

## **НЕЙРОСЕТЕВЫЕ МЕТОДЫ ОБРАБОТКИ ИНФОРМАЦИИ В ЗАДАЧАХ ПРОГНОЗА КЛИМАТИЧЕСКИХ ХАРАКТЕРИСТИК И ЛЕСОРАСТИТЕЛЬНЫХ СВОЙСТВ ЛАНДШАФТНЫХ ЗОН**

*В.Г. Царегородцев, Н.А. Погребная*

*Институт вычислительного моделирования СО РАН,  
Институт леса СО РАН  
660036, Красноярск-36, ИВМ СО РАН,  
E-mail: tsar@cc.krascience.rssi.ru*

В настоящей работе рассматриваются проблемы, возникающие при обработке таблиц экспериментальных данных. Описываются нейросетевые методы обработки информации для задач классификации и построения регрессионных зависимостей. Работа может служить первым введением в нейроинформатику для специалистов-прикладников. Подробно описан опыт применения нейросетевых технологий для решения задач прогноза, классификации и глобального моделирования изменений климата. С помощью нейросетевой транспонированной линейной регрессии, нейросетевой нелинейной регрессии и нейросетевых классификаторов решены задачи прогнозирования неизвестных значений климатических параметров, классификации ландшафтных зон и глобального моделирования последствий изменения климата на основе таблицы данных, собранных с метеостанций Сибири и Дальнего Востока.

### **Введение**

В настоящее время в связи с широким распространением вычислительной техники и повышением ее мощности актуальным становится вопрос эффективного ее применения для решения различных задач моделирования, прогнозирования, классификации и идентификации в экологии, климатологии и метеорологии. Особенность данных проблемных областей заключается в малом числе теоретически обоснованных и хорошо согласующихся с реальными данными вычислительных моделей. Поэтому прикладные задачи часто решаются на основе моделей, построенных по таблицам экспериментальных данных. При этом проблему представляет как сложность учета всех факторов, влияющих на ситуацию в конкретных территориях, так и сложность сбора территориально распределенной информации. В связи с этим часто приходится обрабатывать неполную информацию при наличии дублирующих друг друга либо малоинформативных признаков. В настоящей работе рассматриваются проблемы, возникающие при обработке таблиц экспериментальных данных. Описываются нейросетевые методы обработки информации для задач классификации и построения регрессионных зависимостей. Работа может служить первым введением в нейроинформатику для специалистов-прикладников. Подробно описан опыт применения нейросетевых технологий для решения задач прогноза, классификации и глобального моделирования изменений климата. С помощью нейросетевой транспонированной линейной регрессии, нейросетевой нелинейной регрессии и нейросетевых классификаторов решены задачи прогнозирования неизвестных значений климатических параметров, классификации ландшафтных зон и глобального моделирования последствий изменения климата на основе таблицы данных, собранных с метеостанций Сибири и Дальнего Востока.

### **1. Проблемы обработки таблиц экспериментальных данных**

Имеется таблица экспериментальных данных, где каждому объекту (строке таблицы) соответствует набор значений (столбцов) его независимых и зависимых признаков. Под независимыми (базовыми) признаками понимаются те признаки, на основе которых необходимо предсказать значения зависимых – искомым или целевых признаков, которые могут быть не известны. Все задачи классификации и прогнозирования для такой таблицы можно свести к четырем классическим постановкам [14]:

- 1) Распознавание образов (предсказание для объекта значения некоторого его целевого признака, выраженного в шкале наименований).
- 2) Предсказание значения числового (порядкового или количественного) признака для объекта.
- 3) Динамическое прогнозирование значения числового признака объекта, использующее временные измерения значений этого же признака (анализ временных рядов).
- 4) Автоматическая группировка объектов.

Каждая из перечисленных постановок сводится к единой задаче заполнения пропусков в таблице данных. При автоматической группировке объектов в таблицу добавляется новый столбец, содержащий информацию о разбиении всего множества объектов на группы похожих. Для иных постановок прогнозируются неизвестные значения признаков у тех объектов, где имеется пропущенная информация. Для этого требуется нахождение зависимостей в таблице экспериментальных данных [2,3,10,14]. При этом появляются следующие специфические особенности:

Таблица данных априорно является неполной, поскольку невозможно в общем случае описать все независимые и зависимые признаки, существенные для моделирования объекта или процесса. Это связано и с нашим ограниченным представлением о моделируемом объекте, и с ограничениями на возможность проведения тех или иных измерений.

Задачи приходится решать при высокой априорной неопределенности, когда практически ничего неизвестно о виде функций распределения вероятностей в пространстве признаков. Всякое “сильное” предположение (о нормальности или унимодальности распределения, некоррелированности признаков и т.д.) ставит вопрос об адекватности предлагаемого вида действительному.

При изучении сложных объектов возникают большие трудности при задании исходной системы признаков для их описания. Поэтому в признаковом пространстве может быть много “дублирующих” и “шумящих” признаков. В результате проблема выбора наиболее информативной подсистемы признаков приобретает важное значение, поскольку уменьшение числа признаков часто улучшает качество решения (и сокращает экономические и временные затраты на измерения или сбор информации). Желательно иметь возможность определения значимости каждого признака для принятия решения и выделения минимально необходимого набора базовых признаков для прогнозирования целевого признака с заданной точностью.

Для описания объектов используются признаки, измеренные в разных шкалах и, возможно, разнотипные – количественные (выраженные в шкалах интервалов, отношений и абсолютных значений), порядковые (шкалы порядка, частичного порядка, рангов, баллов) или номинальные (шкалы наименований).

В связи со сложностью проведения измерений, отказом датчиков, историческими причинами в таблице могут отсутствовать некоторые значения исходных и целевых признаков у отдельных объектов. В данных всегда присутствуют ошибки разной природы, шум, а также имеются противоречия отдельных измерений друг другу. За исключением простых случаев, искажения в данных не могут быть устранены полностью. Классификация объектов проблемной области, вводимая человеком, может не совсем точно отражать существующую в проблемной области естественную кластерную структуру объектов, что создает дополнительные трудности.

Эти особенности не связаны только с перечисленными выше проблемными областями, но могут встретиться везде, где используется построение зависимостей по таблице экспериментальных данных. Также не зависит от проблемной области возможность сведения любой задачи прогнозирования и классификации к задаче "правдоподобного" заполнения пропусков в таблице.

Для обработки эмпирических данных традиционно используются классические методы математической статистики [11,12,17]. Можно получить для отсутствующих значений их условные математические ожидания (условия – значения других величин, описывающих конкретную ситуацию) и характеристики разброса – доверительные интервалы. Для решения задачи классификации методы математической статистики строят разделяющие поверхности между классами в признаковом пространстве. Однако достоверное статистическое оценивание требует либо очень большого объема известных данных, либо очень сильных предположений о виде функций распределения, и работает обычно только при нормальных или близких к нормальным функциях распределения. Поэтому при вычислении условного математического ожидания требуется проверять гипотезу о распределении эмпирических данных по нормальному закону или использовать аппарат непараметрической статистики, восстанавливающей оценки плотностей распределения вероятностей.

Поэтому часто для решения задач классификации и прогнозирования используются различные эмпирические (статистически не достоверные) методы обработки информации. Естественным требованием является желание иметь единую парадигму построения различных эмпирических моделей, решающих задачу предсказания и классификации, не привязанную к конкретной проблемной области и предлагающую процедуры решения типовых проблем, встающих при обработке таблиц экспериментальных данных. В связи с этим можно сформировать список требований, которым должен удовлетворять эмпирический метод обработки информации:

1. Работа при наличии пропусков в таблице.
2. Работа в случае, если число измеренных признаков превышает число объектов, и число объектов достаточно мало.
3. Наложение достаточно слабых ограничений на вид распределений.
4. Обеспечение возможности обработки разнотипных экспериментальных данных (без сведения всех признаков к одной шкале) и инвариантность к допустимым преобразованиям шкал признаков.
5. Достаточно высокая вычислительная эффективность.
6. Простота получения результата и отсутствие привязки к конкретной проблемной области.

Эти требования являются очень важными. Обычно при использовании эмпирических методов предполагается, что пользователя удовлетворит просто получение прогноза. Далее на основе своих профессиональных знаний он сделает вывод о применимости полученного результата, сопоставив машинный прогноз со своими экспертными оценками. Пользователь может протестировать на имеющихся у него данных несколько эмпирических методов, выбрать наилучший метод по точности достигаемого прогноза и в дальнейшем использовать именно его. При этом, поскольку пользователь обычно смутно представляет, как следует задавать параметры метода для достижения наилучшей точности прогноза, и обычно не может заложить в метод сформировавшуюся у него эмпирическую модель проблемной области, то возникают проблемы недостаточной эффективности использования методов и неадекватности построенных моделей имеющимся экспертным соображениям.

Можно ввести еще одно требование, основанное на желании применить разработанный метод прогноза или классификации либо построенную эмпирическую модель для решения этих же задач, например, в другом регионе либо по истечению некоторого времени без необходимости их коррекции. Хотя это всегда практически недостижимо, требуется хотя

бы обеспечить возможность адаптации модели к новому региону путем простого переобучения на новых данных.

## **2. Искусственные нейронные сети**

Для решения задач классификации и прогноза используются различные математические методы: математической статистики, кластерного, регрессионного, факторного анализа и т.д. По сравнению с этими методами подход, основанный на применении искусственных нейронных сетей, обладает рядом преимуществ и удовлетворяет введенным ранее требованиям. Во-первых, создается единая для всех задач вычислительная парадигма. Используя нейронные сети со сравнительно небольшим числом нейронов, можно решать достаточно сложные задачи классификации и прогноза. Нейронные сети представляют собой обучающиеся модели, что позволяет просто "доучивать" их при поступлении новых данных либо "переучивать" для обработки данных из другого региона. Возможно использование малых обучающих выборок, не обеспечивающих получение статистически достоверных результатов классическими методами. В нейронных сетях можно использовать любое количество независимых и зависимых признаков, число примеров для разных классов (при решении задачи классификации) может быть различным. Также возможно решение одной сетью одновременно нескольких задач классификации или прогноза. В нейронной сети есть процедура подсчета значимости независимых признаков и возможность минимизации их числа.

После такого многообещающего анонса перейдем непосредственно к описанию того, что такое искусственные нейронные сети и как они решают задачи.

Искусственные нейронные сети, а в более общем случае – и вся нейроинформатика, появились при попытке моделирования мозга не на основе нейробиологических идей, а на основе кибернетических. Так, в основе всего нейросетевого подхода лежит идея построения вычислительного устройства из большого числа параллельно работающих простых процессирующих элементов – нейронов. Эти нейроны функционируют независимо друг от друга и связаны между собой однонаправленными каналами передачи информации – синапсами (как и при именовании нейрона, здесь взяты нейробиологические термин и абстракция). Получаемая при этом искусственная нейронная сеть обладает по аналогии с ее биологическими прототипами следующими преимуществами:

Высокоэффективная параллельно - последовательная обработка информации и, вообще, максимальный потенциальный параллелизм и наиболее эффективное использование любой параллельной вычислительной архитектуры по сравнению с другими вычислительными технологиями.

