Лекция 9
Тема: Понятие нейронных сетей. Основные определения.

Биологический прототип

Развитие *искусственных нейронных сетей* вдохновляется биологией. То есть, рассматривая сетевые конфигурации и алгоритмы, исследователи применяют термины, заимствованные из принципов организации мозговой деятельности. Но на этом *аналогия* заканчивается. Наши знания о работе мозга столь ограничены, что мало бы нашлось точно доказанных закономерностей для тех, кто пожелал бы руководствоваться ими. Поэтому разработчикам сетей приходится выходить за пределы современных биологических знаний в поисках структур, способных выполнять полезные функции. Во многих случаях это приводит к необходимости отказа от биологического правдоподобия, мозг становится просто метафорой, и создаются сети, невозможные в живой материи или требующие неправдоподобно больших допущений об анатомии и функционировании мозга.

Несмотря на то, что *связь* с биологией слаба и зачастую несущественна, *искусственные нейронные сети* продолжают сравнивать с мозгом. Их функционирование часто имеет внешнее сходство с человеческим познанием, поэтому трудно избежать этой аналогии. К сожалению, такие сравнения неплодотворны и создают неоправданные ожидания, неизбежно ведущие к разочарованию.

Нервная система человека, построенная из элементов, называемых ***нейронами***, имеет ошеломляющую сложность. Около 10^{11} *нейронов* участвуют в примерно 10^{15} передающих связях, имеющих длину метр и более. Каждый *нейрон* обладает многими свойствами, общими с другими органами тела, но ему присущи абсолютно уникальные способности: принимать, обрабатывать и передавать электрохимические сигналы *по* нервным путям, которые образуют коммуникационную систему мозга.

На рис. 1 показана структура пары типичных биологических *нейронов*. Дендриты идут от тела нервной клетки к другим *нейронам,* где они принимают сигналы в точках соединения, называемых *синапсами*. Принятые *синапсом* входные сигналы передаются к телу *нейрона*. Здесь они суммируются, причем одни входы стремятся возбудить *нейрон,* другие — воспрепятствовать его возбуждению.

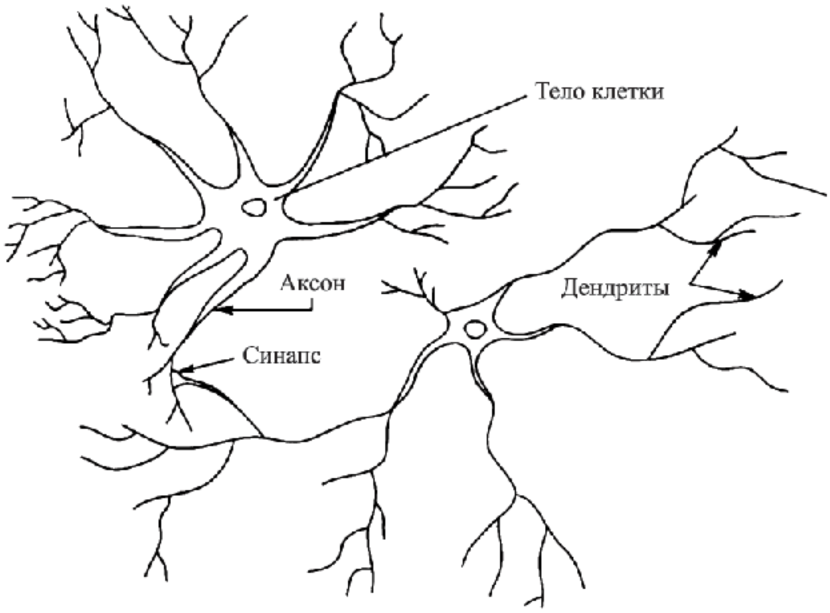

Рис. 1.

Когда суммарное возбуждение в теле *нейрона* превышает некоторый порог, *нейрон* возбуждается, посылая *по аксону* сигнал другим *нейронам*. У этой основной *функциональной схемы* много усложнений и исключений, тем не менее, большинство *искусственных нейронных сетей* моделируют лишь эти простые свойства.

Искусственный нейрон

Искусственный *нейрон* имитирует в первом приближении свойства биологического *нейрона*. На вход искусственного *нейрона* поступает некоторое множество сигналов, каждый из которых является выходом другого *нейрона*. Каждый вход умножается на соответствующий *вес*, аналогичный синаптической силе, и все произведения суммируются, определяя уровень активации *нейрона*.

