потоке.

В виртуальном обучающем массиве при наличии факта схода селя на протяжении всего предпрогнозного периода полагаем $MPM = 1$. После схода селя присваиваем $MPM = 0$. В промежуточные интервалы времени полагаем $MPM = 0.5$. При моделировании вероятности схода селя в реальных условиях для определения MPM предполагается использование экспертных оценок служб наблюдения или их расчетные значения.

При выполнении настоящей работы рассматривались условия формирования селя в бассейнах р. Ала-Арча и двух ее притоков: Аксай и Адыгене. Каждая из исследуемых

рек обладает различным потенциалом образования *MPM*. Например, в верховьях р. Аксай расположен ледник Голубина, моренные озера которого регулярно переполняются и сбрасывают вниз ледниковые отложения. Поэтому сели в бассейне этой реки происходят практически ежегодно, иногда неоднократно. Проведение наблюдения за отложением рыхлообломочных материалов в бассейне этой реки особенно актуально.

Рыхлообломочный материал в бассейне р. Адыгена в основном поставляет моренное озеро Тез-Тёр, переполнение которого и сброс ледниковых отложений происходит реже, но иногда с катастрофическими последствиями.

Прогноз селей, вызванных прорывом моренных озер, требует другого рода информации, и возможность применения технологии нейронных сетей в этом случае требует дополнительных исследований. В связи с этим сценарии, соответствующие датам схода селя типа прорыва, не включаются в обучающий массив во избежание искаженного толкования нейронной сетью противоречивой информации. Так, например, гидротермические данные, соответствующие селю типа «прорыв» (озеро Тез-Тёр, прорыв произошел 22.06.1953) не отличаются от среднестатистических данных, не предвещающих селевой опасности. Соответствующие им сценарии исключены из обучающего массива.

2. Количество воды является, как правило, основополагающим фактором, определяющим начальный момент формирования селя гляциально-ливневого генезиса. Совпадение двух водных факторов: повышенный расход воды в реке и переувлажнение грунта при наличии критической массы рыхлообломочного материала приводит к повышенной селевой опасности.

3. Крутизна гор является величиной постоянной и не влияет на результат выходных сигналов нейронной сети.

Таким образом, при прогнозировании селевой опасности входные векторы обучающего множества должны содержать информацию по первым двум позициям. За рассмотренный период было зарегистрировано 30 ситуаций с высокими паводками, но не все из них имели селевые проявления. Наиболее типичными причинами этого являются недостаточное увлажнение грунта и отсутствие критической массы рыхлообломочных материалов.

Исходя из вышеизложенного, структура входных векторов обучающего множества имеет вид:

- Прогноз максимального и среднесуточного расхода (2 сигнала, *HCP*);
- Прогноз класса влажности грунта (1 сигнал, *HCB*);
- Максимальное значение класса *MPM* (1 сигнал, визуальное наблюдение).

Итого, 4 входных сигнала.

Небольшое количество входных сигналов обусловлено тем, что все информативно значащие гидрометеорологические факторы были учтены на предыдущих этапах. Простая структура входных векторов позволяет использовать упрощенную архитектуру нейронной сети НСС, разработанную для прогноза селевой опасности.

Поскольку целью НСС является моделирование вероятности схода селя, выходной вектор состоит из одного сигнала. При наличии факта прохождения селя в каком либо сценарии, значение этого сигнала (вероятность *p*) принимается равным 1, иначе *p* = 0.

Для краткосрочного прогноза селевой опасности с учетом дополнительных параметров (влажности грунта и массы рыхлообломочного материала) была принята структура двухслойного персептрона. Архитектура НСС и распределение сигналов во входных обучающих векторах приведена на рис. 4.

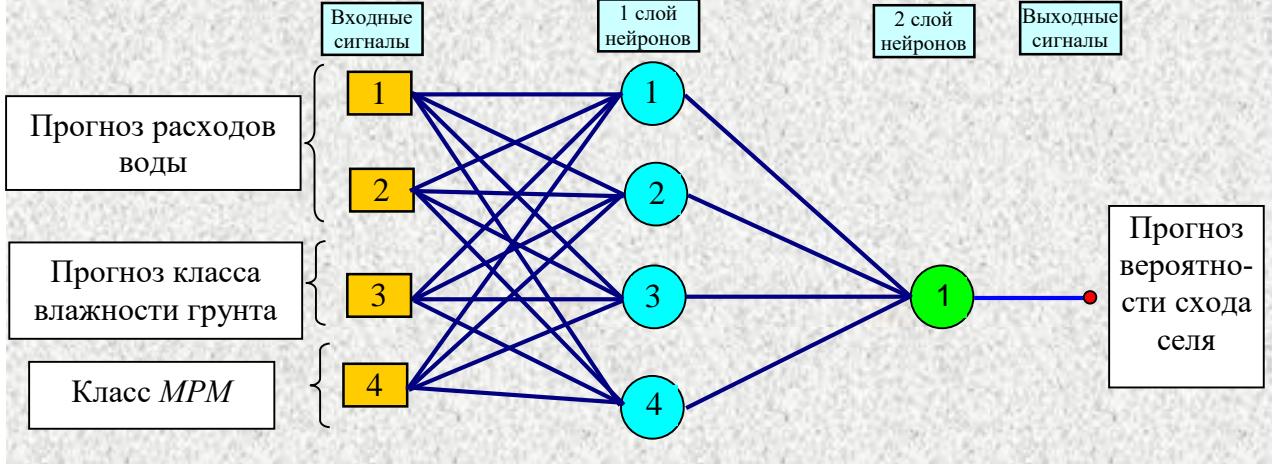


Рис. 4. Архитектура нейронной сети НСС.

На этапе пре-процессирования значения всех входных сигналов сведены к диапазону (0, 1). Тестирование НСС проводилось по данным наблюдения гидрометеослужбы. Результаты моделированных значений приведены на рис. 5. Здесь p – вероятность прохождения селя, N – число сценариев. События со значениями вероятностей $p < 0.5$ будем считать маловероятными.

Как видно из графика (рис. 5), при наличии факта схода селя прогнозные значения вероятностей схода селя $p > 0.5$, т.е. моделированные значения p правильно предсказали возможность селя. Однако, имеются значения p , близкие к единице при несостоявшемся селе. Анализ гидрометеорологических факторов показал, что эти сценарии близки к селевым ситуациям.

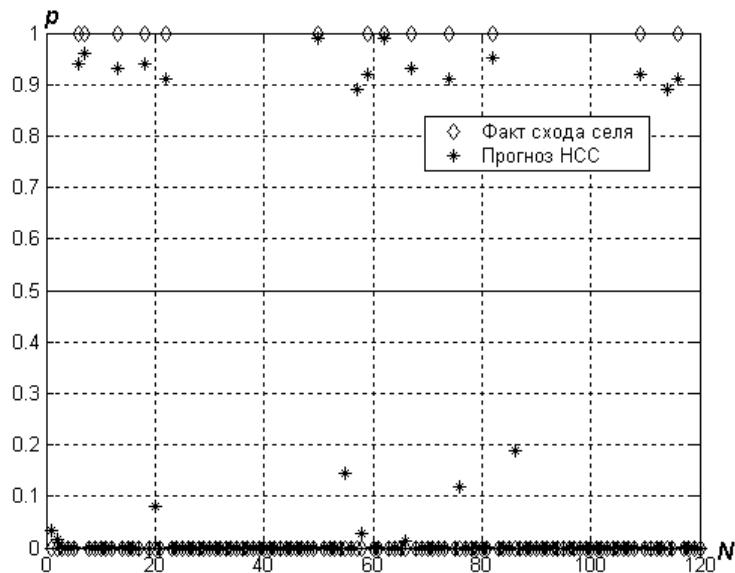


Рис. 5. Прогнозные значения вероятности схода селя, моделированные НСС.

Таким образом, алгоритм краткосрочного прогнозирования селевой опасности на основе метеорологических и гидрологических данных, а также геолого-почвенных условий с заблаговременностью одно сутки заключается в выполнении следующих действий:

1. Определение подсистемы информативных селеформирующих характеристик. На ее основе определение структуры входных и выходных сигналов НСС.
2. Создание виртуального обучающего множества (обучающих векторов) на основе моделюрованных прогнозных значений параметров паводка и данных натурных наблюдений с шумами различных дисперсий (входные сигналы и значения функций цели).
3. Преобразование обучающих векторов (этап пре-процессирования).
4. Выбор типа, архитектуры и алгоритмов обучения НСС.
5. Определение исходных параметров НСС.
6. Обучение НСС.
7. Преобразование выходных сигналов НСС в исходный формат (этап пост-процессирования).
8. Тестирование обученной НСС на контрольном и тестовом множествах.

С помощью обученной нейросети можно получать прогноз селевой опасности на интервале времени до n суток, последовательно вытесняя самые ранние данные наблюдения и применяя прогноз ГМС, моделированные значения классов влажности грунта, прогнозные значения расходов воды Q_{max} и Q_{cp} .

Схема соединения нейросетевых модулей НСВ, НСР и НСС при прогнозе селевой опасности с заблаговременностью 1 – 3 суток приведена на рис. 6.

При сравнении структуры входных сигналов нейросетевых модулей НСР на рис. 6 видно, что данные наблюдений по мере увеличения заблаговременности прогноза частично замещаются прогнозными. Естественно, что при этом происходит накопление ошибки, вызванное как погрешностями прогноза ГМС, так и результатами моделирования НСР расходов воды в реке. В связи с этим трехсуточный прогноз может быть использован лишь для грубо приближенной оценки, которую следует корректировать по мере получения свежих данных: прогнозных, моделюрованных и натурных наблюдений.

Из анализа разработанного нами алгоритма следует, что метод прогнозирования паводковой и селевой опасности с использованием нейросетевых технологий сочетает в себе свойства универсальности и региональности. Универсальность метода заключается в том, что при использовании его для бассейнов различных горных рек сохраняются тип, архитектура, параметры и алгоритмы обучения нейросетей, а региональность – в необходимости проводить их переобучение по архивным и прогнозным данным конкретных регионов.