Высокая надежность и устойчивость к отказам отдельных элементов, составляющих нейронную сеть.

Место программирования занимает процесс обучения (или настройки) нейронной сети. Под обучением понимается процесс адаптации нейронной сети для достижения минимума некоторого оценивающего функционала – например, качества решения сетью поставленной задачи.

В нейронной сети выделена группа входов и группа выходов. По входным рецепторам нейронная сеть принимает информацию и затем, пропуская эту информацию через себя и преобразуя ее с помощью процессорных элементов, генерирует выходные сигналы.

### **2.1. Элементы нейронных сетей**

В нейроинформатике выработана специальная "схемотехника", в которой элементарные устройства – сумматоры, синапсы, нейроны и т.п. объединяются в сети, предназначенные для решения задач [6,9].

Самый заслуженный и, вероятно, наиболее важный элемент нейросистем – это *адаптивный сумматор*. Адаптивный сумматор вычисляет скалярное произведение вектора входного сигнала  $x$  на вектор параметров  $\alpha$ . На схемах будем обозначать его так, как показано на рис.1. Адаптивным называем его из-за наличия вектора настраиваемых параметров  $\alpha$ . Для многих задач полезно иметь линейную неоднородную функцию выходных сигналов. Ее вычисление также можно представить с помощью адаптивного сумматора, имеющего  $n+1$  вход и получающего на 0-й вход постоянный единичный сигнал (рис.2).




Рис. 1. Адаптивный сумматор




Рис. 2. Неоднородный сумматор

*Нелинейный преобразователь сигнала* изображен на рис.3. Он получает скалярный входной сигнал  $x$  и переводит его в  $\varphi(x)$ . *Точка ветвления* служит для рассылки одного сигнала по нескольким адресам (рис.4). Она получает скалярный входной сигнал  $x$  и передает его всем своим выходам. *Стандартный формальный нейрон* составлен из входного сумматора, нелинейного преобразователя и точки ветвления на выходе (рис.5). *Линейная связь - синапс* – отдельно от сумматоров не встречается, однако для некоторых рассуждений бывает удобно выделить этот элемент (рис.6). Он умножает входной сигнал  $x$  на "вес синапса"  $\alpha$ .




Рис.3. Нелинейный преобразователь сигнала




Рис.4. Точка ветвления

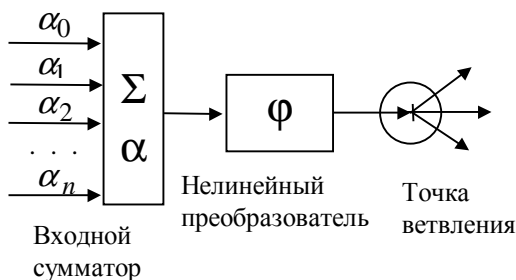


Рис. 5. Формальный нейрон




Рис. 6. Линейная связь (синапс)

## 2.2. Архитектуры нейронных сетей

В "зоопарке" искусственных нейронных сетей можно выделить две базовые архитектуры – *слоистые* и *полносвязные сети*.

*Слоистые сети*: нейроны расположены в несколько слоев (рис.7). Нейроны первого слоя получают входные сигналы, преобразуют их и через точки ветвления передают нейронам второго слоя. Далее срабатывает второй слой и т.д. до  $k$ -го слоя, который выдает выходные сигналы. Если не оговорено противное, то каждый выходной сигнал  $i$ -го слоя подается на вход всех нейронов  $i+1$ -го. Число нейронов в каждом слое может быть любым и никак заранее не связано с количеством нейронов в других слоях. Стандартный способ подачи входных сигналов: все нейроны первого слоя получают каждый входной сигнал.

**Полносвязные сети:** каждый нейрон передает свой выходной сигнал остальным нейронам, включая самого себя. Выходными сигналами сети могут быть все или некоторые выходные сигналы нейронов после нескольких тактов функционирования сети. Все входные сигналы подаются всем нейронам.

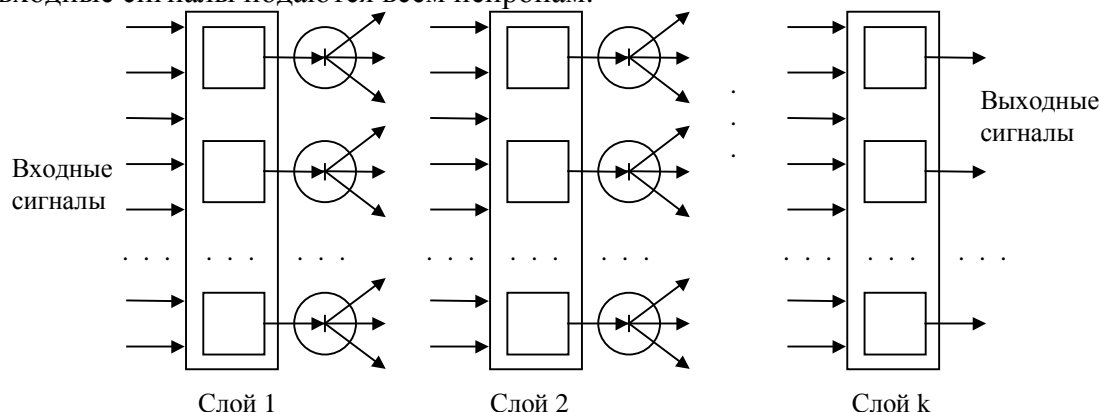


Рис. 7. Слоистая нейронная сеть

Элементы слоистых и полносвязных сетей могут выбираться по-разному. Существует, впрочем, стандартный выбор – нейрон с неоднородным адаптивным линейным сумматором на входе (рис.5).

### 2.3. Решение задач нейронными сетями

Можно выделить два класса задач, решаемых обучаемыми нейронными сетями. Это задачи предсказания и классификации.

Задачи предсказания или прогнозирования являются, по-существу, задачами построения регрессионной зависимости выходных данных от входных. Нейронные сети могут эффективно строить сильно нелинейные регрессионные зависимости. При решении задач классификации нейронная сеть строит разделяющую поверхность в признаковом пространстве, а решение о принадлежности ситуации тому или иному классу принимается самостоятельным, не зависящим от сети устройством – интерпретатором ответа сети [7,9]. Наиболее простой интерпретатор возникает в задаче бинарной классификации (классификации на два класса). В этом случае достаточно одного выходного сигнала сети, а интерпретатор относит, например, ситуацию к первому классу, если выходной сигнал меньше нуля, и ко второму, если он больше или равен нулю.

Классификация на несколько классов требует усложнения интерпретатора. Широко используется интерпретатор "победитель забирает все", где число выходных сигналов сети равно числу классов, а номер класса будет соответствовать номеру нейрона, выдавшего максимальный выходной сигнал.

Одна нейронная сеть может одновременно предсказывать несколько чисел, либо одновременно решать задачи и прогнозирования, и классификации.

### 2.4. Подача входных сигналов и снятие выходных сигналов сети

На веса синапсов сети обычно наложены требования принадлежности некоторому диапазону значений. Наиболее часто используемые нелинейные функции нейронов также обычно выдают значения из некоторого диапазона. Это приводит к тому, что обычно нельзя подавать сети входные сигналы в их истинном диапазоне величин и получать от сети выходные сигналы в требуемом диапазоне.

Поэтому перед подачей сети входных сигналов их необходимо нормировать, например, в диапазон значений  $[-1,1]$  или  $[0,1]$ , либо делать так, чтобы входные сигналы не слишком сильно выходили за пределы этих отрезков. Наиболее просто нормировку можно выполнить так. Каждая компонента входного вектора данных  $x_i$  заменяется величиной

$$x_i = \frac{x_i - (\max x_i + \min x_i) / 2}{(\max x_i - \min x_i) / 2},$$

где  $\max x_i$  и  $\min x_i$  – соответственно максимальное и минимальное значения для данной компоненты, вычисленные по всей обучающей выборке. По этой же формуле пересчитываются и компоненты векторов ответов.

Можно нормировать и по-другому, например, пересчитывать выборку так, чтобы разброс данным был единичным.

Здесь имеется одна сложность. Любое изменение обучающей выборки должно соответственно менять и правило нормирования данных. Поэтому поступают обычно так: в качестве  $\min$  и  $\max$ -величин берут данные из существующего на настоящий момент задачника и в дальнейшем нормировку не меняют, а если предполагается, что в дальнейшем поступят сильно отличающиеся данные, то  $\min$  и  $\max$ -величины задаются пользователем по его оценкам. Иными словами, эти величины должны вводиться в момент создания сети и в дальнейшем не зависеть от обучающей выборки.

Выходные сигналы сети должны нормироваться в диапазон истинных значений по обращенным формулам.

Для сетей-классификаторов нормировка выходных сигналов не нужна, поскольку пользователь получает не собственно выходные сигналы сети, а результат отнесения ситуации интерпретатором ответа к тому или иному классу. Здесь каждый выходной вектор задачника преобразуется так, чтобы правильно обрабатываться интерпретатором ответа. Например, при классификации на три класса и интерпретаторе "победитель забирает все" номер класса будет кодироваться вектором из трех чисел, где компонента вектора, соответствующая номеру класса, имеет значение 1, а остальные две – -1.

Другой проблемой является ситуация, когда в таблице данных имеются пробелы. Вместо таких отсутствующих компонент данных можно подавать нуль, можно исключать некомплектные вектора из обучающей выборки, можно перед обучением сети решать задачу заполнения пробелов в данных некоторыми правдоподобными значениями.

## 2.5. Обучение нейронных сетей

Обучение нейронной сети на некотором "задачнике" означает минимизацию функционала невязки между выходными сигналами сети и сигналами, которые требуется получить.

Минимизация функционала невязки (оценки в дальнейшем) производится путем такой подстройки обучаемых параметров  $a_i$  нейронов сети, чтобы сеть на некоторый входной вектор сигналов  $X$  выдавала ответ  $Y'$ , который был бы по возможности ближе к требуемому ответу  $Y$ . Иными словами, чтобы для задачника с числом примеров  $N$  (т.е. для  $N$  пар  $\{X_i, Y_i\}, i=1..N$ ) достигался минимум суммарной функции оценки:

$$H = \sum_{i=1}^N \|Y_i - Y'_i\| \longrightarrow \min$$

В качестве функции нормы выступает покомпонентная сумма квадратов элементов вектора  $Y - Y'$  (оценка МНК), либо более специализированная. Применение более специализированных оценок ускоряет процесс обучения сети. Так, можно использовать оценки, позволяющие задавать требования к точности решения задачи. Это позволяет прекращать процесс обучения, когда достигнута удовлетворяющая пользователя точность. Для решения задач классификации можно строить специализированные оценки, основанные на используемом при решении задачи интерпретаторе ответа. Подробно разнообразные интерпретаторы ответа и построенные по ним оценки описаны в [7,9]. Минимизация функции оценки выполняется с привлечением градиентных методов оптимизации. Преобразовав по некоторым правилам структуру сети, подавая на выход сети частные производные функции оценки по выходным сигналам и используя так называемое двойственное функционирование, мы можем получить для каждого подстроечного параметра сети и для каждого входного сигнала частные производные

функции оценки по значению этого параметра или сигнала. Для вектора параметров сети вектор соответствующих частных производных будет градиентом функции оценки, поэтому возможна градиентная оптимизация функции оценки, в ходе которой нейронная сеть "обучается" давать требуемые ответы на подаваемые ей входные сигналы. Сеть лучше обучать по суммарному градиенту (градиенту по всем примерам задачника), что ускоряет процесс обучения, и применять специализированные алгоритмы оптимизации, надстраиваемые над простейшим градиентным спуском. Для вычисления суммарного градиента необходимо просуммировать вектора градиентов, вычисляемые для каждого примера задачника (всего  $N$  векторов). Естественно, что нет необходимости одновременного хранения в памяти ЭВМ градиентов для всех примеров, процесс вычисления суммарного градиента реализуется как процесс последовательного накопления.

