

DOI:

НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ В ЭКОНОМИКЕ И ФИНАНСАХ

Иванюк В.А.

Финансовый университет при Правительстве РФ Россия, г. Москва,

ул. Ленинградский проспект, 49

VAIvanyuk@fa.ru

Аннотация: В докладе описываются популярные методы машинного обучения и области применения нейронных сетей. Раскрываются методы обучения нейронных сетей. Предлагается методика прогнозирования на основе нейронных сетей для моделирования финансовых временных рядов.

Ключевые слова: временные ряды, тренд, нейронный прогноз

Введение

Нейронные сети в последнее время набирают все большую популярность среди исследователей. В частности, нейронные сети нашли широкое применение в сфере визуализации, распознавания образов. Но на этом практическая значимость нейронных сетей не заканчивается, они также находят свое применение в задачах прогнозирования, классификации, кластеризации и моделирования. Главным образом, такой успех можно объяснить замечательным свойством моделей, основанных на нейронных сетях – они могут «видеть» нелинейные связи в отличие от многих моделей, которые в большинстве своем имеют линейные связи.

В настоящее время применение нейронных сетей развивается в следующих направлениях:

1. Биржевое и макроэкономическое прогнозирование (Neuro XL, OptimuStock, StocksNeural)
2. Распознавание речи и диалог с человеком (Siri, Alexa, Cortana, Алиса)
3. Имитация интеллектуальной деятельности (слабый ИИ в Siri, Alexa, Cortana, Алиса)
4. Улучшение некачественной и зашумлённой информации (DeepImagePrior)

1 Искусственные нейронные сети

Искусственные нейронные сети - это популярные методы машинного обучения, имитирующие механизм обучения биологических организмов. Нервная система человека содержит клетки, которые называются нейронами. Любая нейронная сеть, по сути, представляет собой совокупность нейронов и связей между ними. Нейрон - это функция с множеством входов и одним выходом. Его задача состоит в том, чтобы взять все значения со своего входа, выполнить на них операции и отправить результат на выход, используя веса в качестве промежуточных параметров. Эта последовательность операций, применяемых к матрице входных данных, обычно представляет собой наборы сложений и умножений, за которыми следуют нелинейные функции.

Искусственная нейронная сеть вычисляет функцию входных данных путем распространения вычисленных значений от входных нейронов к выходным нейронам и использования весов в качестве промежуточных параметров. Обучение происходит путем изменения веса, соединяющего нейроны. Точно так же, как внешние стимулы необходимы для обучения в биологических организмах, внешний стимул в искусственных нейронных сетях обеспечивается обучающими данными, содержащими примеры пар вход-выход изучаемой функции. Например, обучающие данные могут содержать пиксельные представления изображений (входные данные) и их маркировки в качестве выходных данных. Эти пары обучающих данных поступают в нейронную сеть с помощью входных представлений для получения прогнозов относительно выходных меток. Обучающие данные обеспечивают обратную связь о корректности весов в нейронной сети в зависимости от того, насколько хорошо предсказанный выход для конкретного входа соответствует обучающей выходной метке в тренировочных данных. Ошибки, допущенные нейросетью при вычислении функции, можно рассматривать как своего рода неприятную обратную связь в биологическом организме, приводящую к корректировке силы синапса. Аналогичным образом в нейронной сети в ответ на ошибки предсказания корректируются веса между нейронами. Целью изменения весов является модификация вычисленной функции для того, чтобы сделать предсказания более корректными в последующих итерациях. Поэтому веса тщательно изменяются математически обоснованным образом, чтобы уменьшить ошибку в вычислениях. Последовательно изменяя веса между нейронами по многим входным и выходным данным, функция, вычисленная нейросетью, совершенствуется во времени, чтобы обеспечить более точные предсказания. Поэтому, если нейронная сеть обучается множеству различных образов, то в конечном итоге она сможет правильно распознать их по изображению,

которого раньше не видела. Эта способность точно вычислять функции невидимых входов путем обучения на конечном наборе пар вход-выход, называется обобщением модели. Основная польза всех моделей машинного обучения заключается в их способности обобщать свое обучение от виденных ранее тренировочных данных до невидимых примеров.