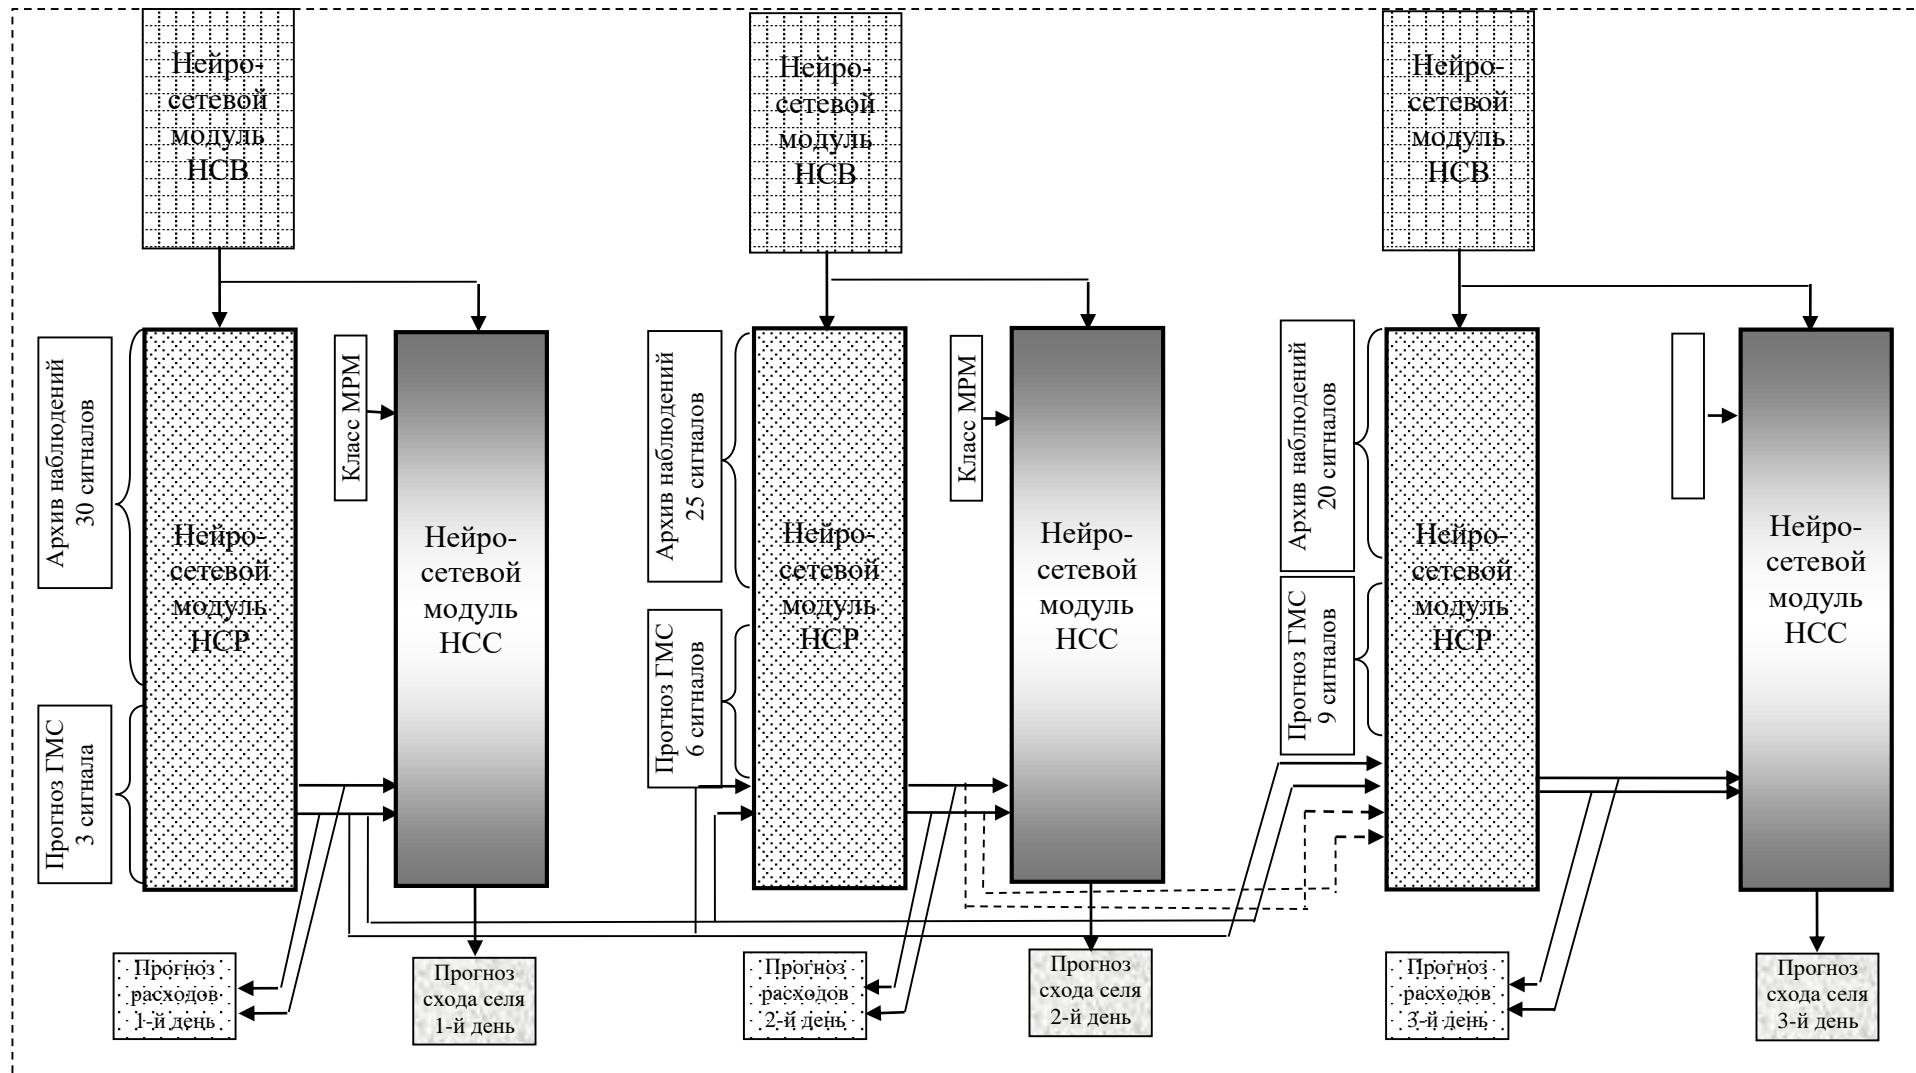


Рис. 6. Последовательность соединения нейросетей при прогнозе селевой опасности с заблаговременностью 1 – 3 суток

Заключение. Учет таких информативно значимых параметров, как влажность грунта и масса рыхлообломочных материалов, позволяет существенно повысить точность прогноза селевой опасности. Тем не менее, предложенные нами методы можно считать лишь приближением к точному прогнозу. Основные причины, препятствующие более точному прогнозу:

1. Нейронные сети могут распознать только те сели, которые близки по параметрам к селям из набора обучающих данных. В связи с этим желательно проводить дообучение нейронных сетей после прохождения каждого нового селя.

2. Сели, вызванные прорывом моренных озер, случаются чрезвычайно редко и, соответственно, по ним недостаточно информации для обучения нейронных сетей. Для прогноза прорыва моренного озера необходимы организация мониторинга за изменениями уровня воды и визуальные обследования состояния моренных плотин.

Имеются и другие, недостаточно изученные факторы, влияющие на процесс формирования селя. Значительное количество факторов, участвующих в селеобразовании, и сложный характер их взаимодействия на данной стадии изученности явления исключают возможность точного прогноза селевой опасности. Однако включение в обучающие множества новых сценариев катастрофических паводков и селей по мере их получения в процессе мониторинга и дообучение нейронных сетей на дополнительных примерах позволит значительно повысить точность прогноза.

Литература

1. Флейшман С.М. Сели. Л., Гидрометеоиздат. 1978, с. 35–58.
2. Голубев Г.Н. О формировании и прогнозировании гляциальных селей.–«Материалы гляциологических исследований», 1966, в. 12. М., Изд. ИГАН СССР, с. 48 – 53.
3. Замай В.И., Курманалиев Т.И., Миркин Е.Л., Мусакулова Ж.А., Савченко Е.Ю. Оперативное прогнозирование природных катастроф с использованием технологий нейронных сетей //Проблемы автоматики и управления. Материалы международной конференции «Проблемы управления и информационных технологий». – Бишкек: Илим, 2010, № 2.
4. Великанова Л.И. Краткосрочное прогнозирование влажности горных грунтов. // Проблемы автоматики и управления. Бишкек: Илим, 2015. С. 158 – 166.
5. Аджиев А.Х., Кондратьева Н.В., Кумукова О.А., Сейнова И.Б., Богаченко Е.М. Метод фотонового прогнозирования селевой опасности на Центральном Кавказе и результаты его апробирования. Труды Международной конференции «Селевые потоки: катастрофы, риск, прогноз, защита».– Пятигорск: Институт «Севкавгипроводхоз», 2008, 396 с.
6. Горбань А.Н., Дунин-Барковский В.Л., Кирдин А.Н. и др. – Нейроинформатика, Новосибирск: Наука. Сибирское предприятие РАН, 1998. - 296с.
7. Медведев В.С., Потемкин В.Г. – Нейронные сети. МАТЛАБ 6. Учебно-справочное издание, М., 2002, 238 с.
8. Зак А.И. Гидрологические условия формирования селевых потоков на реках Армянской ССР и методика прогноза селеопасных периодов.– «Труды ЗакНИКМИ», 1974, вып. 56. 190 с.
9. Великанова Л.И. Краткосрочное прогнозирование вероятности схода селя на базе нейросетевых технологий. // Проблемы автоматики и управления. Бишкек: Илим, 2014. С. 47 – 56.

Velikanova L.I.,

Institute of Automation and Information Technology NAS KR

CHORT-TERM FORECASTING OF FLOOD AND MUDFLOW HAZARDS IN MOUNTAIN AREA SUBJECT TO SOIL DAMPNESS

The method for short-term forecasting of water flow and the probability of mudflow in mountain rivers on the basis of neural networks using hydrometeorological data observation and soil moisture forecasting is suggested.

Key words: short-term forecasting, catastrophic floods, mudflow generating factors, neural network technologies, soil dampness.

Introduction. Natural phenomena such as catastrophic floods and floods are among the natural disasters. Like other natural disasters, they cause serious disruptions to the normal life of the population, destruction and destruction of material assets, and also have a negative impact on the environment.

Currently, there are no methods with sufficient probability to predict catastrophic hydrological phenomena. For some flood areas, certain criteria have been established to assess the likelihood of flooding. Thus, for regions with the highest probability of storms, a large amount of precipitation is determined within 1-3 days, and glacial mudslides-heavy average air temperature for 10-15 days or a combination of these two criteria. But this assumption is not accurate because many other factors influence the occurrence of catastrophic floods and floods.

Mudflows and floods are common in the highlands of Kyrgyzstan. There are six large rural areas identified here: basin

Talassky river, Chuisky River basin (Ala-Archa, Aksai, Adygen, Karabaltina, Aksu, Sokuluk, etc.) (Issyk-Kul basin, Chatkal mountain range basins, Naryn River basin (Chichkan River) and the northern slope of the Alai mountain range. Therefore, the task of forecasting the risk of floods and floods in these regions is very relevant.

Formulation of the problem of short-term flood forecasting. [1] to create torrents, three conditions must be met.

1. The presence in the foothills and depressions of a sufficient number of weathering products of rocks forming a rigid phase of mudflows. If the volume of free block material is small, normal mountain flows occur due to low saturation.

2. The presence of sufficient water for leakage or destruction and movement through the grooves of the loose material of the block. In the absence of appropriate water masses, the processes of gravitational bias, and not landslides – precipitation, collapses, landslides, etc. The main sources of flood water are rains and downpours, as well as melting ice and snow.

3. Highly dissected mountain relief, which causes the presence of steep slopes, slopes and riverbeds, i.e. ensuring the simultaneous movement of significant volumes of water-ground masses at high speeds.

A serious indicator of a possible mudflow-prone period is the strong moistening of soils as a result of prolonged rains. Each of them, neither in duration, nor in intensity, nor in the amount of precipitation, can cause mudflow, but in total such a period contributes to the formation of a mudflow.

Taking into account soil moisture in predicting flood and mudflow hazards is very important, sometimes crucial. Soil moisture affects the absorbency, therefore, the volume of wastewater. In addition, waterlogged soil can cause the surface layer of soil to slide into the riverbed, which can provoke the formation of a mudflow.

The influence of air temperature on mudflow formation is ambiguous. An increase in air temperature, as a rule, does not contribute to heavy precipitation – usually intense rains are preceded by a decrease in temperature. But the high temperature causes more intense melting of glaciers and

snowfields and contributes to the accumulation of water masses in the cavities of glaciers and an increase in water flow in the riverbed.

An additional indicator of the mudflow hazard is the stability of the air temperature during the 5-6 days preceding the mudflow [2].

The multifactorial nature of the problem and the ambiguity of the influence of some parameters on the formation of a mudflow causes great difficulties when trying to describe it using traditional mathematical apparatus. In contrast to such methods, neural network technologies allow, subject to the incompleteness of the initial data, to lay an assessment of interdependence in its entirety, without its decomposition into parts. This approach is used when it is difficult to describe complex geospatial phenomena in detail. The possibility of using neural network technology in predicting natural disasters was shown in [3]. In this paper, the possibility of using neural network technologies to predict flood and mudflow hazards is investigated.

Formation of a training array based on information-relevant parameters. When solving a problem using neural network technologies, it is necessary to collect data for training. The training dataset is a set of observations for which the values of input and output variables are specified. The network learns to establish a connection between the first and second. Usually the training data is taken from the observation results.

The method was tested on the example of the Ala-Archa mountain river and its tributaries. In the process of training the neural network to predict mudflow hazards, archival data of the hydro-meteorological Service (HMS) for more than half a century were used. The specifics of the HMS are such that in this archive there are no such informationally significant parameters for predicting mudslides as the volume of loose blockage material on mudslide-prone slopes (prerequisite 1) and soil moisture in the pre-forecast period. As mentioned above, without taking into account these parameters, the forecast of the mudflow is one-sided and incomplete.

If the volumes of loose materials in mudflow-prone areas can be visually assessed, at least approximately, then the determination of soil moisture in mountainous areas causes significant difficulties due to the wide variety of soil classes: loose, dense, mixed. In addition, soils of various classes are often located interspersed within the same mudflow zone, "tongues". Soil moisture in neighboring "languages" can vary greatly. It seems irrational to install soil moisture sensors in various zones. In addition, an increase in signals at the inputs of a neural network can reduce the accuracy of its forecast. A possible way out in this situation is to determine the class of weather conditions affecting the state of soil moisture [4] and take this class into account when predicting flood and mudflow hazards. With this approach, it is possible to abandon the use of soil moisture sensors altogether, or at least drastically reduce their number.

Such an emergency situation as the passage of a mudflow does not occur instantly, it is determined by the prehistory of the hydrothermal regime for several days. According to the recommendation proposed in [5], this is the time interval of the six preceding days.

For the controlled target, 30 situations with high floods and mudslides were registered during the study period. Each situation was monitored for 10 days. Thus, information on three hundred implementations was included in the data package. Taking into account the background, a lot of 120 scenarios turned out. Based on the data of field observations, a virtual training set with noise of various variances was created.

In accordance with the accepted algorithm, the prediction of mudflow hazard is carried out in four stages.