## 2.6. Вычисление градиента функции оценки по подстроечным параметрам сети

Теперь о том, как же собственно вычисляется градиент функции оценки по подстроечным параметрам сети. Вычисление градиента производится в ходе функционирования нейронной сети, двойственной к исходной. У сети двойственности сигналы передаются в обратном направлении – от выходов сети к ее входам, а элементы, из которых строится двойственная сеть, являются двойственными к исходным. Рассмотрим сначала некоторый достаточно абстрактный элемент сети. Ему передается  $n$  значений переменных  $x_i$ , на основе которых вычисляется значение функции  $f(x_1, \dots, x_n)$  и это значение рассылается по  $m$  выходным связям. В двойственной сети этот элемент получает на выходе набор из  $m$  двойственных сигналов  $\mu_i$ , вычисляет их сумму  $\mu$  и передает на каждый из  $n$  входов произведение  $\mu$  и частной производной функции  $f(x_1, \dots, x_n)$  по значению подаваемого на соответствующий вход сигнала. Этот процесс представлен на рис. 8. Здесь видно, что при построении двойственной сети все точки ветвления переходят в двойственные к ним элементы – простые сумматоры.

Теперь рассмотрим процесс построения нейрона, двойственного к формальному. Для этого представим формальный нейрон (рис. 5) более подробно (рис. 9), представив входной адаптивный сумматор нейрона в виде набора элементов, вычисляющих попарные произведения (веса синапса и приходящего на синапс сигнала), и простого сумматора. По описанному выше правилу построения двойственного элемента преобразуем все элементы, составляющие формальный нейрон. Нейрон, двойственный к формальному, и правила его функционирования показаны на рис. 10. Здесь видно, что при построении двойственной сети все простые сумматоры переходят в двойственные к ним элементы – точки ветвления. Для более понятной иллюстрации этого факта и было использовано представление адаптивного сумматора с помощью простого сумматора и набора синапсов на рис. 9. Из нейронов, двойственных к формальным, и строится двойственная сеть. Разумеется, двойственные сети могут быть построены и для сетей, состоящих из более сложных по конструкции нейронов.




Рис.8. Прямое и двойственное функционирование абстрактного элемента сети






Рис. 9. Функционирование формального нейрона

Итак, построена сеть, двойственная к исходной. Теперь определимся с двойственными




Рис. 10. Двойственное функционирование формального нейрона

переменными  $\mu$ , подаваемыми на выходы нейронов последнего слоя. Чтобы решить задачу вычисления с помощью двойственной сети градиента функции оценки по подстроечным параметрам исходной сети, в качестве двойственных переменных необходимо брать частные производные функции оценки  $H$  по выходным сигналам сети. Тогда для всех элементов и входных сигналов сети будут вычислены частные производные функции оценки по значениям этих параметров и сигналов.

Использование двойственной сети для вычисления градиента позволяет вычислять весь вектор градиента за время, всего в 2-3 раза большее, чем время вычисления выходных сигналов в ходе обычного функционирования исходной сети. Это происходит потому, что все действия организованы рационально, без дублирования вычислений, и градиент вычисляется в максимально параллельном режиме.

Единственным требованием, налагаемым на нейронные сети и функции оценки для того, чтобы можно было использовать двойственное функционирование для вычисления градиента, является существование непрерывных первых производных функций оценки и всех элементов сети по их входным сигналам.

Подробно принцип двойственности для обучения нейронных сетей рассмотрен в [6,9].

## **2.7. Факторы, влияющие на обучение нейронной сети**

Рассмотрим факторы, от которых зависит успешность обучения нейронной сети правильному решению задачи. В первую очередь, сеть должна быть достаточно гибкой, чтобы научиться правильно решать все примеры обучающей выборки. Поэтому в нейронной сети должно быть достаточное количество нейронов и связей.

На основании обучающей выборки достаточно сложно определить, сколько слоев и нейронов сети необходимо. Поэтому поступают обычно так. Обучают сеть со структурой, предлагаемой программой-нейроимитатором по умолчанию, а в дальнейшем, если сеть не может обучиться, пробуют обучить сеть большего размера. На практике при решении разнообразных задач практически не встречается ситуации, когда требуется нейросеть с более чем сотней нейронов – обычно хватает нескольких десятков нейронов и даже меньшего числа.

Однако даже увеличение размера нейронной сети не поможет, если обучающая выборка противоречива. Иными словами, в обучающей выборке присутствуют задачи с одинаковыми условиями, но разными ответами (одинаковыми входными векторами данных, но разными выходными). Таким задачам нейронная сеть обучиться не может. Здесь возникает проблема разрешения такой противоречивой ситуации. Появление таких конфликтных примеров может, допустим, означать недостаточность набора входных признаков, поскольку при расширении признакового пространства конфликтным примерам могут соответствовать разные значения добавляемого признака и критическая ситуация будет исчерпана. В любом случае пользователь должен решить эту проблему, хотя бы даже простым исключением конфликтных примеров из задачника.

После обучения нейронной сети необходимо провести ее тестирование на тестовой выборке для определения точности решения не входивших в обучающую выборку задач. Точность решения очень сильно зависит от репрезентативности обучающей выборки. Обычно при решении различных неформализованных задач в разных проблемных областях точность в 70-90% правильных ответов на тестовой выборке соответствует проценту правильных ответов при решении этих же задач специалистом-экспертом. Может оказаться так, что нейронная сеть обучилась, но дает много ошибок на тестовой выборке. Природу этого явления нужно изучать в каждом конкретном случае. Одна возможная причина – нерепрезентативность обучающей выборки, когда обучающая выборка не охватывает всего множества ситуаций (выборка мала или просто узкоспециализирована). Иной причиной большого количества ошибок, на этот раз, только при решении задачи классификации, может быть неодинаковое число примеров разных классов. При этом при тестировании нейросеть будет достаточно хорошо распознавать примеры класса, для которого в обучающей выборке было большинство примеров, и относить к этому же классу много примеров другого класса. Поэтому желательно, чтобы в обучающей выборке было примерно одинаковое число примеров для каждого класса, или, по крайней мере, не было отличия на порядок и более. Если же неравномерность распределения примеров по классам есть особенность проблемной области, то нужно использовать при обучении сети оценки "с весами" – модификации стандартных оценок, позволяющие уравнивать вклад примеров разных классов в суммарную функцию оценки [9].

## **2.8. Упрощение нейронных сетей**

Сокращение множества параметров сети и входных сигналов может преследовать несколько целей:

Упрощение последующей аппаратной реализации нейронной сети;

Сокращение объема используемой памяти и повышение быстродействия программ-нейроимитаторов;

Удешевление процесса сбора данных за счет сокращения их объема; возможность решения задачи на основе меньшего объема входных данных;

Упрощение (контрастирование) нейронной сети строится как последовательный процесс исключения из сети наименее значимого элемента и дальнейшего доучивания сети. Если после шага упрощения невозможно доучивание сети до требуемой точности, то возвращаемся к сети, полученной на предыдущем шаге, и завершаем процесс упрощения. В следующем разделе опишем процедуру вычисления показателей значимости [4,5,9].

## **2.9 Вычисление показателей значимости параметров и входных сигналов сети**

У нейронной сети имеется набор  $n$ -мерных векторов данных  $x^i$ ,  $i=1, \dots, N$  (задачник) с координатами  $x_j^i$ ,  $j=1, \dots, n$ ,  $M$ -мерный вектор параметров  $a$  с координатами  $a_k$ ,  $k=1, \dots, M$ , и некоторая функция оценки  $H(x, a)$ , оценивающая работу сети с параметрами  $a$  на векторе данных  $x$ . Требуется выделить у сети наименее значимые параметры  $a_k$  и сигналы  $x_j$  и модифицировать систему, отбрасывая эти параметры и компоненты данных. Для каждого  $a_k$  определено некоторое значение  $a_k^0$  и сокращение  $a_k$  означает приравнивание  $a_k = a_k^0$ . Аналогично для каждой компоненты данных  $x_j$  и любого примера  $x^i$  определено  $x_j^{i0}$  и отбрасывание  $j$ -ой компоненты данных для  $i$ -го примера означает приравнивание  $x_j = x_j^{i0}$ .

Такая процедура допускает очень большую свободу в доопределении процедуры сокращения описания. В качестве простейшего базового варианта будем иметь в виду  $a_k^0 = 0$  и для всех  $i$  (параметры обращаются в нуль, данные заменяются средними по выборке). В случае данных,  $x_j^{i0} = \frac{1}{n} \sum_{p=1}^n x_j^p$  отнормированных, например, в диапазон  $[-1, 1]$ , в качестве  $x_j^{i0}$ , естественно, принимается нуль. Показатели значимости вычисляются в два этапа: сначала они вычисляются для одного вектора данных (примера), а потом – по всей выборке. Для данного  $x^p$  значимости  $a_k$  и  $x_j$  оцениваются так:

$$\chi(a_k | x^p) = \left| \frac{\partial H(x^p, a)}{\partial a_k} (a_k - a_k^0) \right|;$$

$$\chi(x_j | x^p) = \left| \frac{\partial H(x^p, a)}{\partial x_j} (x_j^p - x_j^{p0}) \right|.$$

Здесь  $\chi$  – просто вычисленные в линейном приближении абсолютные величины изменения  $H$  при сокращении описания, частные производные вычисляются при двойственном функционировании. Естественно, значение функции оценки должно быть ненулевым. Поэтому, если используются специализированные функции оценки, на этапе вычисления значимости необходимо возвращаться к оценке МНК.