Самые базовые элементы вычислений в нейронной сети вдохновлены традиционными алгоритмами машинного обучения, такими как метод наименьших квадратов и логистическая регрессия. Нейронные сети получают свое преимущество за счет объединения многих таких базовых блоков, а также совместного изучения веса различных блоков, чтобы свести к минимуму ошибку прогнозирования. С этой точки зрения нейронную сеть можно рассматривать как вычислительный граф элементарных единиц, в котором большая мощность достигается за счет соединения их определенными способами. Когда нейронная сеть используется в своей самой базовой форме, не соединяя вместе несколько блоков, алгоритмы обучения часто сводятся к классическим моделям машинного обучения. Реальная ценность нейронной модели перед классическими методами раскрывается при объединении этих элементарных вычислительных единиц, а веса элементарных моделей обучаются с использованием их зависимостей друг от друга. Комбинируя несколько блоков, можно увеличить мощность модели для изучения более сложных функций данных, по сравнению с теми, которые присущи классическим моделям машинного обучения. Способ комбинирования этих блоков также играет роль в мощности архитектуры и требует некоторого осмысления и понимания со стороны аналитика. Кроме того, для изучения большого количества весов в этих расширенных вычислительных графах также требуется достаточное количество обучающих данных.

Глубокое обучение становится более привлекательным, чем обычные методы, в первую очередь, при наличии достаточного количества данных/вычислительной мощности. В последние годы наблюдается увеличение доступности данных и вычислительной мощности, что привело к сильному интересу в глубоком обучении.

2 Методы обучения нейронных сетей

Нейронная сеть — это математическая модель, состоящая из набора связанных между собой элементов, аналогичных нейронам головного мозга.




Рис. 1. Нейронная сеть

С математической точки зрения, нейронной сетью называют множественную суперпозицию многочлена сигма-подобных функций.

$$(1) \quad F = k_0 \zeta \left(k_1 \zeta \left(\sum_{i=1}^{m} k_2 \zeta \left(\sum_{j=i}^{n} k_3 \zeta (k_4 x_{ij}) \right) \right) \right) + k_5 \zeta \left(\sum_{i=1}^{m} k_6 \zeta \left(\sum_{j=i}^{n} k_7 \zeta (k_8 x_{ij}) \right) \right) + \dots$$

Особенный характер функции нейронной сети придают входные и выходные коэффициенты нейронов, обуславливающие как тип зависимости (входные), так и силу влияния нейрона (выходные) на другие нейроны сети. Подбор этих коэффициентов называется обучением нейронной сети.

Существует три типа обучения:

Стохастический метод (обучение по Кохонену) предполагает перебор случайных значений коэффициентов до тех пор, пока функция нейронной сети не начнет удовлетворительно отображать искомую зависимость. Недостаток этого метода – низкая скорость обучения сети.

Градиентный метод (обратное распространение ошибки) предполагает изменение коэффициентов сети на вычисляемую через производные величину градиента ошибки сигма-функции, таким образом, чтобы минимизировать ошибку. Недостаток метода – невозможность поиска альтернативных решений при достижении минимума ошибки в тех случаях, когда минимум функции не глобальный. Эту особенность называют западанием в локальный минимум.

Смешанные методы сочетают в себе одновременное использование как стохастической, так и градиентной составляющей обучения. Примером такого сочетания может служить эволюционный алгоритм, применяемый в модуле поиска решения MS EXCEL.

3 Нейросетевое моделирование в экономике и финансах

Рассмотрим построение автокорреляционного нейронного прогноза одним нейроном для курса доллара США. Предположим, что завтрашний курс доллара зависит от пяти предыдущих значений. Построим временной ряд со сдвигом в 1 день и оценим автокорреляцию (рис. 2).

A	B	C	D	E	F
Дата	Данные	Предыдущее	Корреляция	Коэффициенты	
01.12.2014	52.2525		0.980195541	Вход 1	0.000000
02.12.2014	53	52.2525		Вход 2	0.000000
03.12.2014	53.337	53		Вход 3	0.000000
04.12.2014	53.9	53.337		Вход 4	0.000000
05.12.2014	53.81	53.9		Вход 5	1.000000
08.12.2014	53.42	53.81		Выход	80.000000

Высокий коэффициент корреляции - значит можно использовать сеть из одного нейрона

Рис. 2. Автокорреляция

Зададим начальные значения коэффициентов и создадим формулу нейронной сети (рис.3).