1. Classification of a set of parameters that have the greatest impact on the state of soil moisture is carried out (neural network NSV). A neural network NSR is created and trained, predicting the maximum (Q_{max}) and average daily (Q_{sr}) water consumption in a controlled alignment with a lead time of N days. A neural network NSS is created and trained, predicting the probability of passing a mudflow for the predicted period of N days. This stage is preliminary and is performed once.

2. The soil moisture class is predicted for the forecast period with the help of a trained NSV neural network.

3. The maximum and average daily water consumption in the controlled range is predicted using a trained neural network of the NSR. At the same time, the value of the soil moisture class modeled by NSV is taken into account. In turn, the simulated results of the Qmax and Qsr forecast, along with other data, are input information for the NSS neural network that predicts mudflow hazard.

4. The probability of passing a mudflow for a period of N days is predicted using a trained neural network NSS.

Let's take a closer look at the functioning of the algorithm at each of the stages.

Classification of weather conditions that determine soil moisture. A self-organizing neural network, the Kohonen layer, was used to distribute scenarios that determine the distribution of weather conditions by classes [6]. Neurons of a self-organizing network can be trained to identify groups (clusters) of input vectors with some common properties. Training (without a teacher) is conducted on a virtual set and data from field observations. Then a radial basic neural network NSB [7] is created and trained according to the clustering data of the Kohonen layer. The output information of the NSV is a vector of indices of soil moisture classes for all scenarios

According to the HMS, information on 300 flood situations was processed. Taking into account the six-day background, 120 scenarios were created. As informatively significant parameters for determining the state of soil moisture, the following were taken:

- Average daily air temperature, observation and forecast (7 signals);
- Average daily humidity, observation and forecast (7 signals);
- Daily precipitation, observation and forecast (7 signals);
- Average daily wind speed, observation and forecast (7 signals).

A total of 28 signals.

The result of the simulation is an index vector

```
V_ind=2 2 1 1 2 1 4 4 3 3 3 5 5 5 1 4 4 4 1 1 4 4 3 3 3 3 5 5 5 2 2 1 3 3 3 3  
3 3 3 3 3 3 1 1 4 4 5 5 1 2 1 4 4 4 3 1 1 5 3 3 1 1 5 5 5 2 5 1 1 4 2 1 2 2  
2 1 1 1 3 1 1 5 2 1 5 5 4 4 4 4 1 5 5 5 2 2 2 2 2 2 4 4 4 4 4 4 4 2 2 2 2
```

The result of the correspondence of humidity classes to their weight values, based on the analysis of weather conditions, is shown in Table 1.

Table 1 – Correspondence of soil moisture classes to weight values

Class no.	1	2	3	4	5
Weight value	0.8	0.4	0.2	1.0	0.6

Using the classification of soils by water saturation, classes 2 and 3 can be attributed to low-moisture, class 5 - to wet, classes 1 and 4 – to saturated with water. It is the latter that pose the greatest flood/mudflow danger. After installing the ground moisture control sensor, it will be possible to adjust the weight values of the specified classes.

Based on Table 1, the index vector V_{ind} corresponds to the vector of values of weights of soil moisture classes:

Prediction of soil moisture class

An input vector is formed, which includes the above signals. Based on the values of these signals, the NSV trained at the previous stage simulates the soil moisture class. Then, according to the compliance table, its weight value is determined, which will be used at the next stages of forecasting flood and mudflow hazards.

Forecasting of maximum and average daily flood costs

To predict the maximum and average daily flood costs, an NSR neural network based on a two-layer perceptron was created. The choice of neural network architecture is determined by a set of input and output signals. Of the many informative flood-forming characteristics in the short-term forecasting of water consumption, the most significant ones were selected:

1. Water flow in the river (average daily and maximum);
2. Air temperature (average daily and maximum);
3. Daily precipitation;

4. Soil moisture class.

For each position, an archived data set is used for 6 days preceding the forecast. In addition, a daily forecast is used for the maximum and average daily air temperature and the expected amount of precipitation (according to the HMS observation data) and a forecast of the soil moisture class (modeled by NSV). Thus, the structure of the NSR input signals has the form:

- Background of maximum flood costs (6 signals);
- Background of average daily flood costs (6 signals);
- Background and forecast of maximum air temperature (7 signals);
- Background and forecast of the average daily air temperature (7 signals);
- Background and forecast of daily precipitation (7 signals);
- Forecast of the soil moisture class (1 signal).

A TOTAL of 34 input signals.

The structure of the NSR output signals has the form:

- The predicted value of the maximum flow rate;
- The predicted value of the average daily consumption.

A TOTAL of 2 output signals.

Based on the above, the algorithm for short-term forecasting of catastrophic floods based on meteorological and hydrological data with a one-day lead time is to perform the following sequence of actions:

1. Determination of the subsystem of informative flood-forming characteristics. Based on it, the structure of the input and output signals of the NSR is determined.
2. Selection of the type, architecture and algorithms of NSR training: a two-layer perceptron; the first (hidden) layer – 34 neurons with the logsig activation function; the second layer - 2 neurons with the same logsig activation function; the range of input and output signals after scaling (0; 1). The architecture of the NSR neural network is shown in Fig. 1.
3. Creating a virtual training set based on field observations (scaled input signals and values of target functions).
4. Determination of the initial parameters of the NSR.
5. NSR training. Initial training was conducted on a training set of 120 scenarios with normal noise having minimal variance. Then the NSR was retrained. 10 cycles of 120 scenarios were carried out, each time increasing the noise dispersion.
6. Testing of a trained NSR on a control set consisting of 120 scenarios. The output signals of the neural network were converted to the desired format by multiplying by a scale factor (post-processing stage).

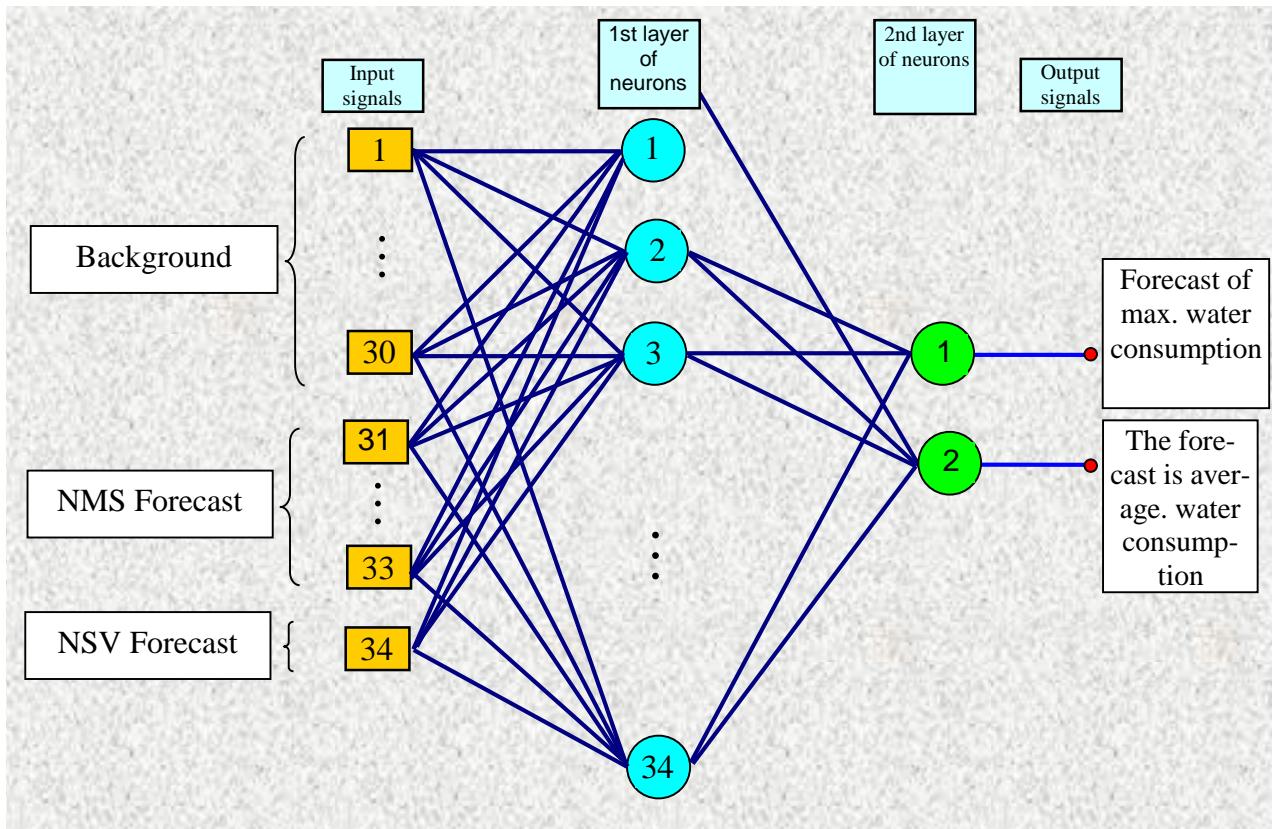


Fig. 1. The architecture of the neural network of the NSR for predicting the maximum and average daily flow of water in the river channels during the passage of a flood.

The results of the forecast values and field observations of the maximum and average daily expenses are shown in the form of graphs (Fig. 2, 3).

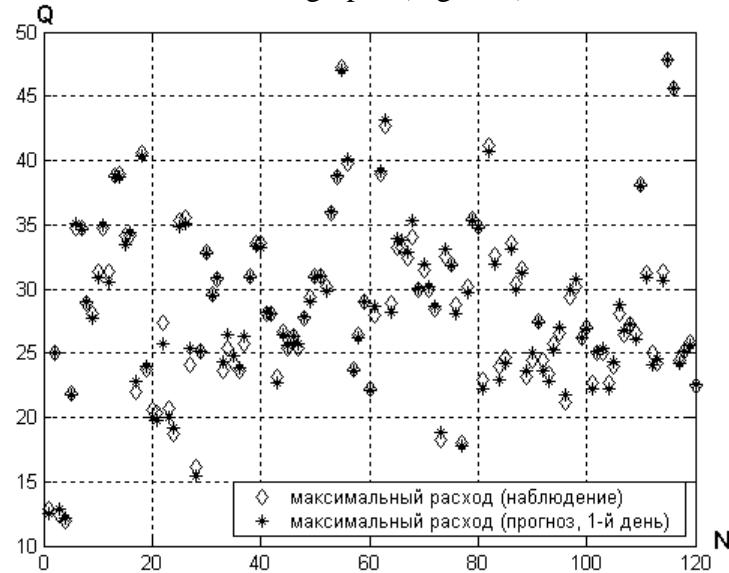


Fig. 2. Target function signals and NSR output signals (maximum flow rate).

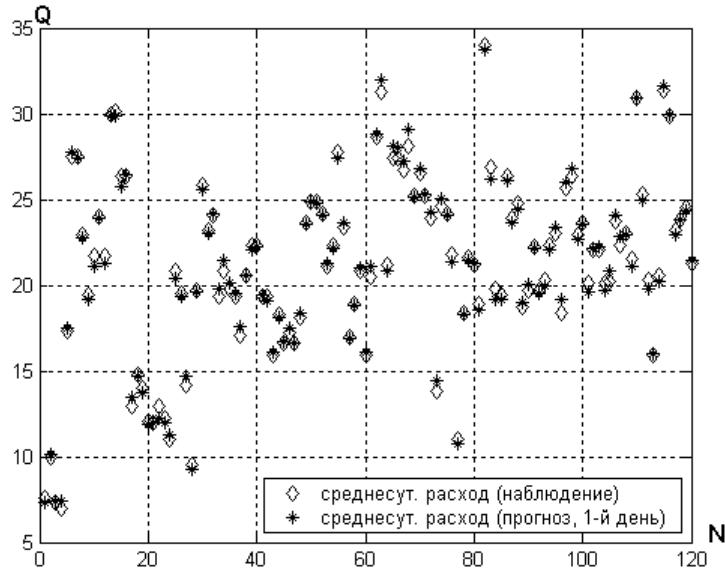


Fig. 3. Target function signals and NSR output signals
(average daily consumption).

In these graphs, N is the scenario number, Q is the water flow rate (m^3/s). The graphs demonstrate acceptable accuracy of the forecast of maximum and average daily water consumption during the flood period in the basin of the Ala-Archa river. The standard error for 120 scenarios for maximum expenses is $\sigma_{\max}=0.0509$, for average daily expenses – $\sigma_{\text{sr}}=0.0180$.

With the help of a trained neural network, it is possible to obtain a flow forecast for a time interval of up to N days, consistently displacing earlier observation data and applying the forecast of the hydrometeorological service and the simulated values of Q_{\max} and Q_{ch} .

Prediction of the probability of mudflow passage

This stage is the final stage in predicting flood/mudflow hazards. Its purpose is a short-term prediction of the probability of a glacial-stormwater genesis mudslide using neural network technologies and data from observations and forecasts of the hydrometeorological service.

Three necessary conditions for the formation of a mudflow were listed above:

1. Sufficient masses of loose materials (*MPM*);
2. Sufficient water to flush and move these masses;
3. Sufficient steepness of mountain slopes.