Оценка по всему задачику производится с использованием некоторой нормы, например, с использованием нормы в виде суммы модулей

$$\chi(a_k) = \sum_p \chi(a_k | x^p); \quad \chi(x_j) = \sum_p \chi(x_j | x^p)$$

или максимума модулей.

$$\chi(a_k) = \max \chi(a_k | x^p); \quad \chi(x_j) = \max \chi(x_j | x^p).$$

Часто приходится иметь дело с системой, которая меняет свои параметры, например, в ходе обучения. Тогда к моменту принятия решения о значимости может быть накоплена информация о частных производных  $H$  в разных точках  $a = a^1, \dots, a^q$ . Тогда показатели значимости для одного вектора данных вычисляются так:

$$\chi(a_k | x^p) = \frac{1}{q} \sum_{s=1}^q \left| \frac{\partial H(x^p, a^s)}{\partial a_k} \right| * |a_k - a_k^0|;$$

$$\chi(x_j | x^p) = \frac{1}{q} \sum_{s=1}^q \left| \frac{\partial H(x^p, a^s)}{\partial x_j} \right| * |x_j^p - x_j^{p0}|.$$

Усредняются абсолютные значения производных, а приращения берутся в той точке, в которой будет проводиться процедура сокращения. Далее для всей выборки показатели значимости усредняются в одной из норм.

Использование вычисленных таким образом показателей значимости часто позволяет очень сильно сократить как число входных сигналов сети (остается только минимально необходимый для правильного решения задачи набор признаков), так и число элементов сети.

Если необходимо не исключать из сети адаптивные элементы, а приводить их значения к конечному набору выделенных значений, то для каждого  $a_k$  в качестве  $a_k^0$  принимается ближайшее к  $a_k$  выделенное значение. Такая задача возникает при бинаризации весов синапсов сети – приведении весов синапсов к величинам -1 или 1.

### **3. Транспонированная задача регрессии**

Представляют интерес не только задачи регрессии. Рассмотрим наиболее общую постановку задачи прогнозирования неизвестных значений. Пусть имеется таблица эмпирических данных, содержащая пропуски. Требуется заполнить эти пропуски и, при добавлении в таблицу информации о новых объектах, для которых отсутствуют значения некоторых признаков, прогнозировать отсутствующие значения. Классическая задача регрессии разбивает все множество признаков объекта на группы зависимых и независимых признаков и для каждого зависимого признака строит регрессионную зависимость от независимых свойств. Однако здесь имеются две трудности.

Предположение о том, что регрессионные зависимости одинаковы для всех объектов выборки, выполняется далеко не всегда. Также может потребоваться большое число регрессионных зависимостей – по одной для любой возможной комбинации пропусков в данных.

Если хорошей точности приближения известных данных добиться не удалось (невозможно построение регрессионной зависимости, общей для всех объектов), то можно предположить, что существуют такие признаки, которые не включены в рассматриваемую таблицу данных, но которые, тем не менее, являются значимыми и несут более существенную информацию и именно в них и заключены скрытые различия, не дающие построить искомые регрессионные зависимости. Эти неучтенные и неизмеренные свойства, от которых зависят наблюдаемые параметры, называют "скрытыми параметрами", а предположение о том, что все дело в них – *гипотезой о скрытых параметрах*.

Одна из простейших форм предположения о скрытых параметрах - *гипотеза о качественной неоднородности выборки*. Она означает, что скрытые параметры принимают сравнительно небольшое конечное число значений и всю выборку можно разбить на классы, внутри которых скрытые параметры, существенные для решения интересующей нас задачи регрессии, постоянны. Каждой такой выборке будет соответствовать "хорошая" регрессионная зависимость.

Построить классификацию (без учителя), соответствующую данной гипотезе, можно только на основе предположений о форме искомой регрессионной зависимости наблюдаемых параметров от наблюдаемых же параметров внутри классов (задача мозаичной регрессии). Если предполагается линейная зависимость, то эта задача классификации решается методом динамических ядер, только место точек – центров тяжести классов – занимают линейные многообразия, каждое из которых соответствует линейному регрессионному закону своего класса [9].

Регрессионные зависимости, которые строятся с помощью нейронных сетей, также образуют вполне определенный класс и для них тоже возможна соответствующая классификация без учителя. Достаточно большая нейронная сеть может освоить любую непротиворечивую обучающую выборку, однако, как показывает опыт, если малая нейронная сеть не может обучиться, то из этого можно извлечь полезную информацию. Если не удастся построить удовлетворительную регрессионную зависимость при заданном (небольшом) числе нейронов, то из обучающей выборки исключаются наиболее сложные примеры до тех пор, пока сеть не обучится. Так получается класс, который предположительно соответствует одному значению скрытых параметров. Далее обучение можно продолжить, сформировав из отброшенных примеров отдельный класс (скорректировав классификационную модель).

Транспонируем таблицу данных (поменяем местами слова "объект" и "признак"). Рассмотрим гипотезу о том, что значения признака одного объекта могут быть функциями значений того же признака других объектов и эти функции одни и те же для всех признаков (или классов признаков). Получаем формально те же задачи регрессии (*транспонированные задачи регрессии*). Есть, однако, два содержательных отличия транспонированных задач от исходных:

Инвариантность к смене шкал измерения – кажется маловероятным, чтобы существенные связи между признаками различных объектов зависели от шкалы измерения, поэтому необходимо, чтобы уравнения транспонированной регрессии были инвариантны относительно смены шкалы измерения любого признака  $x$  (обычно – линейного неоднородного преобразования  $x'=ax+b$ , однородная часть которого описывает смену единицы измерения, а свободный член – сдвиг начала отсчета);

В традиционных задачах регрессии предполагается, что объектов достаточно много ( $N$ ), по сравнению с числом признаков  $n$ , иначе (при  $N < n$ ) точные линейные соотношения возникнут просто из-за малого числа объектов, так как через  $N$  точек всегда можно провести линейное многообразие размерности  $N-1$ . В противовес этому "транспонированное" предположение о достаточно большом числе признаков ( $n > N$ ) кажется нереалистичным.

Требование инвариантности к смене шкал приводит к специальным ограничениям на вид функций регрессии, а недостаточность количества признаков (в сравнении с числом объектов) для построения транспонированной регрессии вынуждает нас для каждого объекта искать небольшую группу объектов, по свойствам которых можно восстановить свойства исходного. Иными словами, задача ставится так: найти для каждого объекта наилучшую формулу, выражающую его вектор признаков через векторы признаков других объектов (которых должно быть по возможности меньше) и инвариантную относительно смены шкал измерения признаков.

Итак, требуется построить отношение, связывающее объекты с группами объектов, по которым строятся интерполяционные формулы. Предположим, что некоторый большой набор свойств – внешних, эмпирических данных об объекте (явление) является сюръекцией небольшого набора внутренних, теоретических переменных (сущности). Эта идея позволяет сделать предположение о том, что размер опорной группы объектов, по которой наилучшим образом восстанавливаются свойства данного объекта, не только не должен превосходить размер набора свойств (иначе заведомо возникнут точные линейные соотношения), но и быть малым настолько, насколько это позволяет заданная точность [6,8,9].

Если предположить, что для некоторого множества объектов зависимость между теоретическим и эмпирическим линейна, и векторы теоретических параметров объектов данного множества лежат в линейном многообразии размерности  $q$ , то размер опорной группы не будет превосходить  $q+1$ .

Другое условие, налагаемое на искомую формулу, требует инвариантности к смене шкал измерений:

$$f(ay^1+b, \dots, ay^q+b) = a f(y^1, \dots, y^q) + b$$

Способ реализации этого ограничения — представление  $f$  в виде [6,17]

$$f(y, \dots, y^q) = M_y + \sum_{i=1}^q \varphi_i (y^1 - M_y, \dots, y^q - M_y) (y^i - M_y),$$

где  $M_y = \frac{1}{q} \sum_{i=1}^q y^i$  — барицентр опорной группы, а  $\varphi_i$  — однородные функции нулевой

степени : для любого  $a$ :  $\varphi_i(az_1, \dots, az_q) = \varphi_i(z_1, \dots, z_q)$ .

Простейшие примеры таких  $\varphi$ :

$$1) \varphi = \text{const}; \quad 2) \varphi = \frac{a_1 z_1 + \dots + a_q z_q}{b_1 z_1 + \dots + b_q z_q}; \quad 3) \varphi = \frac{a_1 \varphi_1 + \dots + a_q \varphi_q}{b_1 \varphi_1 + \dots + b_q \varphi_q}$$

где все  $\varphi$  в 3) имеют вид 2) с различными наборами коэффициентов  $a_i, b_i$ .

Если в качестве искомой формулы рассматривать линейную комбинацию векторов опорной группы (линейную транспонированную регрессию), то требуемой инвариантности можно достичь, наложив некоторое условие на коэффициенты разложения. Таковым условием является равенство суммы коэффициентов единице:

$$\tilde{\mathbf{y}} = \sum_i \alpha_i \mathbf{y}^i, \quad \sum_i \alpha_i = 1.$$

Рассматривались два варианта нахождения коэффициентов разложения, соответствующих некоторой опорной группе объектов. Первый:

$$\tilde{\mathbf{y}} = \mathbf{m}_y + \sum_{i=1}^q \beta_i (\mathbf{y}^i - \mathbf{m}_y), \quad \alpha_i = \beta_i + \frac{1}{q} - \frac{1}{q} \sum_{k=1}^q \beta_k \quad (1)$$

где  $\tilde{\mathbf{y}}$  — восстановленный вектор свойств,  $\mathbf{y}^i$  — вектор свойств  $i$ -го объекта опорной

группы,  $q$  — мощность опорной группы,  $\mathbf{m}_y = \frac{1}{q} \sum_{i=1}^q \mathbf{y}^i$ , — среднее значение (барицентр

опорной группы).

Во втором случае в качестве  $\mathbf{m}_y$  выбирался один из векторов опорной группы.

$$\tilde{\mathbf{y}} = \mathbf{y}^t + \sum_{i=1}^q \beta_i (\mathbf{y}^i - \mathbf{y}^t), \quad \alpha_i = \beta_i, \quad \alpha_t = 1 - \sum_{\substack{k=1 \\ k \neq t}}^q \beta_k \quad (2)$$

Заметим, что легко построить нейронную сеть, вычисляющую такие формулы [9,19]. Коэффициенты разложения определяются в ходе минимизации одного из следующих критериев:

$$a) \|\mathbf{y} - \tilde{\mathbf{y}}\|^2 + \varepsilon^2 \|\alpha\|^2 \rightarrow \min,$$

если в качестве нормы используется евклидова норма, или

$$б) \|\mathbf{y} - \tilde{\mathbf{y}}\| + \varepsilon \|\alpha\| \rightarrow \min$$

при использовании нормы в виде суммы модулей компонент вектора. Второе слагаемое в обоих критериях вводится для получения устойчивого решения — при уменьшении модулей коэффициентов разложения возможные искажения в значениях компонент векторов опорной группы приведут к меньшим ошибкам при восстановлении неизвестных компонент искомого вектора.

В случае а) точное решение находится из системы линейных уравнений. Введем обозначения:  $Y$  — матрица векторов опорной группы,  $n$  строк,  $q$  столбцов.  $n$  — число

известных компонент восстанавливаемого вектора  $y$ ;  $\hat{Y} = (y^j - m_y)$  – матрица  $Y$ , в которой из каждого столбца вычтен вектор  $m_y$  ( $y^t$  в случае 2);  $M$  – матрица, все элементы которой равны 1;  $m$  – вектор, все компоненты которого равны 1;  $E$  – единичная матрица;  $\alpha$ ,  $\beta$  – вектора размерностью  $q$ .