На рис. 2 представлена модель, реализующая эту идею. Множество входных сигналов, обозначенных $x_1, x_2, \ldots, x_n$, поступает на искусственный *нейрон*. Эти входные сигналы, в совокупности обозначаемые вектором X, соответствуют сигналам, приходящим в *синапсы* биологического *нейрона*. Каждый сигнал умножается на соответствующий *вес* $w_1, w_2, \ldots, w_n$, и поступает на суммирующий блок, обозначенный Σ. Каждый *вес* соответствует "силе" одной биологической синаптической связи. (Множество весов в совокупности обозначается вектором W.) Суммирующий блок, соответствующий телу биологического элемента, складывает взвешенные входы алгебраически, создавая *выход*, который мы будем называть NET. В векторных обозначениях это может быть компактно записано следующим образом:

$$NET = XW.$$

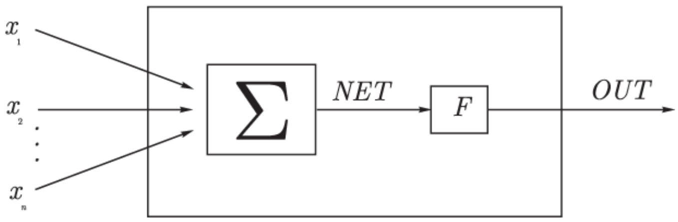

Рис. 2.

Сигнал NET далее, как правило, преобразуется активационной функцией F и дает *выходной нейронный* сигнал OUT. Активационная *функция* может быть обычной *линейной функцией*

$$OUT = F(NET),$$

где F — константа, пороговой функцией

$$OUT = \begin{cases} 1, & \text{если } NET > T; \\ 0, & \text{если } NET \leqslant T \end{cases}$$

где T — некоторая постоянная пороговая величина, или же *функция,* более точно моделирующая нелинейную передаточную характеристику биологического *нейрона* и предоставляющей **нейронной сети** большие возможности.

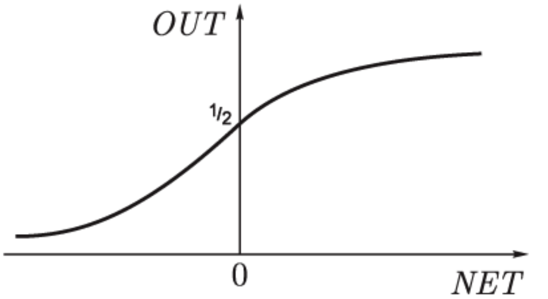

Рис. 3.

На рис.2 блок, обозначенный F, принимает сигнал NET и выдает сигнал OUT. Если блок F сужает *диапазон* изменения величины NET так, что при любых значениях NET значения OUT принадлежат некоторому конечному интервалу, то F называется **"сжимающей" функцией**. В качестве "сжимающей" функции часто используется логистическая или "сигмоидальная" (S-образная) *функция*, показанная на рис.3. Эта *функция* математически выражается как $F(x) = 1/(1 + e^{-x})$. Таким образом,

$$OUT = \frac{1}{1 + e^{-NET}}.$$

По аналогии с электронными системами активационную функцию можно считать нелинейной усилительной характеристикой искусственного *нейрона*. Коэффициент усиления вычисляется как *отношение* приращения величины OUT к вызвавшему его небольшому приращению величины NET. Он выражается наклоном кривой при определенном уровне возбуждения и изменяется от малых значений при больших отрицательных возбуждениях (кривая почти горизонтальна) до максимального значения при нулевом возбуждении и снова уменьшается, когда возбуждение становится большим положительным. С. Гроссберг (1973) обнаружил, что подобная нелинейная характеристика решает поставленную им дилемму шумового насыщения. Каким образом одна и та же *сеть* может обрабатывать как слабые, так и сильные сигналы? Слабые сигналы нуждаются в большом сетевом усилении, чтобы дать пригодный к использованию выходной сигнал. Однако усилительные каскады с большими коэффициентами усиления могут привести к насыщению выхода шумами усилителей (случайными флуктуациями), которые присутствуют в любой физически реализованной сети. Сильные входные сигналы, в свою *очередь*, также будут приводить к насыщению усилительных каскадов, исключая возможность полезного использования выхода. Центральная область логистической функции, имеющая большой коэффициент усиления, решает проблему обработки слабых сигналов, в то время как области с падающим усилением на положительном и отрицательном концах подходят для больших возбуждений. Таким образом, *нейрон* функционирует с большим усилением в широком диапазоне уровня входного сигнала

$$OUT = \frac{1}{1 + e^{-NET}} = F(NET).$$

Другой широко используемой *активационной функцией* является гиперболический тангенс. *По* форме она сходна с логистической функцией и часто используется биологами в качестве математической модели активации нервной клетки. В качестве активационной функции *искусственной нейронной сети* она записывается следующим образом:

$$OUT = \mathrm{th}(x).$$

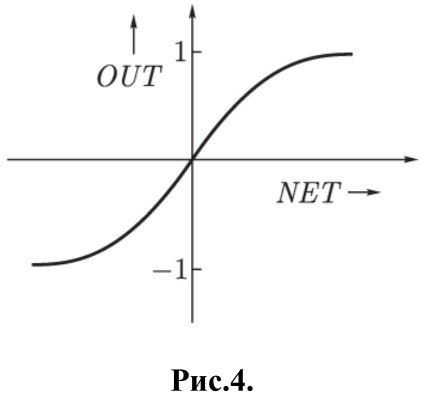

Рис.4.

Подобно логистической функции гиперболический тангенс является S-образной функцией, но он симметричен относительно начала координат, и в точке $NET = 0$

значение выходного сигнала OUT равно нулю (см. рис. 4). В отличие от логистической функции, гиперболический тангенс принимает значения различных знаков, и это его свойство применяется для целого ряда сетей.

Рассмотренная простая модель искусственного *нейрона* игнорирует многие свойства своего биологического двойника. Например, она не принимает во внимание задержки во времени, которые воздействуют на динамику системы. Входные сигналы сразу же порождают выходной сигнал. И, что более важно, она не учитывает воздействий функции частотной *модуляции* или синхронизирующей функции биологического *нейрона,* которые ряд исследователей считают решающими в нервной деятельности естественного мозга.

Несмотря на эти ограничения, сети, построенные из таких *нейронов,* обнаруживают свойства, сильно напоминающие биологическую систему. Только время и исследования смогут ответить на вопрос, являются ли подобные совпадения случайными или же они есть следствие того, что в модели верно схвачены важнейшие черты биологического *нейрона*.

Однослойные искусственные нейронные сети

Хотя один *нейрон* и способен выполнять простейшие процедуры распознавания, но для серьезных нейронных вычислений необходимо соединять *нейроны* в сети. Простейшая *сеть* состоит из группы *нейронов,* образующих слой, как показано в правой части рис. 5. Отметим, что вершины-круги слева служат лишь для распределения входных сигналов. Они не выполняют каких-либо вычислений и поэтому не будут считаться слоем. Для большей наглядности обозначим их кругами, чтобы отличать их от вычисляющих *нейронов,* обозначенных квадратами. Каждый элемент из *множества* входов X отдельным весом соединен с каждым искусственным *нейроном*. А каждый *нейрон* выдает взвешенную сумму входов в *сеть*. В *искусственных* и биологических сетях многие соединения могут отсутствовать, но здесь они показаны все для демонстрации общей картины. Могут существовать также соединения между выходами и входами элементов в слое.

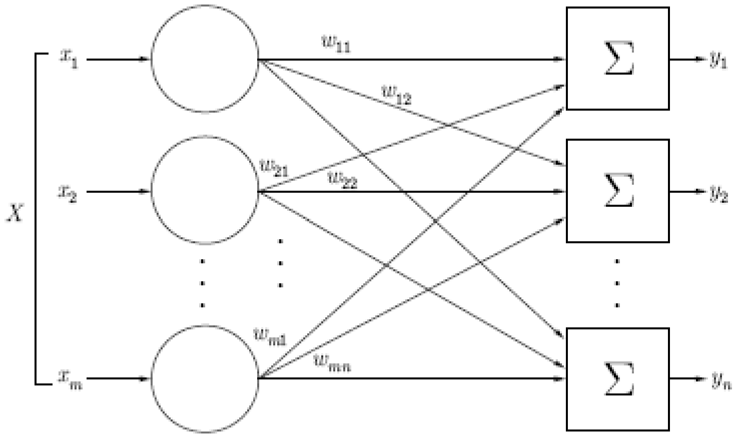

Рис. 5.

Удобно считать веса элементами матрицы W. *Матрица* имеет m строк и n столбцов, где m — число входов, а n — число *нейронов*. Например, $w_{2,3}$ — это *вес,* связывающий второй вход с третьим *нейроном*. Таким образом, *вычисление* выходного вектора N, компонентами которого являются выходы OUT *нейронов,* сводится к матричному умножению $N = XW$, где N и X — векторы-строки.