Let's consider taking these factors into account when forming input vectors of a neural network for its training and modeling.

1. Most works on the prediction of mudflow hazard are based only on hydrometeorological forecasting of mudflow formation conditions and do not contain attempts to quantify geological and soil conditions, without which any forecast of mudflow formation is one-sided and, therefore, insufficiently accurate. In [8], methods of approximate prediction of the mudflow-prone period were proposed, taking into account the mass of loose blockage material on the mountain slopes of the region under consideration. The author offers special tables in which the point indices of accumulation of loose-block material are given (from +2 for a very large accumulation of products of destruction of rocks to -2 for their insignificant accumulation). A similar table was proposed by him to assess soil moisture. But these indices are not entered by the author into the calculation formulas and represent only indirect indicators of mudflow hazard. His proposed method takes into account only three factors (precipitation, pre-moistening of soils and accumulation of loose material). And although such attempts are a step forward in comparison with the methods of forecasting mudslides only by hydrometeorological indicators, this method can only be considered as a preliminary, roughly approximate method of estimating the mudflow-prone period.

In the development of the previous stages of predicting mudflow hazard [9], in this work, the mass of loose-block materials is taken into account by creating appropriate signals in the input vectors. Since accurate accounting of *MPM* in mudslide-prone regions has not been carried out and re-

quires the development of monitoring and control services, the values of this parameter will be estimated in the range (0, 1). By analogy with the definition of the soil moisture class, we introduce the concept of the *MPM* class. We will assign a weight value from zero to one to each class. Suppose that there are N mudflow-prone areas in a mudflow-prone zone. We will distribute the values of $MPMi$, $i=1,N$ by classes in accordance with Table 2.

Table 2.– Weight values of *MPM* classes.

Class no.	1	2	3	4	5
Weight value	0 – 0.2	0.2 – 0.4	0.4 – 0.6	0.6 – 0.8	0.8 – 1.0

The *MPM* values in the range (0.8 – 1) correspond to their critical masses, at which mudflow manifestations previously occurred. If there are tributaries of the river under study, their mudflow-prone areas are also evaluated. For training and modeling of the neural network NSS, predicting the probability of a mudslide, $MPM=\max MPM_i$, $i=1,N$. is used. In the absence of a critical *MPM* value, we can talk not about a village, but about a major flood or mudflow.

In the virtual training array, if there is a fact of a mudslide throughout the entire forecast period, we assume $MPM = 1$. After the mudslide, we assign $MPM = 0$. In the intermediate time intervals, we assume $MPM = 0.5$. When modeling the probability of a mudslide in real conditions, it is assumed to use expert assessments of monitoring services or their calculated values to determine the *MPM*.

When performing this work, the conditions of mudflow formation in the basins of the Ala-Archa river and its two tributaries: Aksai and Adygen were considered. Each of the studied rivers has a different potential for the formation of *MPM*. For example, the Golubina glacier is located in the upper reaches of the Aksai River, the moraine lakes of which regularly overflow and dump glacial deposits down. Therefore, mudslides in the basin of this river occur almost annually, sometimes repeatedly. The observation of the deposition of loose materials in the basin of this river is especially relevant.

The friable material in the basin of the Adygen River is mainly supplied by the moraine lake Tez-Ter, the overflow of which and the discharge of glacial deposits occur less frequently, but sometimes with catastrophic consequences.

The forecast of mudflows caused by the breakthrough of moraine lakes requires a different kind of information, and the possibility of using neural network technology in this case requires additional research. In this regard, scenarios corresponding to the dates of a mudslide of the breakthrough type are not included in the training array in order to avoid a distorted interpretation of contradictory information by the neural network. So, for example, the hydrothermal data corresponding to a mudflow of the "breakthrough" type (Lake Tez-Ter, the breakthrough occurred on 22.06.1953) do not differ from the average statistical data that do not portend a mudflow hazard. The corresponding scenarios are excluded from the training array.

2. The amount of water is, as a rule, the fundamental factor determining the initial moment of the formation of a glacial-stormwater mudflow genesis. The coincidence of two water factors: increased water consumption in the river and waterlogging of the soil in the presence of a critical mass of loose material leads to increased mudflow hazard.

3. The steepness of the mountains is a constant value and does not affect the result of the output signals of the neural network.

Thus, when predicting a mudflow hazard, the input vectors of the training set must contain information on the first two positions. During the period under review, 30 situations with high floods were registered, but not all of them had mudflow manifestations. The most typical reasons for this are insufficient moistening of the soil and the absence of a critical mass of loose materials.

Based on the above, the structure of the input vectors of the training set has the form:

- Forecast of maximum and average daily consumption (2 signals, NSR);
- Forecast of soil moisture class (1 signal, NSV);
- The maximum value of the *MPM* class (1 signal, visual observation).

In total, 4 input signals.

The small number of input signals is due to the fact that all informatively significant hydro-meteorological factors were taken into account at the previous stages. The simple structure of the input vectors allows the use of a simplified architecture of the neural network NSS, developed for the prediction of mudflow hazard.

Since the purpose of the NSS is to simulate the probability of a mudslide, the output vector consists of a single signal. If there is a mudflow in any scenario, the value of this signal (probability p) is assumed to be 1, otherwise $p = 0$.

For a short-term forecast of mudflow hazard, taking into account additional parameters (soil moisture and the mass of loose blockage material), the structure of a two-layer perceptron was adopted. The architecture of the NSS and the distribution of signals in the input training vectors are shown in Fig. 4.

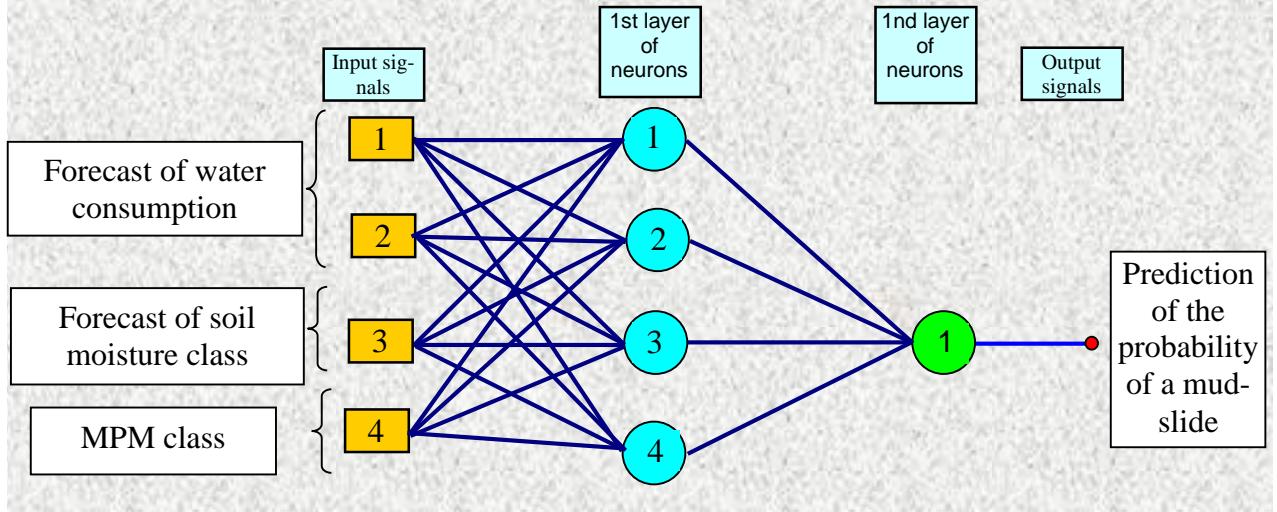


Fig. 4. The architecture of the neural network NSS.

At the preprocessing stage, the values of all input signals are reduced to the range $(0, 1)$. Testing of the NS was carried out according to the observation data of the hydrometeorological service. The results of the simulated values are shown in Fig. 5. Here p is the probability of a mudflow, N is the number of scenarios. Events with probability values $p < 0.5$ will be considered unlikely.

As can be seen from the graph (Fig. 5), in the presence of the fact of a mudslide, the predicted values of the probability of a mudslide are $p > 0.5$, i.e. the simulated values of p correctly predicted the possibility of a mudslide. However, there are p values close to one for a failed village. Analysis of hydrometeorological factors has shown that these scenarios are close to mudflow situations.

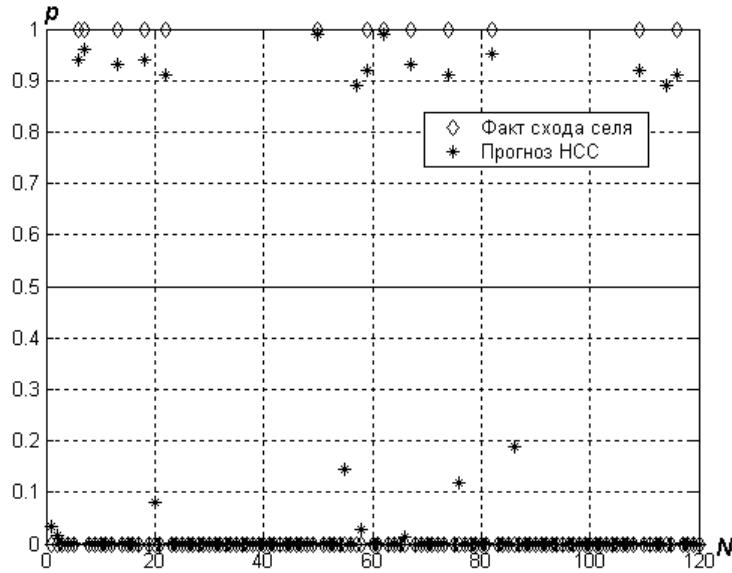


Fig. 5. Forecast values of the probability of a mudslide, modeled by the NSS.

Thus, the algorithm for short-term forecasting of mudflow hazard based on meteorological and hydrological data, as well as geological and soil conditions with a one-day lead time is to perform the following actions:

1. Determination of the subsystem of informative self-forming characteristics. Based on it, the structure of the input and output signals of the NSS is determined.
2. Creation of a virtual training set (training vectors) based on simulated forecast values of flood parameters and data from field observations with noise of various variances (input signals and values of target functions).
3. Transformation of training vectors (pre-processing stage).
4. Selection of the type, architecture and algorithms of NSS training.
5. Determination of the initial parameters of the NSS.
6. NSS training.
7. Conversion of the NSS output signals to the original format (post-processing stage).
8. Testing of the trained NSS on control and test sets.

With the help of a trained neural network, it is possible to obtain a forecast of mudflow hazard over a time interval of up to n days, sequentially displacing the earliest observation data and applying the HMS forecast, simulated values of soil moisture classes, forecast values of water consumption Q_{max} and Q_{sr} .

The scheme of connection of neural network modules NSV, NSR and NSS when predicting mudflow hazard with a lead time of 1-3 days is shown in Fig. 6.

When comparing the structure of the input signals of the neural network modules of the NSR in Fig. 6, it can be seen that the observational data are partially replaced by predictive ones as the forecast time increases. Naturally, an accumulation of errors occurs in this case, caused by both the errors in the forecast of the HMS and the results of modeling the NSR of water flow in the river. In this regard, a three-day forecast can only be used for a roughly approximate estimate, which should be adjusted as fresh data is obtained: forecast, simulated and field observations.

From the analysis of the algorithm developed by us, it follows that the method of forecasting flood and mudflow hazards using neural network technologies combines the properties of universality and regionality. The universality of the method lies in the fact that when using it for the basins of various mountain rivers, the type, architecture, parameters and algorithms of neural network training are preserved, and the regionality is in the need to retrain them based on archival and forecast data of specific regions.