Для выражения (1)

$$\tilde{y} = m_y + Y\alpha, \quad \alpha = \frac{1}{q}m + \left(E - \frac{1}{q}M\right)\beta.$$

Дифференцируя выражение а) и приравнявая нулю, получаем:

$$\left(\hat{Y}^T \hat{Y} + \varepsilon \left(E - \frac{1}{q}M\right)\right)\beta = \hat{Y}^T (y - m_y).$$

Для выражения (2):  $e^t$  – вектор,  $t$ -ая компонента которого равна 1, остальные 0;  $L_t = (e^t)$  – матрица, столбцы которой равны вектору  $e^t$ .  $L_t^T L_t = M, L_t^T e^t = m$ . Имеем

$$\tilde{y} = y^t + Y\beta, \quad \alpha = e^t + (E - L_t)\beta, \\ \left(Y^T Y + \varepsilon(E + M)\right)\beta = Y^T (y - y^t) + \varepsilon m$$

Система уравнений решается для известных значений компонент вектора  $y$ , полученное решение используется для предсказания неизвестных значений.

В случае критерия б) в качестве начального приближения для каждого испытуемого набора рассматриваются  $\beta$ , минимизирующие невязку  $\Delta = \|y - \tilde{y}\|$ . Минимум всего критерия находится градиентным методом оптимизации; для вычисления градиента можно сделать переход в нейросетевой базис.

Для построения для объекта его оптимальной опорной группы возможны два варианта. Первый задает фиксированный размер (мощность) опорной группы и ищет оптимальную опорную группу в ходе полного перебора всех опорных групп заданной мощности. Оптимальной опорной группе будет соответствовать наименьшее значение критерия а) или б). Другой вариант (оптимизационный) предполагает первоначальное задание избыточного числа объектов в опорной группе и последующее сокращение ее размера в результате отбрасывания наименее значимых объектов (входящих в транспонированную регрессионную формулу с наименьшим по модулю весом  $\alpha_i$ ). Этот вариант разумнее реализовать в нейросетевом базисе.

После построения для объекта оптимальной опорной группы возможно прогнозирование значений отсутствующих у него признаков на основе единого регрессионного уравнения. При этом единственным требованием для возможности прогноза является необходимость наличия значений соответствующих признаков у объектов его опорной группы.

#### **4. Применение нейросетевых технологий для обработки таблицы климатических данных**

Для обработки была взята база данных по климату и растительности Института леса СО РАН в г.Красноярске, построенная по средним многолетним значениям характеристик климата, измеренных на 170 метеостанциях.

Каждая из 170 станций охарактеризована 20 полями, из которых от 5 до 9 полей занимают характеристики климата, остальные – характеристики растительного и почвенного покрова. По этим качественным характеристикам определена зональная принадлежность каждой станции к той или иной ландшафтной зоне и сделано предположение, что данные зоны имеют достаточно устойчивую корреляцию с некоторыми из климатических

характеристик – теплом, относительным увлажнением, степенью континентальности климата и др. Зоны самого крупного порядка – тундра, лес и степь; между ними есть полосы перехода – лесотундра и редколесье на севере и лесостепь на юге. Этого перечня должно было хватить для того, чтобы прогнозировать (точнее идентифицировать) по климату зональный тип растительности, дающий название ландшафтной зоне.

База данных была сверена со справочниками по климату СССР и дополнена новыми данными. В настоящее время база данных имеет 250 записей (метеостанций) и 25 полей.

На основе описанной таблицы данных выполнялись работы по прогнозированию, классификации и глобальному моделированию с применением искусственных нейронных сетей.

#### **4.1. Заполнение пропусков в таблице климатических данных**

Решалась задача заполнения пропусков в значениях 6 интегральных климатических параметров:

- годовая сумма температур;
- годовая сумма осадков;
- коэффициент увлажнения;
- дефицит влаги;
- индекс сухости;
- индекс континентальности.

Для 121 метеостанции имелись значения всех шести климатических параметров, у остальных в различных комбинациях отсутствовали значения одного-трех параметров. Целью работы являлось прогнозирование отсутствующих значений.

Первым этапом работы являлось оценивание точности прогнозирования известных данных при помощи нейросетевых методов обработки информации. Использовалась нейросетевая нелинейная регрессия и транспонированная линейная регрессия.

Определение точности прогноза проводилось в режиме скользящего экзамена на основе данных по 121 метеостанции, где имелись значения всех шести параметров. Оценивалась точность прогнозирования одного из климатических параметров на основе информации о пяти других.

При использовании транспонированной линейной регрессии для каждой из метеостанций по пяти климатическим параметрам отбиралась наилучшая опорная группа из нескольких метеостанций и по построенному транспонированному регрессионному уравнению на основе значений искомого признака у метеостанций наилучшей опорной группы прогнозировалось значение искомого признака целевой метеостанции и прогнозное значение затем сравнивалось с известным значением этого признака у данной метеостанции. Затем для метеостанции прогнозировался другой климатический параметр после построения новой (возможно, включающей другие метеостанции) опорной группы по набору из оставшихся пяти параметров. Далее для каждого из параметров по всему набору из 121 метеостанции находились средние и максимальные ошибки прогноза известных значений. Такая работа по нахождению проводилась несколько раз для оценки влияния различных параметров метода транспонированной линейной регрессии (например, числа метеостанций в опорной группе) на достигаемую точность прогноза. При использовании нейросетевой нелинейной регрессии процесс оценивания точности прогноза являлся модификацией скользящего экзамена, примененного для транспонированной линейной регрессии. По-прежнему прогнозировался один из параметров метеостанции по значениям пяти других параметров. При этом весь набор из 121 станции разбивался на 5 частей и 4 части (80% от числа метеостанций) использовались для обучения нейронной сети, а оставшаяся часть – для определения точности прогноза искомого климатического параметра. Для прогнозирования каждого из



параметров обучались 5 нейронных сетей (каждая по своему набору из 80% метеостанций) и определялись средняя и максимальная ошибки прогноза этого параметра. Таким образом, было обучено 30 нейронных сетей.

В Табл. 1 представлены результаты по полученной точности прогноза. Для каждого климатического параметра представлены максимальная и средняя ошибки, выраженные в процентах от диапазона изменения соответствующего параметра. Для транспонированной линейной регрессии представлены точности прогноза при разном числе метеостанций в опорной группе (две, три и четыре станции). Чтобы сравнить полученную точность прогноза с точностью, достигаемой классическими методами построения зависимостей, в таблице приведена точность прогноза классической линейной регрессии.

Можно сделать следующие выводы. Нейросетевая нелинейная регрессия и транспонированная линейная регрессия (при четырех метеостанциях в опорной группе) показали лучшую точность прогноза по сравнению с классической линейной регрессией. Поскольку при решении задачи регрессии при переходе от линейных регрессионных зависимостей (классическая линейная регрессия) к нелинейным (нейросетевая регрессия) наблюдается повышение точности прогноза, то по аналогии можно предположить потенциальное повышение точности прогноза при переходе от транспонированных линейных регрессионных зависимостей к нелинейным транспонированным регрессионным зависимостям (даже к простейшим дробно-рациональным, представленным в гл.3).

Тем не менее, не надо на основании только этой работы делать вывод, что

Таблица 1.

Достигнутая точность прогноза климатических параметров

Использованный метод построения регрессионной зависимости		Ошибка (максимальная (max), средняя (avg)) прогноза известных данных, в % от диапазона изменения параметра, по климатическим параметрам											
		Коэфф-т увлажнения		Годовая сумма температур		Дефицит влаги		Индекс континентальности		Индекс сухости		Годовая сумма осадков	
		max	avg	max	avg	Ma x	avg	max	avg	max	avg	max	avg
Линейная регрессия		20,3	2,0	53,4	7,7	29,9	9,9	33,1	9,3	38,3	9,0	22,3	2,9
Нейросетевая нелин. Регрессия		4,4	1,1	10,1	3,0	14,8	5,0	11,8	3,2	13,9	4,1	5,5	1,2
Трансп. лин. регрессия	2 метеостанции	19,9	1,4	49,3	8,9	43,9	10,4	64,0	10,3	39,5	8,2	34,2	1,9
	3 метеостанции	21,8	1,3	34,6	5,7	39,	11,2	35,5	8,7	42,3	7,9	27,4	1,3
	4 метеостанции	18,7	1,2	32,5	5,7	29,2	7,5	27,6	7,7	37,6	6,1	12,9	1,5

транспонированная линейная регрессия уступает регрессии нейросетевой. Имеются опыты по весьма эффективному применению транспонированной регрессии, даже

простейшей линейной, как в данной работе, для обработки иных таблиц данных [18]. У транспонированной регрессии как у метода анализа эмпирических данных имеется одно преимущество, которое для некоторых задач может быть значимым. Поскольку для каждого объекта строится оптимальная опорная группа, то в результате получается некоторая группировка объектов – пары "искомый объект" – "малая группа объектов, наилучшим образом описывающая искомый". Теперь можно решать некоторые содержательные задачи на основе такой группировки объектов.

В приведенном примере каждой метеостанции соответствует точка на карте (если рассматривать географические координаты станции – ее широту и долготу). Если для каждой станции проанализировать территориальное размещение станций, входящих в ее оптимальную опорную группу, то оказывается, что станции опорной группы расположены достаточно компактно относительно исходной. Иными словами, не происходит интерполяции климатических параметров, например, восточносибирских метеостанций по значениям параметров станций Западной Сибири и Дальнего Востока, или станций района Красноярск по станциям Таймыра и Алтая. Такая глобальная интерполяция, конечно, возможна, но по точности проигрывает локальным моделям климатической ситуации. Можно сказать, что достаточно существенный вклад в климатическую ситуацию района вносят особенности самого района, как-то: удаленность от океана, рельеф местности и другие параметры, влияние которых можно учитывать при прогнозировании климатических параметров метеостанции по близлежащим метеостанциям.

Вернемся к исходной задаче заполнения пропусков в таблице данных. Тестирование точности прогноза проводилось в условиях, достаточно сильно отличающихся от реальных – у метеостанций в действительности могли отсутствовать значения более чем одного параметра. Реально из 111 метеостанций, для которых восстанавливались отсутствующие значения, 84 станции имели пропущенные значения одного параметра, 19 – двух и 8 метеостанций – трех параметров. Определение точности прогноза одновременно двух и более параметров в данной работе не рассматривалось, но, естественно, эта точность оказалась бы ниже точности, достигнутой при прогнозе одного параметра (из-за сокращения набора признаков, по которым делался бы прогноз). Точность прогноза, достигнутая нейросетевыми методами, оказалась достаточной и позволила провести дальнейшую работу по прогнозированию неизвестных значений климатических параметров у отдельных метеостанций. При этом в большинстве случаев прогнозные значения, получаемые разными методами, были достаточно близки друг к другу и к экспертным заключениям, выполнявшимся с привлечением дополнительной информации.