Многослойные искусственные нейронные сети

Более крупные и сложные нейронные сети обладают, как правило, и большими вычислительными возможностями. Хотя созданы сети всех конфигураций, какие только можно себе представить, послойная организация *нейронов* копирует слоистые структуры определенных отделов мозга. Оказалось, что такие *многослойные сети* обладают большими возможностями, чем *однослойные,* и в последние годы были разработаны алгоритмы для их обучения. *Многослойные сети* могут строиться из каскадов слоев. *Выход* одного слоя является входом для последующего слоя. Подобная *сеть* показана на рис.6 и снова изображена со всеми соединениями. *Многослойные сети* не могут привести к увеличению вычислительной мощности *по* сравнению с *однослойной сетью,* если *активационная функция* между слоями линейна. *Вычисление* выхода слоя заключается в умножении входного вектора на первую весовую матрицу с последующим умножением (если отсутствует нелинейная активационная *функция*) результирующего вектора на вторую весовую матрицу

$$OUT = (XW_1)W_2.$$

Так как *умножение матриц* ассоциативно, то $(XW_1)W_2 = X(W_1W_2).$

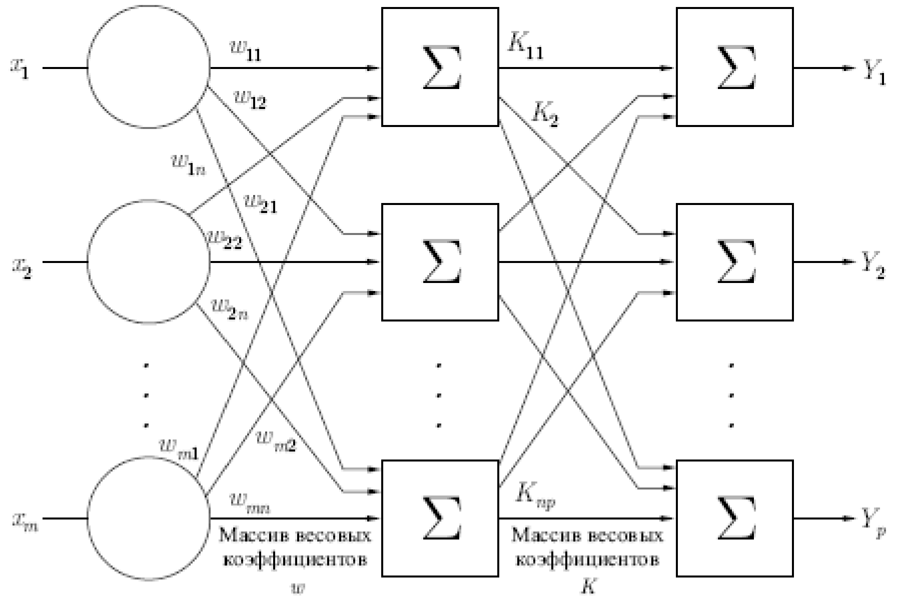

Рис. 6.

Это показывает, что двухслойная линейная *сеть* эквивалентна одному слою с весовой матрицей, равной произведению двух весовых матриц. Следовательно, любая многослойная линейная *сеть* может быть заменена эквивалентной однослойной сетью. Однако *однослойные сети* весьма ограничены *по* своим вычислительным возможностям. Таким образом, для расширения возможностей сетей *по* сравнению с *однослойной сетью* необходима нелинейная *активационная функция*.

У сетей, рассмотренных до сих пор, не было обратных связей, т. е. соединений, идущих от выходов некоторого слоя к входам этого же слоя или предшествующих слоев. Этот специальный *класс сетей,* называемых **сетями без обратных связей** или **сетями прямого распространения**, представляет большой интерес и широко используется. Сети более общего вида, имеющие соединения от выходов к входам, называются **сетями с обратными связями**. У *сетей без обратных связей* нет памяти, их *выход* полностью определяется текущими входами и значениями весов. В некоторых конфигурациях сетей с обратными связями предыдущие значения выходов возвращаются на входы; *выход*, следовательно, определяется как текущим входом, так и предыдущими выходами. Поэтому сети с обратными связями могут обладать свойствами, сходными с кратковременной человеческой памятью, где сетевые выходы тоже частично зависят от предыдущих входов.

К сожалению, нет общепринятого способа подсчета числа слоев в сети. *Многослойная сеть* состоит, как показано на рис. 6, из чередующихся множеств *нейронов* и весов. Ранее, в связи с рис. 5, уже говорилось, что *входной слой* не выполняет суммирования. Эти *нейроны* служат лишь в качестве разветвлений для первого *множества* весов и не влияют на вычислительные возможности сети. *По* этой причине первый слой не принимается во внимание при подсчете слоев, и *сеть*, подобная изображенной на рисунке 6, считается двуслойной, так как только два слоя выполняют вычисления. Далее, веса слоя считаются связанными со следующими за ними *нейронами*. Следовательно, слой состоит из *множества* весов со следующими за ними *нейронами*, суммирующими взвешенные сигналы.