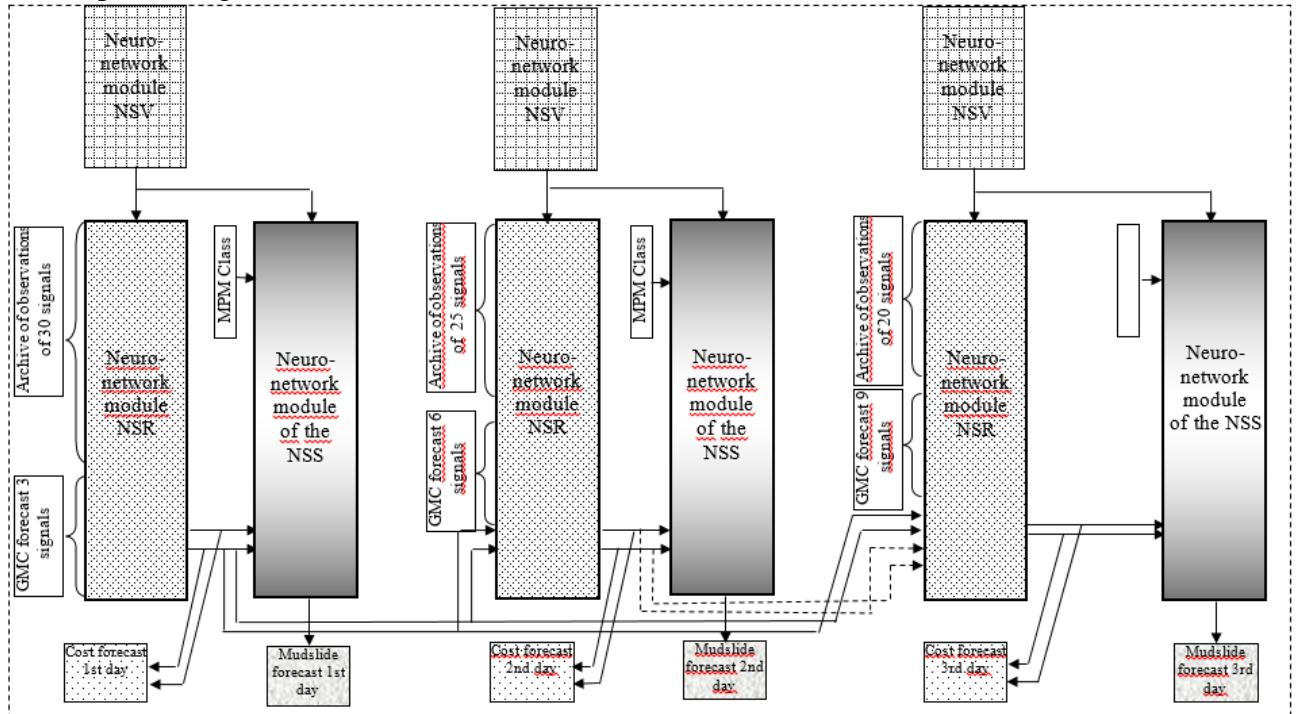


Fig. 6. The sequence of neural network connections in the prediction of mudflow hazard with a lead time of 1-3 days

Conclusion. Taking into account such informatively significant parameters as soil moisture and the mass of loose materials can significantly improve the accuracy of the prediction of mudflow hazard. Nevertheless, the methods we have proposed can only be considered an approximation to an accurate forecast. The main reasons preventing a more accurate forecast:

1. Neural networks can recognize only those villages that are close in parameters to the villages from the training data set. In this regard, it is desirable to carry out additional training of neural networks after passing each new mudflow.

2. Mudflows caused by the breakthrough of moraine lakes are extremely rare and, accordingly, there is not enough information on them to train neural networks. To predict the breakthrough of a moraine lake, it is necessary to organize monitoring of changes in the water level and visual surveys of the state of moraine dams.

There are other, insufficiently studied factors affecting the process of mudflow formation. A significant number of factors involved in mudflow formation and the complex nature of their interaction at this stage of the phenomenon study exclude the possibility of an accurate prediction of mudflow hazard. However, the inclusion in the training sets of new scenarios of catastrophic floods and mudslides as they are received in the monitoring process and the additional training of neural networks on additional examples will significantly improve the accuracy of the forecast.

Л. И. Великанова

КР НАНын автоматика жана маалыматтык технологиялар институту

ЭСКЕ АЛУУ МЕНЕН ТООЛУУ РАЙОНДОРДО СЕЛ ЖАНА СЕЛ КОРКУ- НУЧТАРЫНЫН КЫСКА МӨӨНӨТТҮҮ БОЛЖОЛУ ТОПУРАКТЫН НЫМДУУЛУГУ

Гидрометеорология кызматынын байкоо маалыматтарын жана жер кыртышынын нымдуулугун болжолдоону колдонуу менен нейрон тармактарынын базасында тоо селдеринде селдин өтүү ыктымалдуулугун кыска мөөнөттүү болжолдоо ыкмасы сунушталды.

Ачкыч сөздөр: кыска мөөнөттүү болжолдоо, катастрофалык суу ташкыны, стилдик факторлор, нейросет технологиилары, жердин нымдуулугу.

Киришүү. Катастрофалык суу ташкыны жана сел сыйктуу жаратылыш кубулуштары табигый кырсыктардын катарына кирет. Башка табигый кырсыктар сыйктуу эле, алар калктын нормалдуу жашоо-турмушунун кескин бузулушун, материалдык баалуулуктардын жок болушун жана жок болушун шарттайт, ошондой эле айлана-чөйрөгө терс таасирин тийгизет.

Азыркы учурда, катастрофалык гидрологиялык кубулуштарды болжолдоонун жетиштүү ыктымалдыгы бар ыкмалары жок. Айрым сел райондору учун селдин пайда болуу ыктымалдуулугун баалоого мүмкүндүк берген белгилүү критерийлер белгиленген. Ошентип, бороон-чапкын келип чыгышы ыктымал болгон аймактар үчүн жаан – чачындын оор суммасы 1-3 суткада, ал эми гляциалдык келип чыккан селдер-10-15 суткадагы абанын оор орточо температурасы же ушул эки критерийдин айкалышы аныкталат. Бирок мындай божомол так эмес, анткени. катастрофалык суу ташкындарынын жана селдердин пайда болушуна көптөгөн башка факторлор таасир этет.

Кыргызстандын бийик тоолуу аймагында сел жана суу ташкыны көп кездешет. Бул жерде айылга кооптуу алты ири район белгиленди: бассейн Талас дарыясы, Чүй дарыя бассейни (Ала-Арча, Аксай, Адыгене дарыялары, Карабалта, Аксу, Сокулук ж. б.), Ысык-Көл бассейни, Чаткал тоо кырkalарынын бассейндери, Нарын дарыясынын бассейни (Узунхалат, Чичкан дарыялары) жана Алай тоо кырkalарынын түндүк жантайышы. Ошондуктан, бул аймактарда сел жана сел коркунучун болжолдоо милдети өтө актуалдуу болуп саналат.

Селди кыска мөөнөттүү болжолдоо маселесин коюу. [1] ылайык, максаттарды түзүү учун үч шарт аткарылышы керек.

1. Тоо этектеринде жана нуктарында сел агымынын катуу фазасын түзө турган тоо тектеринин бузулуу продуктуларынын жетиштүү болушу. Эгерде бош блок материалынын көлөмү кичинекей болсо, анда кадимки тоо агымдары аз каныккандыктан пайда болот.

2. Ағызуу же бузуу учун жетиштүү суунун болушу жана бош блок материалынын нуктары аркылуу жылуу. Тиешелүү суу массалары жок болгон учурда сел эмес, гравитациялык жантайма процесстер – жаан-чачындар, кулоолор, жер көчкү ж.б. журөт. Туздардын негизги суу булагы жаан-чачын жана нөшөр, ошондой эле муздун жана кардын эриши.

3. Тик эңкейиштердин, эңкейиштердин жана дарыялардын болушун шарттаган, б.а. суу-кыртыш массаларынын Олуттуу көлөмдөрүнүн чоң ылдамдык менен бир убакта кыймылын камсыз кылуучу өтө бөлүнгөн тоо рельефи.

Мүмкүн болгон селе коркунучу мезгилиниң олуттуу көрсөткүчү узак, узак жааган жамгырдын натыйжасында топурактын топурактарынын күчтүү нымдалышы болуп саналат. Алардын ар бири узактыгы боюнча да, интенсивдүүлүгү боюнча да, түшкөн жаан-чачындын көлөмү боюнча да селендин пайда болушуна алып келбейт, бирок жалпысынан мындай мезгил селдин пайда болушуна өбөлгө түзөт.

Сел жана сел коркунучун болжолдоодо топурактын нымдуулугун эсепке алуу өтө чон, кээде чечүүчү мааниге ээ. Топурактын нымдуулугу сицирүү жөндөмүнө, демек, агын

суулардын көлөмүнө таасир этет. Мындан тышкary, суу баскан топурак селдин пайда болушун шарттагандан көрө, жердин үстүңкү катмарынын дарыянын нугуна жылышина алып келиши мүмкүн.

Абанын температурасынын селдин пайда болушуна тийгизген таасири түшүнүксүз. Абанын температурасынын жогорулаши, адатта, жаан – чачындын көп болушуна шарт түзбөйт-адатта, катту жаан-чачындар температуранын төмөндөшүнө чейин болот. Бирок жогорку температура мөнгүлөрдүн жана кар бүртүкчөлөрүнүн эришине алып келет жана мөнгүлөрдүн көндөйүндө суу массасынын топтолушуна жана дарыянын нугунда суунун чыгымынын көбөйшүнө ебөлгө түзөт.

Айыл коркунучунун кошумча индикатору болуп селден мурунку 5-6 сутканын ичинде абанын температурасынын туруктуулугу эсептелет [2].

Маселенин көп факторлуулугу жана сел агымынын калыптанышына айрым параметрлердин таасириниң түшүнүксүздүгү аны салттуу математикалык аппарат менен сүрөттөө аракетинде чоң кыйынчылыктарды жаратат. Мындаи ыкмалардан айырмаланып, нейросет технологиялары баштапкы маалыматтар tolук эмес болгон шартта, өз ара көзкарандылыкты толугу менен баалоого мүмкүндүк берет, аны бөлүктөргө бөлбөстөн. Мындаи мамиле татаал Геомейкиндиктик кубулуштарды деталдуу сүрөттөө кыйынчылыгында колдонулат. Табигый кырсыктарды болжолдоодо нейрон тармагынын технологиясын колдонуу мүмкүнчүлүгү [3] көрсөтүлгөн . Бул эмгекте суу ташкынын жана сел коркунучун болжолдоо үчүн нейросет технологияларын колдонуу мүмкүнчүлүгү изилденет.

Маалыматтык маанилүү параметрлердин негизинде окутуу массивин түзүү.

Тапшырманы нейросет технологиясы менен чечүүдө окутуу үчүн маалыматтарды чогултуу керек. Окутуу маалымат топтому-бул киргизүү жана чыгаруу өзгөрмөлөрүнүн маанилери көрсөтүлгөн байкоолордун жыйындысы. Тармак биринчи менен экинчисинин ортосунда байланыш түзүүнү үйрөнөт. Адатта, окутуу маалыматтары байкоолордун натыйжаларынан алынат.

Методду апробациялоо Ала-Арча тоо дарыясынын жана анын куймаларынын мисалында жүргүзүлдү. Нейрон тармагын сел коркунучун болжолдоого үйрөтүү процессинде гидрометеорология кызматынын (ММК) жарым кылымдан ашык мезгилдеги архивдик маалыматтары колдонулган. МККнын өзгөчөлүгү бул архивде селди болжолдоо үчүн сел коркунучу бар боорлордогу борпон блоктук материалдын көлөмү (зарыл 1-шарт) жана болжолдоо алдындагы мезгилдеги топурактардын нымдуулугу сыйктуу маалыматтык маанилүү параметрлер жок. Жогоруда айтылгандай, бул параметрлерди эске албаганда, селдин божомолу бир тарааптуу жана төмөн.

Эгерде селге кооптуу зоналардагы борпон блоктук материалдардын көлөмү болжол менен болсо да визуалдык баалоого мүмкүн болсо, анда тоолуу жерлердеги топурактардын нымдуулугун аныктоо кыртыштын көп түрдүү класстарына: борпон, тыгыз, аралаш катмарларга байланыштуу олуттуу кыйынчылыктарды жаратат. Мындан тышкary, көп учурда бир айыл-кооптуу зонанын чегинде ар кандай класстардагы топурактар "тилдер", "тил" менен жайгашат. Коншу "тилдерде" топурактын нымдуулугу такыр башкача болушу мүмкүн. Ар кандай зоналарда топурактын нымдуулук сенсорлорун орнотуу абылга сыйбайт. Мындан тышкary, нейрон тармагынын кириштериндеги сигналдарды көбөйтүү анын божомолунун тактыгын азайтышы мүмкүн. Бул жагдайда мүмкүн болгон жол топурактын нымдуулугунун абалына таасир этүүчү аба-ырайынын шарттарынын классын аныктоо болуп саналат [4] жана сел жана сел коркунучун болжолдоодо ушул классты эсепке алуу. Мындаи ыкма менен жердин нымдуулук сенсорлорун колдонуудан таптакыр баш тартууга же жок дегенде кескин кыскартууга болот.

Селден өтүү сыйктуу өзгөчө кырдаал заматта болбойт, ал бир нече күндүн ичинде гидротерминалык режимдин тарыхы менен аныкталат. Сунуш боюнча сунушталган [5], бул-алты күн чейинки убакыт аралыгы.

Контролдонуучу тирөөч үчүн изилдөө мезгилинде суу ташкыны жана сел көрүнүштөрү жогору болгон 30 кырдаал катталган. Ар бир кырдаал 10 күндүн ичинде байкалып турду. Ошентип, маалымат пакетине тремст ишке ашыруу боюнча маалымат киргизилген. Тарыхты эске алганда, 120 сценарийдин көпчүлүгү пайда болду. Табигый байкоо маалыматтарынын негизинде ар кандай дисперсиялардың ызы-чуусу менен виртуалдык окутуу топтому түзүлдү.

Кабыл алынган алгоритмге ылайык сел коркунучун болжолдоо төрт этапта жүргүзүлөт.