Здесь может возникнуть справедливое замечание: можно ли доверять прогнозу, сделанному на основании обработки такой достаточно малой таблицы данных.

Излагаемые далее результаты будут получены даже на еще меньших объемах данных. Однако повторим, что в случае отсутствия теоретически обоснованных моделей единственным способом проверки адекватности построенной модели является рассмотрение точности прогноза модели на тестовой выборке, а точность получилась достаточной. Также специфика данных проблемных областей такова, что прогноз модели непосредственно не "пойдет в дело" – исследователь будет сравнивать прогноз модели с собственными экспертными заключениями и использовать наиболее правдоподобное значение.

Результаты данного исследования позволяют предположить, что нейросетевые методы восстановления зависимостей с успехом могут быть использованы при решении различных задач прогнозирования при обработке климатической, метеорологической и экологической информации.

#### **4.2. Построение классификационной модели ландшафтных зон и секторов континентальности**

В этом разделе описаны исследования, выполнявшиеся для решения различных задач классификации на основе описанных выше климатических данных. В разделах 4.2.1 и 4.2.2 описана постановка задач классификации (разделения) метеостанций, находящихся в различных ландшафтных зонах и секторах континентальности, и приведены результаты по достигнутой на тестовых выборках точности прогноза. В качестве независимых признаков бралось несколько интегральных климатических параметров. В разделе 4.3 описан опыт моделирования глобального изменения климата, когда для ряда метеостанций по оценкам экспертов на 2030г. были изменены значения рассматриваемых климатических параметров и прогнозировалась потенциально возможная смена климатических зон и секторов континентальности у этих станций, что привело бы к изменению ландшафтных зон и смене лесообразователей в соответствующих районах.

#### **4.2.1. Классификация ландшафтных зон Сибири**

Для решения задачи классификации ландшафтных зон выбрано четыре крупных зональных класса :

1. Тундра и северное редколесье (лесотундра);
2. Лес;
3. Лесостепь;
4. Степь.

Для полученные этой обобщенной зональной классификации были переработаны данные по более точной зональной классификации, включающей 20 мелких климатических зон Сибири.

Ландшафтные зоны: тундра, лес, степь – это основные природные зоны Сибири.

Лесотундра и лесостепь являются экотонами. Экотон – это промежуточная полоса между двумя соседними зонами. Экотон лесостепи представляет особый интерес с точки зрения классификации и прогноза: куда отнести лесостепь, к лесу или степи, или рассматривать ее как самостоятельную ландшафтную зону? Вопрос этот дискуссионен и решается разными специалистами по-разному [13,15].

Деление на зоны не является достаточным, так как в разных экорегионах зоны имеют свои самобытные черты состава, структуры, и функционирования. Поэтому широтно-зональное деление необходимо сочетать с секторным, проводимым с учетом континентальности.

Континентальность характеризует суровость климата в регионах и имеет очень большое значение для классификации растительных зон Сибири [16].

Для решения задачи классификации секторов континентальности все лесные зоны (лес, лесостепь и лесотундра) на втором шаге построения иерархической системы разделены на три сектора континентальности:

1. континентальный,
2. резко континентальный,
3. крайне континентальный.

Таким образом, система включает 4 зоны, 3 сектора и 12 производных единиц – секторно-зональных классов.

Задача классификации состоит в следующем: определить, к какому зональному классу и сектору континентальности относится тот или иной набор значений климатических параметров метеостанций.

Для решения задачи классификации были выбраны следующие климатические параметры:

1. Дефицит влажности.
2. Сумма температур за период с температурами выше 5°C.
3. Сумма температур за период с температурами выше 10°C (*Gdd10*).
4. Средняя температура января (*Mjan*).
5. Средняя температура июля (*Mjul*).
6. Сумма осадков за холодный период года (*OsdCold*).

Мнемонические имена некоторых климатических параметров здесь приводятся для последующего удобства записи формул. Дополнительно в данную выборку были включены три параметра:

Сумма осадков за год (*Osd*), вычисленная по формуле  $Osd = OsdCold + OsdWarm$ , где *OsdWarm* – сумма осадков теплого периода.

Коэффициент увлажнения (*Kv*), вычисленный по формуле Мезенцева

$$Kv = \frac{Osd}{0.2 * Gdd10 + 306}$$

Индекс континентальности (*IndK*), вычисленный по формуле Конрада,

$$IndK = \frac{1.7 * Amplituda}{\sin(shirota + 10)} - 14, \text{ где } Amplituda = Mjul + |Mjan|, \text{ а } shirota -$$

географическая широта метеостанции.

Обучающая и тестирующая выборки для нейронных сетей содержат эти девять входных параметров (климатических признаков), и один выходной параметр – код ландшафтной зоны.

В работе строилось несколько классификационных моделей путем последовательного уточнения классификации.

На первом этапе исследований проводилось деление на 3 зональных класса – тундру-лесотундру, лес и степь. Лесостепь как зональный класс не была включена в выборку чтобы изучить поведение лесостепи как экотона, промежуточного между лесом и степью. В обучающую выборку включены данные для 99 метеостанций, а в тестирующую – для 64 станций. В обучающей и тестирующей выборках примеры делятся по классам следующим образом (здесь и далее первым числом является число примеров в обучающей, а вторым – в тестовой выборке):

- класс 1 (тундра и лесотундра) – 18 и 6 примеров,
- класс 2 (лес) – 65 и 54 примеров,
- класс 3 (степь) – 16 и 4 примера.

На этой обучающей выборке было обучено 15 нейросетей с различными параметрами. Процент правильных ответов на тестовой выборке колебался в диапазоне от 81 до 86%. Для сети с наилучшей точностью прогноза ошибка распределяется так: к лесотундровой зоне ошибочно отнесены 2 из 54 метеостанций лесной зоны; к лесной зоне – 2 из 6 метеостанций лесотундровой зоны; к степной зоне – 4 метеостанции из 54 метеостанций лесной зоны.

Самыми информативными климатическими параметрами из девяти использовавшихся для этой сети оказались сумма осадков за год, средняя температура июля и осадки холодного периода. В работе только определялась информативность входных сигналов, а работа по сокращению их числа не проводилась.

При тестировании 32-х станций лесостепи этой нейросетью получились следующие результаты:

- 14 метеостанций попали в лесную зону,
- 18 – в степь.

В общем случае лесостепная зона распределялась между лесом и степью следующим образом при тестировании всех 15-ти обученных нейронных сетей:

- от 11 до 20 метеостанций попадали в лесную зону,
- от 12 до 21 – в степь.

Отсюда следует, что лесостепные станции не только образуют пограничный класс (экотон), но и занимают определенное место в климатическом пространстве. Поэтому правомерно выделение лесостепи в качестве самостоятельной биоклиматической зоны. Применение обучаемых нейросетевых классификаторов позволило внести ясность в классификационное положение лесостепи, которое оставалось дискуссионным на протяжении долгого времени. Подтверждена точка зрения ландшафтоведов-географов, выделяющих лесостепь в качестве самостоятельной природной зоны наряду с лесом и степью.

На втором этапе исследования выполнено отделение лесостепи от леса и степи. В обучающую выборку включены данные для 108 метеостанций, а в тестирующую – для 60 станций. В обучающей и тестирующей выборках примеры делятся по классам следующим образом:

- класс 1 (лес) – 66 и 46 примеров,
- класс 2 (лесостепь) – 24 и 8 примеров,
- класс 3 (степь) – 18 и 6 примеров.

Обучено 15 нейросетей с различными параметрами и точностью прогноза на тестовой выборке от 73 до 82%. Для наилучшей нейросети получились следующие результаты: к лесной зоне ошибочно отнесены 2 из 8 метеостанций лесостепной зоны и 1 из 6 метеостанций степной зоны; к лесостепной зоне – 3 из 46 метеостанций лесной зоны и 2

из 6 метеостанций степной зоны; к степной зоне – 1 из 8 метеостанций лесостепной зоны и 2 из 46 станций лесной зоны.

Самыми информативными параметрами для лучшей нейросети оказались осадки холодного периода, индекс континентальности и температура января. Весьма знаменательно, что и в работах географов осадки холодного периода выделяются как главный, наиболее информативный признак для отделения леса от лесостепи [1]. Сравнивая результаты классификаций ландшафтных зон с лесостепью и без нее, можно сделать вывод, что лесостепь, как пограничный класс, выделяется несколько хуже других. Интервал колебания процента правильных ответов увеличился от 5 до 9%. В дополнение к тому, что экотоны трудно разграничить, лесостепь – это самая освоенная человеком ландшафтная зона. Вмешательства человека настолько велики, что изменились естественные границы и покров лесостепной зоны. Но это не означает, что лесостепь нельзя идентифицировать по климатическим параметрам. Класс "лесостепь", как и три других класса, дает вполне допустимые погрешности при тестировании: скачков через соседний класс нет, а ошибочные определения зоны связаны с тем, что в соседний класс попадают метеостанции, близкие к границе между соседними зонами.

Для более точного выделения зональных классов и наиболее информативных признаков целесообразно вводить бинарные классификации – разделения двух соседних зон.

На следующем этапе исследований сделаны 3 бинарные классификации:

1. Лесотундра и лес.
2. Лес и лесостепь.
3. Лесостепь и степь.

Рассмотрим первую бинарную классификацию. В обучающую выборку включены данные для 83 метеостанций, а в тестирующую – для 53 станций. В обучающей и тестирующей выборках примеры делятся по классам следующим образом:

- класс 1 (лесотундра) – 20 и 4 примера,
- класс 2 (лес) – 63 и 49 примеров.

Обучено 10 нейросетей с различными параметрами. При тестировании процент правильных ответов колебался от 87 до 93%. Наилучшей нейросетью к лесотундровой зоне ошибочно отнесено 5 из 49 метеостанций лесной зоны. Самыми информативными параметрами для данной нейронной сети оказались годовая сумма осадков, осадки холодного периода и средняя температура января.

Данное ранжирование параметров по информативности не поддается пока объяснению. Согласно общепринятому взгляду, северная граница леса определяется температурой июля или другими показателями из группы "теплообеспеченность". Все же результат косвенно говорит о суровости зимы, и в этом есть своя логика.

Следующая бинарная классификация – разделение леса и лесостепи. В обучающую выборку включены данные для 89 метеостанций, а в тестирующую – для 55 станций. В обучающей и тестирующей выборках примеры делятся по классам следующим образом:

- класс 1 (лес) – 63 и 49 примеров,
- класс 2 (лесостепь) – 26 и 6 примеров.