Обучение искусственных нейронных сетей

Среди всех интересных свойств *искусственных нейронных сетей* ни одно не захватывает так воображения, как их способность к обучению. Их обучение до такой степени напоминает процесс интеллектуального развития человеческой *личности*, что может показаться, будто нами достигнуто глубокое понимание этого процесса. Но, проявляя осторожность, следует сдерживать эйфорию. Возможности обучения *искусственных нейронных сетей* ограничены, и нужно решить много сложных задач, чтобы определить, находимся ли мы на правильном пути.

Цель обучения

Сеть обучается, чтобы для некоторого *множества* входов давать желаемое (или, *по* крайней мере, сообразное с ним) множество выходов. Каждое такое входное (или выходное) множество рассматривается как *вектор*. Обучение осуществляется путем последовательного предъявления входных векторов с одновременной подстройкой весов в соответствии с определенной процедурой. В процессе обучения веса сети постепенно становятся такими, чтобы каждый *входной вектор* вырабатывал выходной *вектор*.

Обучение с учителем

Различают алгоритмы *обучения с учителем* и *без учителя*. ***Обучение с учителем*** предполагает, что для каждого входного вектора существует целевой *вектор*, представляющий собой требуемый *выход*. Вместе они называются обучающей парой. Обычно *сеть* обучается на некотором числе таких обучающих пар. Предъявляется выходной *вектор*, вычисляется *выход* сети и сравнивается с соответствующим целевым вектором, *разность* (ошибка) с помощью обратной связи подается в *сеть*, и веса изменяются в соответствии с алгоритмом, стремящимся минимизировать ошибку. Векторы обучающего *множества* предъявляются последовательно, ошибки вычисляются и веса подстраиваются для каждого вектора до тех пор, пока ошибка *по* всему обучающему массиву не достигнет приемлемо низкого уровня.

Обучение без учителя

Несмотря на многочисленные прикладные достижения, *обучение с учителем* критиковалось за свою биологическую неправдоподобность. Трудно вообразить обучающий механизм в мозге, который бы сравнивал желаемые и действительные значения выходов, выполняя коррекцию с помощью обратной связи. ***Обучение без учителя*** является намного более правдоподобной моделью обучения для биологической системы. Развитая Кохоненом и многими другими, она не нуждается в целевом векторе для выходов и, следовательно, не требует сравнения с предопределенными идеальными ответами. Обучающее множество состоит лишь из входных векторов. Обучающий *алгоритм* подстраивает веса сети так, чтобы получались согласованные выходные векторы, т. е. чтобы предъявление достаточно близких входных векторов давало одинаковые выходы. Процесс обучения, следовательно, выделяет статистические свойства обучающего *множества* и группирует сходные векторы в классы. Предъявление на вход вектора из данного класса даст определенный выходной *вектор*, но до обучения невозможно предсказать, какой *выход* будет производиться данным классом входных векторов. Следовательно, выходы подобной сети должны трансформироваться в некоторую понятную форму, обусловленную процессом обучения. Это не является серьезной проблемой. Обычно не сложно идентифицировать *связь* между входом и выходом, установленную сетью.

Алгоритмы обучения

Большинство современных алгоритмов обучения выросло из концепций Д.О. Хэбба. Он предложил модель *обучения без учителя*, в которой синаптическая сила (*вес*) возрастает, если активированы оба *нейрона*, источник и приемник. Таким образом, часто используемые пути в сети усиливаются и феномены привычки и обучения через повторение получают объяснение.

В *искусственной нейронной сети*, использующей обучение *по* Хэббу, наращивание весов определяется произведением уровней возбуждения передающего и принимающего *нейронов*. Это можно записать как

$$w_{ij}(n+1) = w(n) + \alpha OUT_i OUT_j,$$

где $w_{ij}(n)$ — *значение* веса от *нейрона* i к *нейрону* j до подстройки, $w_{ij}(n+1)$ — *значение* веса от *нейрона* i к *нейрону* j после подстройки, α — коэффициент скорости обучения, OUT_i — *выход нейрона* i и вход *нейрона* j, OUT_j — *выход нейрона* j.

Сети, использующие обучение *по* Хэббу, конструктивно развивались, однако за последние 20 лет появились и разрабатывались более эффективные алгоритмы обучения. В частности, были развиты алгоритмы *обучения с учителем*, приводящие к сетям с более широким диапазоном характеристик обучающих входных образов и большими скоростями обучения, чем использующие простое обучение *по* Хэббу.