1. Топурактын нымдуулугунун абалына эң көп таасир этүүчү параметрлердин жыйындысын классификациялоо жүргүзүлөт (НСВ нейрон тармагы). НСРнын нейрон тармагы түзүлөт жана окутулат, ал контролдонуучу чекте суунун максималдуу (Q_{max}) жана орточо суткалыш (Q_{cp}) чыгымдарын бир суткага чейин алдын ала болжолдойт. Селдин N сутканын болжолдонгон мезгилине өтүү мүмкүнчүлүгүн болжолдогон НССтин нейрон тармагы түзүлөт жана окутулат. Бул этап алдын-ала жана бир жолу аткарылат.

2. НСВнын үйрөтүлгөн нейросет тармагынын жардамы менен болжолдонгон мезгилге кыртыштын нымдуулугунун классы болжолдонот.

3. НСРдин үйрөтүлгөн нейросет тармагынын жардамы менен контролдонуучу капкактагы суунун максималдуу жана орточо суткалыш чыгымдары болжолдонот. Мында топурактын нымдуулук НСВ классынын моделделген мааниси эске алынат. Өз кезегинде, Q_{max} жана Q_{cp} божомолдорунун моделделген натыйжалары, башка маалыматтар менен катар, сел коркунучун болжолдоону жүзөгө ашырган НСС нейрон тармагы үчүн кириш маалымат болуп саналат.

4. Селдин N суткага өтүү ыктымалдыгы НССтин үйрөтүлгөн нейросетинин жардамы менен божомолдонууда.

Алгоритмдин ар бир этапта иштешин кененирээк карап көрөлү.

Топурактын нымдуулугун аныктоочу аба-ырайынын шарттарынын классификациясы. Аба ырайынын класстарга бөлүштүрүлүшүн шарттаган сценарийлерди бөлүштүрүү үчүн, өзүн – өзү уюштурган нейрон тармагы-кохонен катмары колдонулган [6]. Өзүн-өзү уюштурган тармактын нейрондору жалпы касиеттерге ээ болгон кирүү векторлорунун топторун (кластерлерин) аныктоого үйрөтүлүшү мүмкүн. Окутуу (мугалимсиз) виртуалдык топтомдо жана табигый байкоолордун маалыматында жүргүзүлөт. Андан кийин НСВ радиалдык базалык нейрон тармагы түзүлөт [7] жана кохонен катмарынын кластерлөө маалыматтары боюнча окутулат. НСВнын Чыгыш маалыматы бардык сценарийлер үчүн топурактын нымдуулук класстарынын индексинин вектору болуп саналат

ММКнын маалыматы боюнча 300 суу ташкынын кырдаал боюнча маалымат иштелип чыккан. Алты күндүк тарыхты эске алганда, 120 сценарий түзүлдү. Топурактын нымдуулугунун абалын аныктоо үчүн маалыматтык маанилүү параметрлер катары кабыл алынды:

- Абанын орточо суткалыш температурасы, байкоо жана болжолдоо (7 сигнал);
- Абанын орточо күндүк нымдуулугу, байкоо жана болжолдоо (7 сигнал);
- Күнүмдүк жаан-чачын, байкоо жана болжолдоо (7 сигнал);
- Шамалдын орточо суткалыш ылдамдыгы, байкоо жана болжолдоо (7 сигнал).

Бардыгы 28 сигнал.

Моделдөө натыйжасы индекси багыты болуп саналат

V_{ind}=2 2 1 1 2 1 4 4 3 3 3 3 5 5 5 5 1 4 4 4 1 1 4 4 3 3 3 3 3 5 5 5 2 2 1 3 3 3 3
3 3 3 3 3 3 3 1 1 4 4 5 5 1 2 1 4 4 4 3 1 1 5 3 3 1 1 5 5 5 2 5 1 1 4 2 1 2 2
2 1 1 1 3 1 1 5 2 1 5 5 4 4 4 4 1 5 5 5 2 2 2 2 2 2 4 4 4 4 4 4 4 2 2 2 2

Нымдуулук класстарынын аба-ырайынын шарттарына талдоо жүргүзүүнүн негизинде алардын салмактык маанилерине дал келишинин натыйжасы 1-таблицада көлтирилген.

1-Таблица - топурактын нымдуулук класстарынын салмактык маанилерге дал келиши

Класстын №	1	2	3	4	5
Салмак мааниси	0.8	0.4	0.2	1.0	0.6

Топурактын суу каныккандыгы боюнча классификациясын колдонуп, 2 жана 3 – класстарды нымдуу эмес, 5 – классты нымдуу, 1 жана 4-класстарды суу менен каныккан деп бөлсө болот. Акыркы суу ташкыны/сел коркунучу жогору. Топурактын нымдуулук сенсорун орноткондон кийин, көрсөтүлгөн класстардын салмак маанилерин жөндөө мүмкүнчүлүгү пайда болот.

1-таблицанын негизинде V_{ind} индекс векторуна топурактын нымдуулук класстарынын салмактарынын маанилеринин вектору дал келет:

Топурактын нымдуулук классын болжолдоо

Жогорудагы сигналдарды камтыган киргизүү вектору түзүлөт. Бул сигналдардын мааниси боюнча мурунку этапта үйрөтүлгөн НСВ топурактын нымдуулук классын моделдейт. Андан кийин шайкештик таблицасы анын салмак маанисин аныктайт, ал суу ташкынын жана сел коркунучун болжолдоонун кийинки этаптарында колдонулат.

Селдин максималдуу жана орточо суткалык чыгымдарын болжолдоо

Селдин максималдуу жана орточо суткалык чыгымдарын болжолдоо үчүн эки катмарлуу персептрондун базасында НСРдин нейросет тармагы түзүлгөн. Нейрон тармагынын архитектурасын тандоо киргизүү жана чыгаруу сигналдарынын жыйындысы менен аныкталат. Суунун чыгымдарын кыска мөөнөттүү болжолдоодо суу ташкынын формалдаштыруучу көптөгөн мүнөздөмөлөрдүн ичинен эң маанилүүлөрү тандалды:

- 1.Дарыядагы суунун чыгымы (орточо күндүк жана максималдуу);
- 2.Абанын температуrasesы (орточо күндүк жана максималдуу);
- 3.Жаан-чачындын суткалык көлөмү;
- 4.Топурактын нымдуулук классы.

Ар бир позиция боюнча болжолдуу маалыматтардан 6 күн мурун архивдик маалыматтар топтому колдонулат. Мындан тышкары, абанын максималдуу жана орточо суткалык температуrasesы жана жаан-чачындын күтүлүүчү көлөмү боюнча суткалык божомол (ММКнын байкоосунун маалыматтары боюнча) жана топурактын нымдуулук классынын божомолу (НСВ моделделген) колдонулат. Ошентип, НСРдин киргизүү сигналдарынын түзүлүшү:

- Суу ташкынын максималдуу чыгымдарынын тарыхы (6 сигнал);
- Суу ташкынынын орточо күндүк чыгымдарынын тарыхы (6 сигнал);
- Абанын максималдуу температуrasesынын тарыхы жана божомолу (7 сигнал);
- Абанын орточо суткалык температуrasesынын тарыхы жана божомолу (7 сигнал);
- Күнүмдүк жаан-чачындын тарыхы жана божомолу (7 сигнал);
- Топурактын нымдуулук классынын божомолу (1 сигнал).

БАРДЫГЫ 34 киргизүү сигналдары.

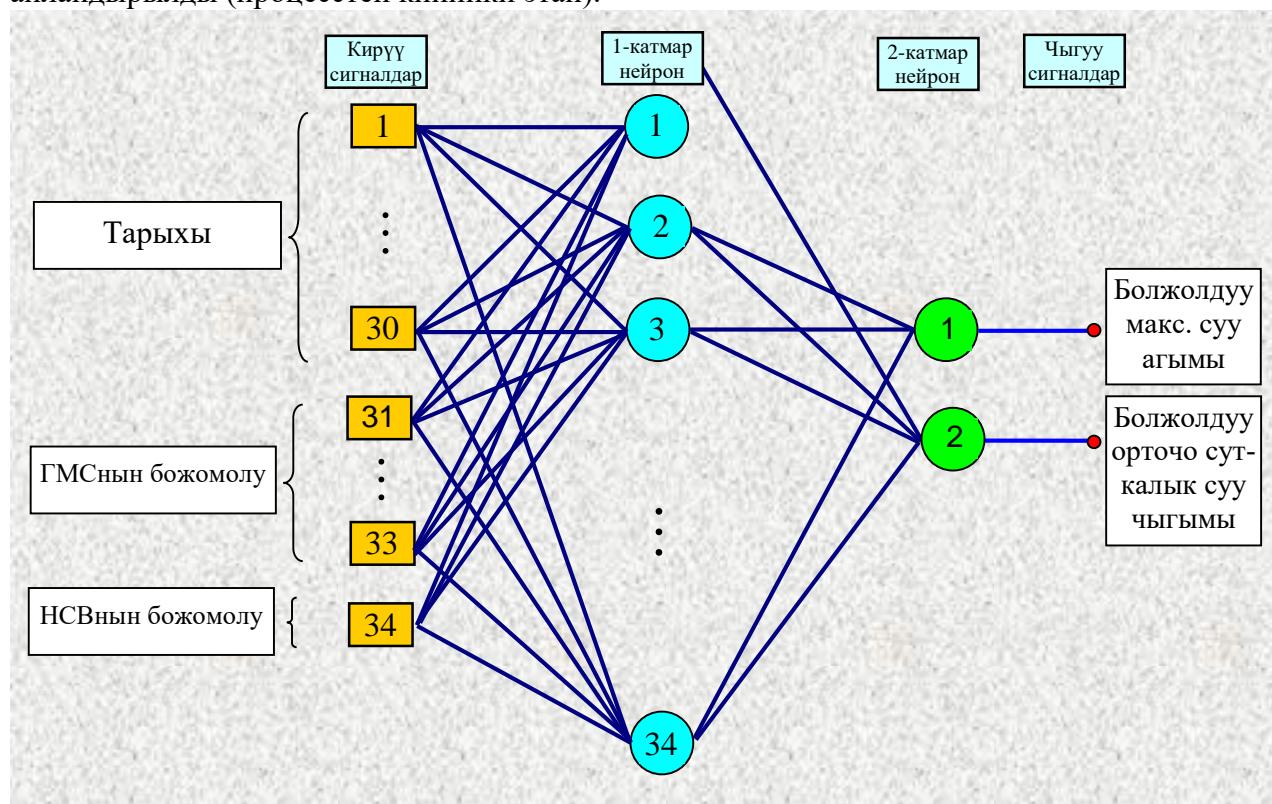
НСРдин чыгуу сигналдарынын структурасы:

- Максималдуу агымдын болжолдонгон мааниси;
- Орточо күндүк чыгымдын болжолдонгон мааниси.

БАРДЫГЫ болуп 2 сигнал чыгаруу.

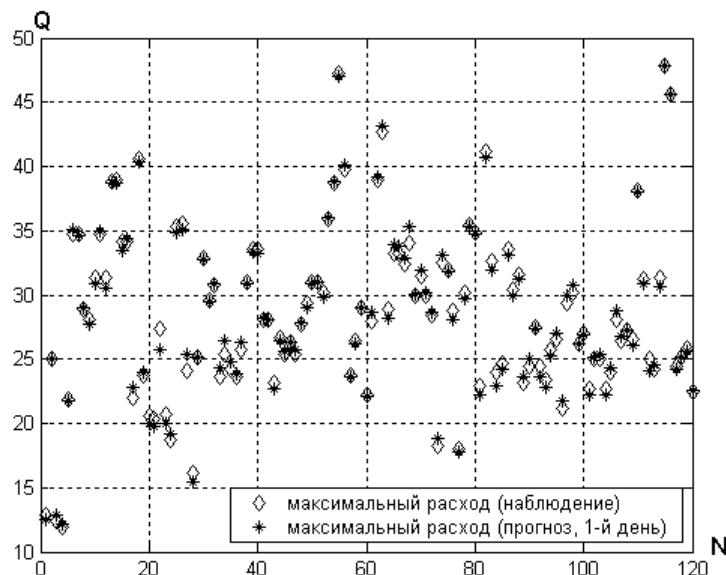
Жогоруда баяндалгандарга негизденүү менен метеорологиялык жана гидрологиялык маалыматтардын негизинде катастрофалык суу ташкындарын кыска мөөнөттүү божомолдоонун алгоритми бир сутканын ичинде иш-аракеттердин төмөнкүдөй ырааттуулугун жүзөгө ашыруудан турат:

1. Суу ташкынын аныктоочу мүнөздөмөлөрдүн подсистемасын аныктоо. Анын негизинде НСР киргизүү жана чыгаруу сигналдар түзүмүн аныктоо.
2. НСРдин түрүн, архитектурасын жана алгоритмдерин тандоо: эки катмарлуу персептрон; биринчи (жашыруун) катмар – ВК активдештириүү функциясы бар 34 нейрон; экинчи катмар – ЛОС активдештириүү функциясы бар 2 нейрон; масштабдан кийин киргизүү жана чыгаруу сигналдарынын өзгөрүү диапазону (0; 1). НСРдин нейросет архитектурасы сүрөттө келтирилген. 1.
3. Табигый байкоо маалыматтарынын негизинде виртуалдык окутуу топтомун түзүү (масштабдуу киргизүү жана максаттуу функциялардын мааниси).
4. НСРДИН баштапкы параметрлерин аныктоо.
5. ССР окутуу. Баштапкы окутуу минималдуу дисперсияга ээ болгон кадимки ызы-чуу менен 120 сценарийдин окутуу топтомунда жүргүзүлдү. Андан кийин НСР боюнча кошумча окутуу жүргүзүлдү. Ар бир жолу ызы-чуунун дисперсиясын көбөйтүп, 10 сценарий боюнча 120 цикл жүргүзүлдү.
6. 120 сценариiden турган контролдук топтомдо окутуулган НСРди тестиirlөө. Нейрон тармагынын чыгышы масштабдуу мультиликаторго көбөйтүү жолу менен туура форматка айландырылды (процесстен кийинки этап).