Обучено 15 нейросетей с различными параметрами. При тестировании процент правильных ответов колебался от 81 до 96%, наилучшая нейросеть ошибалась так: к лесной зоне отнесена 1 из 6 метеостанций лесостепной зоны; к лесостепной зоне отнесены 2 из 49 метеостанции лесной зоны. Самыми информативными параметрами для этой сети оказались средняя температура января, индекс континентальности и дефицит влаги. Экологическое значение этого ранжирования параметров трудно интерпретировать, поскольку экспертная оценка не совпадает. Дефицит влаги должен быть на первом месте, а осадки зимнего периода – на следующем. Значимость температуры января и индекса континентальности оценить сложно. Этот результат мог возникнуть потому, что лесные районы расположены в Западной и Средней Сибири, а лесостепь – в Восточной. Иными словами, температурный класс зон один, а секторы континентальности – разные.

И последняя бинарная классификация – разделение лесостепи и степи. В обучающую выборку включены данные для 43 метеостанций, а в тестирующую – для 17 метеостанций. В обучающей и тестирующей выборках примеры делятся по классам следующим образом:

- класс 1 (лесостепь) – 21 и 11 примеров,
- класс 2 (степь) – 18 и 6 примеров.

Обучено 20 нейросетей с различными параметрами. При тестировании наилучшей нейросети ошибочно отнесена к лесостепной зоне 1 из 6 метеостанций степной зоны. Самыми информативными параметрами для лучшей сети оказались коэффициент увлажнения, годовая сумма осадков и средняя температура июля. По оценкам экспертов, это отличное выделение наиболее значимых признаков. Показатели увлажнения и должны играть роль дифференцирующих признаков при разделении степи и лесостепи. Обсуждая результаты, можно сделать вывод, что бинарная классификация ландшафтных зон оказалась более точной (увеличился процент правильных ответов). Для каждой из классификаций имеется собственное ранжирование климатических параметров по степени важности для принятия решения – отнесения метеостанции к тому или иному классу.

#### **4.2.2. Идентификация лесных зон по континентальности**

В данной работе все лесные зоны (лесотундра, лес и лесостепь) разделены на три сектора континентальности:

1. Континентальный.
2. Резко континентальный.
3. Крайне континентальный.

Первая классификация сделана отдельно для равнин. В обучающую выборку включены данные для 76 метеостанций, а в тестирующую – для 62 метеостанций. Взяты те же входные параметры, что и для рассмотренной ранее классификации ландшафтных зон, выходным параметром (классом) является сектор континентальности. В обучающей и тестирующей выборках примеры делятся по классам следующим образом:

- класс 1 (континентальный сектор) – 19 и 15 примеров,
- класс 2 (резко континентальный) – 24 и 20 примеров,
- класс 3 (крайне континентальный) – 33 и 27 примеров.

Обучено 12 нейросетей. При тестировании процент правильных ответов колебался от 72 до 82%. Наилучшая сеть ошибается так: к континентальному сектору отнесены 3 из 20 метеостанций резко континентального сектора и 1 из 27 метеостанций крайне континентального сектора; к резко континентальному сектору отнесены 3 из 15 станций континентального сектора и 2 из 27 станций крайне континентального сектора; к крайне континентальному сектору отнесены 3 из 20 станций резко континентального сектора. Самыми информативными параметрами для данной нейронной сети оказались коэффициент увлажнения, средняя температура июля и годовая сумма осадков.

Для классификации секторов в горах в обучающую выборку включены данные для 44 метеостанций, а в тестирующую – для 18 метеостанций. В обучающей и тестирующей выборках примеры делятся по классам следующим образом:

- класс 1 (континентальный) – 15 и 5 примеров,
- класс 2 (резко континентальный) – 12 и 4 примера,
- класс 3 (крайне континентальный) – 17 и 9 примеров.

Для разделения секторов в горах обучено 16 нейросетей. При тестировании процент правильных ответов колебался от 72 до 89%. При тестировании нейросети с лучшей точностью прогноза получились следующие результаты: к резко континентальному сектору отнесена 1 из 9 метеостанций крайне континентального сектора, к крайне континентальному сектору отнесена 1 из 4 метеостанций резко континентального сектора. Самыми информативными параметрами для данной нейронной сети оказались осадки холодного периода, индекс континентальности и дефицит влаги. Это хороший результат.

Все три параметра действительно значимы и имеют экологический смысл применительно к ситуации.

Информативность климатических параметров для классификации секторов континентальности на равнине и в горах сильно отличается, поэтому эти секторы нежелательно объединять в одну классификацию. Нужно отметить, что для классификации равнинных секторов индекс континентальности не играет большой роли (по сравнению с его значимостью для классификации секторов в горах). Хотя этот параметр, по мнению ландшафтоведов, имеет важное значение для классификации секторов.

По итогам работы по разделению секторов можно сделать следующие выводы: данная классификационная модель, как и классификация ландшафтных зон, пригодна для дальнейших исследований, т.к. по небольшому количеству основных параметров климата она дает неплохие результаты.

#### **4.3. Прогнозирование возможного изменения ландшафтных зон и секторов континентальности**

Для прогноза крупных зональных классов – ландшафтных зон или зонобиомов – разрабатываются модели глобального уровня [19,20,22]. Считается, что изменения температуры января и июля наиболее доступны для долгосрочного прогноза, а поскольку по ним можно вычислить индекс континентальности, то можно предложить последний как один из наиболее доступных производных параметров. Известно, что с континентальностью связана повторяемость воздушных масс океанического и континентального происхождения и режимы тепла и влаги. Эксперты предсказывают, что в наших широтах средняя температура января увеличится на 3-4°C, а июля – на 1-2°C, и эти данные согласуются у различных авторов. Это означает, что континентальность снизится, и режимы тепла будут менее суровы в году.

Труднее предсказать режим увлажнения. Поэтому в данной работе взято некоторое приближение сценариев. Так, предполагается, что количество осадков холодного периода может увеличиться на 10-30 мм, а количество годовых осадков – на 30-50 мм. И эти все значения меняются по долготе (см. Таблица 2).

Еще хуже дело обстоит с учетом взаимодействия систем в силу не только прямых, но и обратных связей климат–растительность, и множества косвенных взаимодействий (лес – почва, лес – насекомые, пожары и др. экстремальные события). Разработка общей концепции прогноза наземных экосистем еще далека от завершения.



Задача данного исследования – сделать первый шаг к прогнозу изменения ландшафтного покрова на основе базы данных по климату и растительности, опираясь на фундаментальную концепцию природной зональности Докучаева–Берга–Григорьева–Будыко. Учитывая характер базы данных, следует ограничиться точечным прогнозом, т.е. исследованием возможности смены секторно-зональной принадлежности конкретных точек (метеостанций) согласно одному из сценариев климата на 2030 год. Весьма актуальной представляется возможность выявления тех территорий, которые могут оказаться особенно подвергнутыми риску сокращения лесных площадей.

Таблица 2.

Прогноз изменения климатических параметров по секторам континентальности на 2030 год

Климатические Параметры	Континентальный и резко континентальный секторы	Крайне Континентальный сектор
Температура января	+ 3°	+ 4°
Температура июля	+ 1°	+ 2°
Сумма осадков за холодный период года	+ 30 мм	+ 10 мм
Сумма осадков за год	+ 50 мм	+ 30 мм

Для решения задачи прогноза смены ландшафтных зон из обучающей и тестирующей выборок для нейронных сетей исключены четыре параметра, которые пока недоступны для прогноза:

1. Коэффициент увлажнения.
2. Дефицит влажности.
3. Сумма температур за период выше 5°С.
4. Сумма температур за период выше 10°С.

Итак, в обучающей и тестируемой выборках осталось пять параметров:

1. Индекс континентальности.
2. Средняя температура января.
3. Средняя температура июля.
4. Сумма осадков за холодный период года.
5. Сумма осадков за год.

Для прогноза смены ландшафтных зон и секторов континентальности на 2030г. выбрана описанная ранее последовательно уточняемая классификационная модель ландшафтных зон (без бинарной классификации зон) и деление на три сектора континентальности. На выборке из оставшихся пяти параметров для каждой классификационной модели были обучены наборы нейросетей, и для каждой классификационной модели было выбрано по одной нейросети с наибольшим процентом правильных ответов:

Для классификации ландшафтных зон без лесостепи – 83% правильных ответов. При тестировании к лесотундровой зоне ошибочно отнесены 5 из 54 станций лесной зоны, к лесной зоне – 1 из 6 станций лесотундровой зоны и 1 из 4 станций степной зоны, к степной зоне – 3 из 54 станций лесной зоны.

Для классификации леса, лесостепи и степи – 80%. При тестировании к лесной зоне ошибочно отнесены 2 из 8 метеостанций лесостепной зоны и 1 из 6 станций степной зоны,

к лесостепной зоне – 4 из 46 станций лесной зоны и 2 из 6 станций степной зоны, к степной зоне – 2 из 8 станций лесостепной зоны и 1 из 6 станций степной зоны.

Для классификации секторов континентальности на равнине – 82%. При тестировании к континентальному сектору ошибочно отнесены 3 из 20 станций резко континентального сектора, к резко континентальному сектору – 2 из 15 станций континентального сектора и 3 из 27 станций крайне континентального сектора, к крайне континентальному сектору – 2 из 20 станций резко континентального сектора.

Для классификации секторов в горах – 94%, к резко континентальному сектору ошибочно отнесена 1 из 4 метеостанций крайне континентального сектора.

Самыми информативными параметрами при прогнозе оказались следующие:

- Для ландшафтных зон без лесостепи – средняя температура января, осадки холодного периода и сумма осадков за год.
- Для ландшафтных зон с лесостепью – осадки холодного периода и сумма осадков за год.
- Для секторов континентальности на равнине – осадки холодного периода, сумма осадков за год и индекс континентальности.
- Для секторов континентальности в горах – средняя температура июля, индекс континентальности и средняя температура января.

При обучении нейросетей для прогноза на основании пяти параметров распознаваемость классов, в общем, не ухудшилась: понижение процента правильных ответов произошло на 1-2%. Распознаваемость секторов континентальности в горах улучшилась с 89 до 94%.

Стоит отметить, что обучение нейронных сетей на меньшем количестве входных параметров происходило значительно дольше. Интервал колебания процента правильных ответов стал больше. В целом данную систему классификации можно использовать для прогноза, предварительно убедившись в ее объективности.

При дальнейшем исследовании возможной смены ландшафтных зон нужно дополнительно включить в обучающую и тестирующую выборки новые климатические параметры, доступные для прогноза.

В качестве примера на полученных нейросетях по данным эксперта выполнен точечный прогноз ситуации на 2030г. для 40 метеостанций, расположенных в разных ландшафтных зонах и секторах континентальности. Определялась возможность изменения лесорастительного потенциала метеостанций, т.е. их зональной и секторной принадлежности при заданном сценарии климата.

По таблице "Изменение климатических параметров по секторам на 2030 год" (Таблица 2) для 40 метеостанций были изменены следующие параметры: средняя температура января, средняя температура июля, сумма осадков за холодный период года, сумма осадков за год. На основании измененных параметров был вычислен индекс континентальности по формуле Конрада. Далее использовались обученные нейронные сети для определения зон и секторов, которые должны соответствовать измененным климатическим параметрам метеостанций.