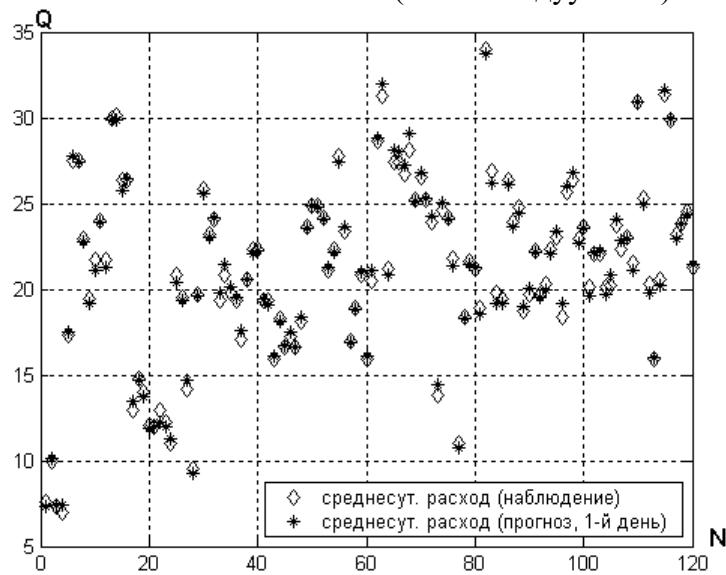


Сүрөт 1. Максималдуу болжолдоо үчүн НСР нейросет архитектурасы жана суу ташкыны өтүп жатканда дарыянын жээктөрөндөгө суунун ортоочо суткалык чыгымы.

Болжолдуу маанилердин жана максималдуу жана ортоочо суткалык чыгымдардын натурагалык байкоолорунун натыйжалары график түрүндө келтирилген (сүрөт. 2, 3).



Сүрөт 2. Максат сигналдары жана НСР чыгаруу сигналдары (максималдуу агым).



Сүрөт 3. Максат сигналдары жана НСР чыгаруу сигналдары (орточо суткалык чыгым).

Бул графиктерде N -сценарийдин номери, Q -суунун чыгымы (m^3/c). Графиктер Ала-Арча бассейниндеги суу ташкыны мезгилиндеги суунун максималдуу жана орточо суткалык чыгымдарын болжолдоонун алгылыктуу тактыгын көрсөтөт. 120 сценарий боюнча орточо квадраттык ката, Эмактын максималдуу чыгымдары үчүн $\sigma_{max}=0.0509$, орточо суткалык чыгымдар үчүн- $\sigma_{cp}=0.0180$.

Окутулган нейросет тармагынын жардамы менен, мурдагы байкоо маалыматтарын ыраттуу жылдырып жана гидрометеорология кызматынын божомолун жана Q_{max} жана Q_{avg} модельдөн маанилерин колдонуу менен, N суткага чейинки убакыт аралыгында чыгымдардын болжолун алууга болот .

Селдин оттүү ыктымалдуулугун болжолдоо

Бул этап сел/сел коркунучун болжолдоодо акыркы этап болуп саналат. Анын максаты-нейросет технологияларын жана гидрометеорология кызматынын байкоо жана болжолдоо маалыматтарын колдонуп, бороон-чапкындын генезисинин селдин кетүү ыктымалдыгын кыска мөөнөттүү болжолдоо.

Жогоруда селдин пайда болушунун үч зарыл шарты келтирилген:

1. Борпон блоктук материалдардын (*MPM*) жетиштүү массалары;
2. Бул массаларды жууп, жылдырууга жетиштүү суу;

3. Тоо боорлорунун тик болушу жетиштүү.

Аны окутуу жана моделдөө үчүн нейрон тармагынын киргизүү векторлорун түзүүдө ушул факторлорду эске алууну карап көрөлү.

1. Селдин пайда болуу шарттарын гидрометеорологиялык болжолдоого гана негизделген жана геологиялык-кыртыштык шарттарды сан жагынан баалоо аракеттерин камтыбайт, ансыз селдин пайда болушунун ар кандай божомолу бир тараптуу жана Ошондуктан жетиштүү так эмес. [8] каралып жаткан региондун тоо боорлорундагы борпоң блоктук материалдын массасын эске алуу менен селге кооптуу мезгилди болжолдуу болжолдоо ыкмалары сунушталды. Автор бош блоктук материалдын топтолушунун баллдык индекстерин берген атайын таблицаларды сунуш кылат (тоо тектерин талкалоо продуктуларынын өтө чоң топтолушу үчүн +2ден баштап, алардын анча – мынча топтолушу үчүн-2ге чейин). Ушундай эле стол топурактын нымдалышын баалоо үчүн аларга сунушталат. Бирок, бул индекстер эсептөө бисмиллах жазуучу тарабынан киргизилген эмес жана селе коркунучу гана кыйыр көрсөткүчтөрү болуп саналат. Ал сунуш кылган ыкма үч факторду гана эске алат (жаан-чачын, топурактын алдын-ала нымдалышы жана борпоң материалдын топтолушу). Мындей аракеттер селди гидрометеорологиялык көрсөткүчтер боюнча гана болжолдоо ыкмаларына салыштырмалуу алдыга кадам болуп саналса да, бул ыкма селге коркунуч туудурган мезгилди баалоонун болжолдуу, болжолдуу ыкмасы катары гана каралышы мүмкүн.

Сел коркунучун болжолдоонун мурунку этаптарын өнүктүрүүдө [9], бул иште киргизүү векторлорунда тиешелүү сигналдарды түзүү жолу менен борпоң блоктук материалдардын массасын эсепке алуу жүргүзүлдү. Айыл-кыштактарга кооптуу аймактарда MPM так эсепке алуу жүргүзүлбөгөндүктөн жана кырдаалды байкоо жана контролдоо кызматтарын өнүктүрүүнү талап кылгандыктан, бул параметрдин маанисин (0, 1) диапазондо баалайбыз. Топурактын нымдуулук классынын аныктамасы менен окшоштук боюнча биз MPM классынын түшүнүгүн киргизебиз. Ар бир класска нөлдөн бирге чейинки салмак маанисин дал көлтирибиз. Сел коркунучу бар аймакта сел коркунучу бар участоктор жайгашкан деп коелу. $MPMi$ маанилерин трекке, требе $i=1,N$ Требага ылайык класстар боюнча бөлүштүрөбүз таблица 2.

Таблица 2.- MPM класстарынын салмактык мааниси.

Класстын №	1	2	3	4	5
Салмак мааниси	0 – 0.2	0.2 – 0.4	0.4 – 0.6	0.6 – 0.8	0.8 – 1.0

MPM нын интервалдагы мааниси (0.8 – 1) мурда сел көрүнүштөрү болгон алардын критикалык массаларына туура келет. Изилденүүчү дарыянын күймалары болгон учурда алардын селге кооптуу участоктору да бааланат. Селдин жоголуу ыктымалдыгын болжолдогон НС нейросетин окутуу жана моделдөө үчүн $MPM=\max MPM_i, i=1,N$ MPM критикалык чоңдугу жок болгон учурда айыл жөнүндө эмес, ири суу ташкыны же ылай агымы жөнүндө айтууга болот.

Виртуалдык окутуу массивинде, божомолдорго чейинки мезгилдин ичинде селдин жок болуп кетүү фактысы болгондо, $MPM = 1$ деп эсептейбиз. Сел кеткендөн кийин $MPM = 0$ дайындайбыз. Арасынан убакыт аралыгында биз $MPM = 0,5$ деп эсептейбиз. MPM аныктоо үчүн реалдуу шарттарда селдин жоголуу ыктымалдуулугун моделдөө байкоо кызматтарынын экспертицик баалоолорун же алардын эсептик маанилерин колдонуу болжолдонот.

Бул ишти аткарууда Ала-Арча дарыясынын бассейндеринде селдин жана анын эки қүймасынын: Аксай менен Адыгендин түзүлүшүнүн шарттары каралды. Изилденүүчү дарыялардын ар бири MPM түзүүнүн ар кандай потенциалына ээ. Мисалы, Аксай дарыясынын жогору жагында Голубина мөңгүсү жайгашкан, анын морен көлдөрү дайыма толуп турат жана мөңгү чөкмөлөрүн ылдый түшүрөт. Ошондуктан, бул дарыянын бассейнинде отуруу дээрлик жыл сайын, кээде бир нече жолу болот. Бул дарыянын бассейнинде бош блоктук материалдарды сактоого байкоо жүргүзүү өзгөчө актуалдуу.

Р. Адыгене бассейнине борпоң блок материалы негизинен мореникалык тез-Тер көлүн камсыз кылат, анын толуп кетиши жана мөңгү кендерин төгүү сейрек кездешет, бирок кээде каргашалуу кесептөрдө алып келет.

Морен көлдөрүнүн бузулушунан келип чыккан селдин божомолу башкача маалыматты талап кылат жана бул учурда нейрон тармагынын технологиясын колдонуу мүмкүнчүлүгү көбүрөөк изилдөө жүргүзүүнү талап кылат. Ушуга байланыштуу, үзгүлтүккө учурган типтеги селдин даталарына туура келген сценарийлер, карама-каршылыктуу маалыматтын нейрон тармагы тарабынан бурмаланган чечмеленишине жол бербөө үчүн окуу массивине киргизилген эмес. Алсақ, мисалы, "тыныгүү" тибиндеги селге туура келген гидротерминалык маалыматтар (Тез-Тер көлү, үзүлүү 22.06.1953) сел коркунучун билдирибegen орточо маалыматтардан айырмаланбайт. Аларга ылайыктуу сценарийлер окуу массивинен алынып салынат.

2. Суунун көлөмү, адатта, бороон генезисинин селдин пайда болушунун баштапкы учурун аныктоочу негизги фактор болуп саналат. Эки суу факторунун дал келиши: дарыядагы суунун көп чыгымдалышы жана борпон блоктук материалдын критикалык массасы болгондо топурактын батпай калышы сел коркунучуна алып келет.

3. Тоолордун тик турушу туруктуу чондук жана нейрон тармагынын чыгуучу сигналдарынын натыйжасына таасир этпейт.

Ошентип, сел коркунучун болжолдоодо окутуу топтомунун кириш векторлору биринчи эки позиция боюнча маалыматты камтышы керек. Карапан мезгилде суу ташкыны жогору болгон 30 кырдаал катталган, бирок алардын бардыгында сел көрүнүштөрү болгон эмес. Мунун эң мүнөздүү себептери-жердин жетишсиз нымдалышы жана борпон блоктук материалдардын критикалык массасынын жоктугу.

Жогоруда айтылгандардан баштап, окуу топтомунун киргизүү векторлорунун структурасы:

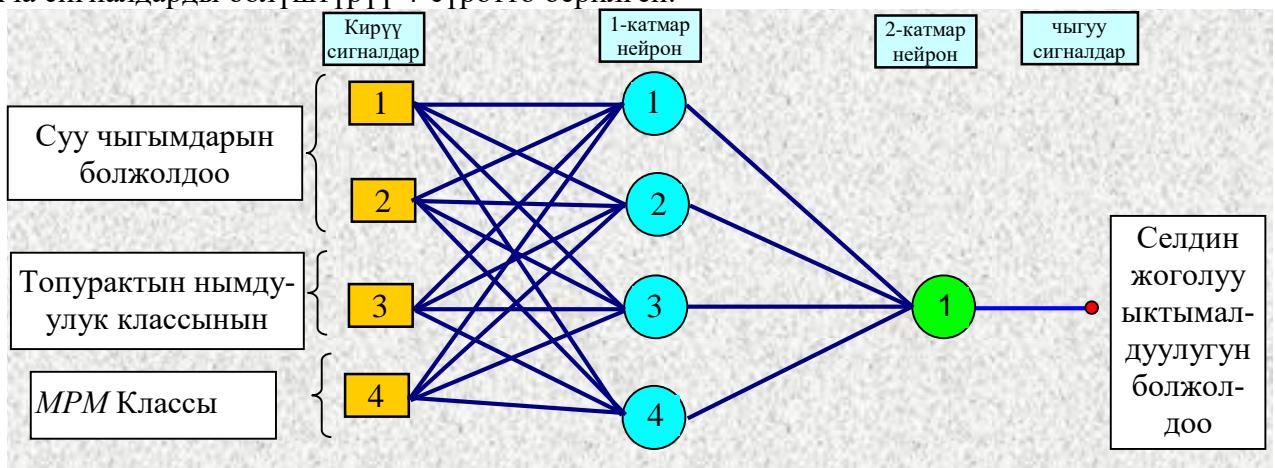
- Максималдуу жана орточо суткалых чыгымдарды болжолдоо (2 сигнал, *HCP*);
- Топурактын нымдуулук классынын божомолу (1 сигнал, *HCB*);
- *MPM* классынын максималдуу мааниси (1 сигнал, визуалдык байкоо).

Бардыгы, 4 киргизүү сигналдары.

Кириш сигналдарынын аз саны бардык маалыматтык маанилүү гидрометеорологиялык факторлор мурунку этаптарда эске алынгандыгына байланыштуу. Киргизүү векторлорунун жөнөкөй түзүлүшү селдин коркунучун болжолдоо үчүн иштелип чыккан жөнөкөйлөтүлгөн НСС нейрон тармагынын архитектурасын колдонууга мүмкүндүк берет.

НССтин максаты селдин жоголуу ыктымалдыгын моделдөө болгондуктан, чыгуучу вектор бир сигналдан турат. Селдин өтүү фактысы болгон учурда же кандайдыр бир сценарийде, бул сигналдын мааниси (p ыктымалдуулугу) 1ге барабар, антпесе нект $p = 0$.

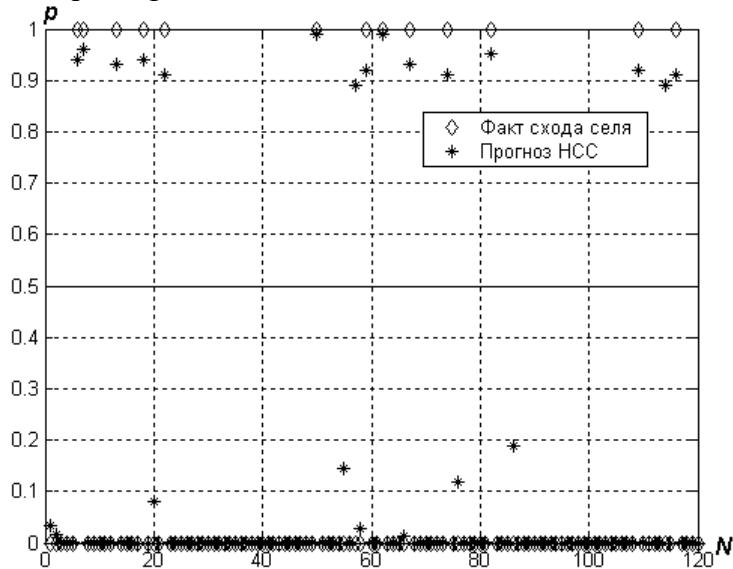
Сел коркунучун кыска мөөнөттүү болжолдоо үчүн кошумча параметрлерди эске алуу менен (топурактын нымдуулугу жана борпон блоктук материалдын массасы) эки катмарлуу персептрондун түзүлүшү кабыл алынган. НСС Архитектура жана киргизүү окутуу багыттар боюнча сигналдарды бөлүштүрүү 4-сүрөттө берилген.



Күрүч. 4. НСС нейрон тармагынын архитектурасы

Процесске чейинки этапта бардык киргизүү сигналдарынын мааниси диапазонго чейин кыскарат ($0, 1$). НСС тестиirlөө гидрометеорология кызматынын байкоо маалыматтары боюнча жүргүзүлдү. Моделделген маанилердин натыйжалары сүрөттө келтирилген. 5. Бул жерде p – селден өтүү ыктымалдыгы, N -сценарийлердин саны. $p < 0.5$ ыктымалдуулук маанилери менен болгон окуялар күмөн деп эсептелет.

Графиктен көрүнүп турганда (сүрөт. 5) селдин жоголуу фактысы болгон учурда селдин жоголуу ыктымалдыгынын болжолдуу мааниси $p > 0.5$, б.а. моделделген мааниси селдин мүмкүнчүлүгүн туура болжолдогон. Бирок, ишке аштай калган айылда бирдикке жакын p мааниси бар. Гидрометеорологиялык факторлорду талдоо бул сценарийлер Селтик кырдаалдарына жакын экендигин көрсөттү.



Сүрөт 5. Селдин кетүү ыктымалдыгынын болжолдуу мааниси, моделдеген НСС.

Ошентип, метеорологиялык жана гидрологиялык маалыматтардын, ошондой эле геологиялык-кыртыштык шарттардын негизинде сел коркунучун кыска мөөнөттүү божомолдоонун алгоритми бир сутка мурда төмөнкү иш-аракеттерди аткаруудан турат:

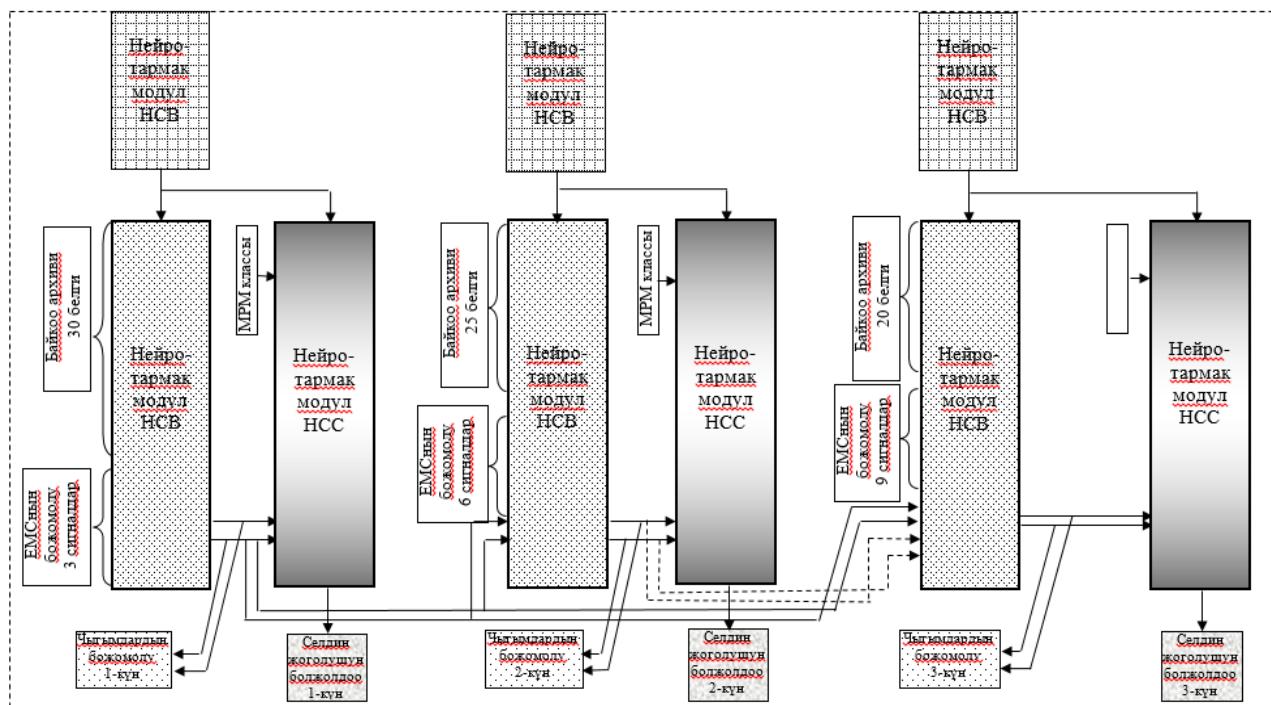
1. Маалыматтык селеформациялык мунөздөмөлөрдүн подсистемасын аныктоо. Анын негизинде НСС киргизүү жана чыгаруу сигналдар түзүмүн аныктоо.
2. Сел параметрлеринин моделделген болжолдуу маанилеринин жана ар кандай дисперсиялардын ызы-чуусу менен табигый байкоо маалыматтарынын негизинде виртуалдык окутуу топтомун (окутуу векторлорун) түзүү (киргизүү сигналдары жана максаттуу функциялардын мааниси).
3. Окуу векторлорун өзгөртүү (процессорго чейинки этап).
4. Түрү, архитектура жана НСС алгоритмдердин тандоо.
5. НСС баштапкы параметрлерин аныктоо.
6. НСС окутуу.
7. НСС тиин чыгуу сигналдарын баштапкы форматка айландыруу (пост-процессордук этап).
8. Контролдук жана тесттик топтомдордо окутулган НСС тестиirlөө.

Үйрөтүлгөн нейросетканын жардамы менен сел коркунучунун божомолун n сутканын чейинки убакыт аралыгында байкоо жүргүзүүнүн эң алгачкы маалыматтарын ырааттуу алмаштыруу жана ГМС нын божомолун, топурактын нымдуулук классстарынын моделделген маанилерин, Q_{max} жана Q_{cp} дин суу чыгымдарынын болжолдуу маанилерин колдонуу менен алууга болот.

Сел коркунучун болжолдоодо НСВ, НСР жана НСС нейросет модулдарын биректирүү схемасы 1-3 сутка алдын ала сүрөттө келтирилген. 6.

НСРдин нейросет модулдарынын киргизүү сигналдарынын түзүмүн салыштырууда б-сүрөттө болжолдоонун алдын ала көбөйтүлүшүнө жараша байкоолордун маалыматтары болжолдуу маалыматтар менен жарым-жартылай алмаштырылганы көрүнүп турат. Албетте, мында ГМСны болжолдоодогу каталардан, ошондой эле дарыядагы сууну сарптоону НСР моделдөөнүн натыйжаларынан келип чыккан каталардын топтолушу байкалат. Ушуга байланыштуу, уч сааттык божомолду болжолдуу баалоо үчүн гана колдонсо болот, аны жаңы маалыматтар алынган сайын тууралоо керек: болжолдуу, моделделген жана табигый байкоолор.

Биз иштеп чыккан Алгоритмдин анализинен нейросет технологияларын колдонуу менин суу ташкынын жана сел коркунучун болжолдоо ыкмасы универсалдуулуктун жана регионалдуулуктун касиеттерин айкалыштырат. Методдун универсалдуулугу аны ар кандай тоодарыяларынын бассейндерин үчүн колдонууда нейросет тармактарынын түрү, архитектурасы, параметрлери жана алгоритмдери сакталат, ал эми регионалдуулук – конкреттүү региондордун архивдик жана болжолдуу маалыматтары боюнча аларды кайра окутуу зарыл болгондо сакталат.



Сүрөт 6. Селеванын божомолунда нейросет түйүндөрүнүн кошулушунун ырааттуулугу алдын ала коркунуч 1-3 күн

Жыйынтыктоо. Топурактын нымдуулугу жана борпоң блоктук материалдардын масасы сыйктуу маалыматтык маанилүү параметрлерди эсепке алуу сел коркунучун болжолдоонун тактыгын олуттуу жогорулаттууга мүмкүндүк берет. Бирок, биз сунуш кылган ыкмаларды так божомолго жакындоо деп гана эсептесек болот. Так прогнозго тоскоол болгон негизги себептер:

1. Нейрон тармактары окуу маалыматтарынын топтомунан селге жакын жайгашкан селдерди гана тааный алышат. Ушуга байланыштуу, ар бир жаңы селден өткөндөн кийин нейрон тармактарын кошумча окутуу максатка ылайыктуу.

2. Морен көлдөрүнүн бузулушунан келип чыккан селдер өтө сейрек кездешет жана ошого жараша нейрон тармактарын окутуу үчүн жетиштүү маалымат жок. Морен көлүнүн ачылышын болжолдоо үчүн суунун денгээлинин өзгөрүшүнө мониторинг жүргүзүүнү уюштуруу жана морен дамбаларынын абалын көрүү зарыл.

Селдин пайда болуу процессине таасир этүүчүү башка, изилденбеген факторлор дагы бар. Селге катышкан факторлордун олуттуу саны жана кубулуштарды изилдөөнүн ушул этабында алардын өзара аракеттенүүсүнүн татаал мүнөзү сел коркунучун так болжолдоо мүмкүнчүлүгүн жокко чыгарат. Бирок, көптөгөн жаңы катастрофалык суу ташкындарынын

сценарийлерин жана селдерди мониторинг процессинде алган сайын киргизүү жана кошумча мисалдар аркылуу нейрон тармактарын кошумча окутуу божомолдун тактыгын кыйла жого-рулатат.