При прогнозе разные станции ведут себя по-разному. 26 метеостанций остались в тех же зонах и секторах (например, Богучаны, Енисейск, Игарка, Красноярск, Томск). А те, которые были ближе к климатическим границам, переходят в другой класс. У 8 метеостанций изменилась зона (например: Братск, Кежма, Якутск, Янск), эти зоны имеют потенциал, соответствующий соседней, более южной зоне. И для 7 станций изменился сектор континентальности (например: Канск, Минусинск, Абакан), эти секторы имеют потенциал, соответствующий соседнему, менее континентальному сектору.

Соответственно прогнозу в данных зонах и секторах должна измениться и растительность. Отсюда следует, что к 2030г. все современные ландшафтные зоны сохранятся на территории Сибири, хотя некоторые смещения границ, возможно, произойдут. Общий вывод данного точечного прогноза сводится к тому, что тенденции к сменам на более "южную" зону могут проявиться во всех звеньях ландшафтов: в растительности, почвах,

гидрологическом режиме и т.д. Тенденция смены более северных зон более южными и менее континентальными, отмечаемая другими авторами [21], в целом подтверждается. Оценивая первые опыты моделирования, не следует особенно доверять полученным результатам, поскольку авторы не учитывали обратное влияние лесных экосистем на климат и многие косвенные взаимодействия в ландшафтах. В данном случае важен не столько результат прогноза, сколько методика прогноза. Фактически мы прогнозируем, какое новое равновесное состояние будет устойчивым, если температура июля вырастет на 1-2 градуса, января – на 3-4 градуса, осадки за год вырастут на 30-50 мм., осадки холодного периода – на 10-30 мм. Если какая-либо точка переходит в другой, соседний класс, это означает для нее потенциальное состояние растительного покрова, тогда как реальный покров не сразу достигнет этого состояния. Нужно, чтобы прошло, по меньшей мере, несколько сотен лет (время релаксации лесной растительности) для достижения нового равновесного состояния в ландшафте при данном климатическом сценарии. Определим теоретическое и прикладное значение прогноза. Очевидно, что лесное хозяйство должно принимать во внимание долгосрочные прогнозы климата для того, чтобы планировать лесовосстановление, поддержание лесистости и устойчивости лесного покрова с учетом региональных особенностей. Моделирование с помощью нейронных сетей позволяет выделить те объекты (регионы), которые могут подвергнуться максимальному риску. Так, например, не следует проводить массовые посадки леса в тех районах, где наиболее высок риск засухи, пожара. Здесь важнее провести первоочередную противопожарную профилактику лесных массивов и ограничить посадки леса наиболее благоприятными условиями топографии и почв.

## **5. Заключение**

В данной работе описаны результаты применения нейросетевых методов обработки информации для решения задач прогнозирования и классификации при обработке климатических данных. Задачи решаются достаточно эффективно и результаты их решения могут быть использованы в дальнейшем. Очень просто выглядит возможность моделирования глобального изменения климата и оценки последствий этого изменения. К настоящему времени накоплен очень большой опыт по применению нейронных сетей для решения задач в различных проблемных областях – не только в климатологии (здесь это наш первый опыт), но и в медицине, психологии и политологии, диагностике и оптимальном управлении в технических системах и т.д. [9]. Нейронные сети позволяют решать различные неформализованные задачи (задачи, где алгоритм решения неизвестен). Исследователь при этом получает очень эффективную модель проблемной области и может очень просто моделировать различные ситуации, предъявляя сети различные данные и оценивая ответ, выдаваемый сетью. Нейронные сети могут применяться и в ситуациях, когда известен сравнимый по точности прогноза метод решения, но критично, например, время получения результата, поскольку обученная нейронная сеть решает предъявляемую ей задачу очень быстро. Большинство пользователей (от простых пользователей нейросетевых экспертных систем до специалистов-исследователей в области нейроинформатики), применяющих нейронные сети, отмечают единственный существенный недостаток нейронных сетей. А именно, человеку не понятно, какие "рассуждения" используются внутри нейронной сети при решении задачи. Иными словами, очень трудно понять процесс получения сетью результата. Первый шаг в этом направлении уже сделан. Сеть может количественно оценить влияние входных признаков на точность решения задачи. Ранжируя входные признаки по этим показателям значимости и последовательно исключая наименее значимые (дообучая при этом сеть извлекать нужную информацию из меньшего объема данных), можно получить минимально необходимый для правильного решения задачи набор входных параметров. Это уже дает информацию для содержательного анализа.

В настоящее время ведутся работы по созданию новой технологии, позволяющих не только решать задачи с помощью обучаемых нейронных сетей, но и генерировать вербализованное (на естественном языке) описание процесса решения сетью задачи. Фактически, по таблице экспериментальных данных, описывающих проблемную область, можно будет получить новое знание – явный алгоритм решения поставленной неформализованной задачи.

Авторы благодарны А.Н. Горбаню, Д.И. Назимовой, Л.Ф. Ноженковой за руководство работой.

Работа выполнена при финансовой поддержке Красноярского краевого фонда науки (гранты 6F0181, 7F0113), Министерства науки и технологий РФ (подпрограмма "Перспективные информационные технологии", проект № 05.04.1291) и ФЦП "ИНТЕГРАЦИЯ" (проект № 68, напр. 2.1.).

#### ЛИТЕРАТУРА

1. Бессолицина Е.П., Какарека С.В., Крауклис А.А., Кремер Л.К. Геосистемы контакта тайги и степи: юг Центральной Сибири. – Новосибирск: Наука, 1991. – 217 с.
2. Браверман Э.М., Мучник И.Б. Структурные методы обработки эмпирических данных. – М., Наука. Гл. ред. физ.-мат. лит., 1983. – 464с.
3. Вапник В.Н. Восстановление зависимостей по эмпирическим данным. – М.: Наука, 1979. – 448с.
4. Гилев С.Е., Коченов Д.А., Миркес Е.М., Россиев Д.А. Контрастирование, оценка значимости параметров, оптимизация их значений и их интерпретация в нейронных сетях // Доклады III Всероссийского семинара "Нейроинформатика и ее приложения". - Красноярск, 1995. - С.66-78.
5. Горбань А.Н. Обучение нейронных сетей. М.": изд. СССР-США СП "ParaGraph", 1990. - 160 с.
6. Горбань А.Н. Проблема скрытых параметров и задачи транспонированной регрессии // Нейроинформатика и ее приложения. Тезисы докладов V Всероссийского семинара. Красноярск: изд. КГТУ, 1997. – с.57-58.
7. Горбань А.Н., Миркес Е.М. Оценки и интерпретаторы ответа для сетей двойственного функционирования. Вычислительный центр СО РАН в г. Красноярске. Красноярск, 1997. - 24 с. (Рукопись деп. в ВИНТИ 25.07.97, № 2511-B97)
8. Горбань А.Н., Новоходько А.Ю., Царегородцев В.Г. Нейросетевая реализация транспонированной задачи линейной регрессии // Нейроинформатика и ее приложения. Тезисы докладов IV Всероссийского семинара, 5-7 октября 1996 г. Красноярск: изд. КГТУ, 1996. – с.37-39.
9. Горбань А.Н., Россиев Д.А. Нейронные сети на персональном компьютере. – Новосибирск: Наука (Сиб. отделение), 1996. – 276с.
10. Загоруйко Н.Г., Елкина В.Н., Лбов Г.С. Алгоритмы обнаружения эмпирических закономерностей. – Новосибирск: Наука, 1985. – 110с.
11. Кендалл М., Стьюарт А. Статистические выводы и связи. – М.: Наука, 1973. – 900с.
12. Кендалл М., Стьюарт А. Многомерный статистический анализ и временные ряды. – М.: Наука, 1976. – 736 с.
13. Ландшафты юга Восточной Сибири. Карта м-ба 1: 1 500 000 / Ред. В. Б. Сочава. – М.:ГУГК, 1977.
14. Лбов Г.С. Методы обработки разнотипных экспериментальных данных. – Новосибирск: Наука, 1981. – 157с.
15. Мильков Ф. Н. Лесостепной ландшафт и его зональное подразделение / Изв. АН СССР. Сер. геогр., № 5, 1951. С. 3-14.
16. Назимова Д.И., Молокова Н.И., Джансеитов К.К. Высотная поясность и климат в горах южной Сибири / География и природные ресурсы., № 2, 1981. С. 68-78.

17. Рао С.Р. Линейные статистические методы. – М.: Наука, 1968. – 548 с.
18. Царегородцев В.Г. Транспонированная регрессия в задаче интерполяции свойств химических элементов. // Вестник КГТУ. Информатика, вычислительная техника, управление. Сб. научных трудов / Красноярск: КГТУ. 1997. 139с. – с.31-36.
19. Gorban A.N., Novokhodko A.Yu. Neural Networks In Transposed Regression Problem, Proc. of the World Congress on Neural Networks, Sept. 15-18, 1996, San Diego, CA, Lawrence Erlbaum Associates, 1996, pp. 515-522.
20. Solomon A. M. and Cramer W. Biospheric Implications of Global Environmental Change / Repr. From Solomon et al. Vegetation Dynamics and Global Change. Chapman and hall, London, 1976. p. 25-51.
21. Tchebakova N.M., Mousured R.A., Leemans R. and Nazimova D.I. Possible Vegetation Shifts in Siberia under Climatic Change. / Impacts of Climate Change on Ecosystems, 1995. p. 67-83.
22. Tchebakova N.M., Mousured R.A. and Nazimova D.I. A Siberian Vegetation Model Based on Climatic Parameters / Can. J. For. Res. 24, 1994. p. 1597-1607.
23. Walter, Hand Box. Global Classification of Natural Terrestrial Ecosystem / Vegetatio. 32 (2), 1976. p. 75-81.
24. Кирдин А.Н., Новоходько А.Ю., Царегородцев В.Г. Глава 7. Скрытые параметры и транспонированная регрессия // Нейроинформатика / А.Н.Горбань, В.Л.Дунин-Барковский, А.Н.Кирдин, Е.М.Миркес и др. Новосибирск: Наука, 1998.
25. Миркес Е.М. Глава 9. Логически прозрачные нейронные сети и производство явных знаний из данных // Нейроинформатика / А.Н.Горбань, В.Л.Дунин-Барковский, А.Н.Кирдин, Е.М.Миркес и др. Новосибирск: Наука, 1998.
26. Горбань А.Н. Глава 1. Возможности нейронных сетей // Нейроинформатика / А.Н.Горбань, В.Л.Дунин-Барковский, А.Н.Кирдин, Е.М.Миркес и др. Новосибирск: Наука, 1998.
27. Горбань А.Н. Глава 2. Решение задач нейронными сетями // Нейроинформатика / А.Н.Горбань, В.Л.Дунин-Барковский, А.Н.Кирдин, Е.М.Миркес и др. Новосибирск: Наука, 1998.
28. Горбань А.Н. Глава 3. Быстрое дифференцирование, двойственность и обратное распространение ошибки // Нейроинформатика / А.Н.Горбань, В.Л.Дунин-Барковский, А.Н.Кирдин, Е.М.Миркес и др. Новосибирск: Наука, 1998.