B	C	D	E	F	G
Данные	Предыдущее	Корреляция	Коэффициенты		Ошибки
52.2525		0.980195541	Вход 1	0.000000	100865.8
53	52.2525		Вход 2	0.000000	
53.337	53		Вход 3	0.000000	
53.9	53.337		Вход 4	0.000000	
53.81	53.9		Вход 5	1.000000	Результат
53.42	53.81		Выход	80.000000	80
54.1595	53.42		Границы		80
54.434	54.1595		Входы		80
55.57	54.434		Верх	0.03581	80
57.48	55.57		Низ	-0.03581	80
60.5015	57.48		Выход		80
72.5	60.5015		Верх	50	80
64.9	72.5		Низ	49	80
60.45	64.9				80
59.2	60.45				80
54.54	59.2				80

Рис. 3. Формула нейронной сети

Рассчитаем ошибку сети, как сумму квадратов отклонений. Продолжим формулу нейронной сети на одно значение вперед, сформируем данные прогноза, как результат сети с учётом среднеквадратичного отклонения. Зададим ограничения коэффициентов нейронной сети и проведём их подбор эволюционным алгоритмом, используя как оптимизирующий критерий уменьшение ошибки.

Получим прогноз и оценим его качество, построив график.

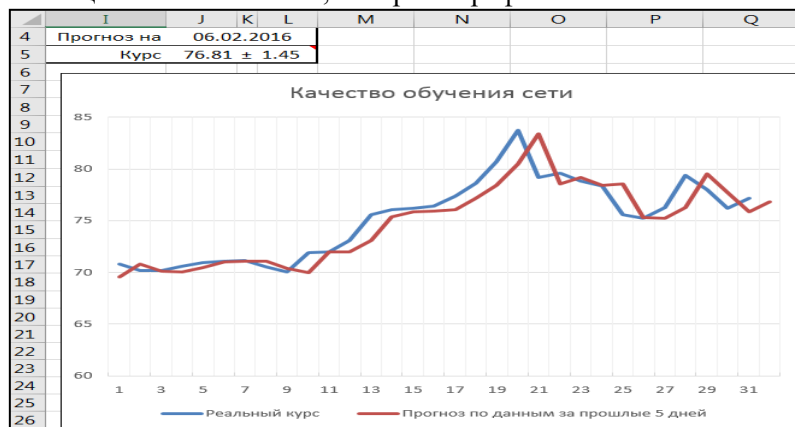


Рис. 4. Прогноз на основе нейронной сети

4 Глубокие нейронные сети

Сети с большим количеством нейронов (сотни тысяч), скрытых слоёв (десятки и сотни) и сложной, обычно специализированной, архитектурой называют глубокими. Обучение таких сетей требует значительного времени и большого количества как эталонных, так и ошибочных образцов решений. Однако, результативность таких сетей весьма значима, что позволяет использовать их в серьёзных научных и коммерческих проектах.

Специализированные алгоритмы глубокого обучения представляют из себя те или иные модификации смешанного метода, ориентированные на параллельное исполнение на большом количестве нейронов или группе нейронных сетей. Для обучения и работы этого типа нейронных сетей используют нейронные процессоры (Neural Processing Unit, NPU) – специализированное оборудование, ориентированное исключительно на задачу математического моделирования нейронных сетей.

Наиболее известные коммерческие нейропроцессоры:

NVIDIA DGX-2 – 8.2×10^4 нейронов, 1.28×10^9 коэффициентов, 2×10^{15} FLOPS, габариты: $52 \times 26 \times 64$ см, энергопотребление: 103 Вт, цена: \$ 400 000. Готовый вычислительный комплекс для обучения сетей.

IBM TrueNorth – Одновременная обработка: 106 нейронов, 2.56×10^8 коэффициентов, 4.5×10^{12} FLOPS, габариты: $2 \times 2 \times 1$ см, энергопотребление: 0.1 Вт, цена: \$ 8 000. Готовые нейронные серверы под заказ.

Nvidia Tesla M4 – Одновременная обработка: 1024 нейронов, 2048 коэффициентов, 2.2×10^{12} FLOPS, габариты: $17 \times 8 \times 5$ см, энергопотребление: 75 Вт, цена: \$ 1 900. Для настольных компьютеров.

Apple A12 Bionic – Одновременная обработка: 8 нейронов, 16 коэффициентов, 5×10^{12} FLOPS, габариты: $3 \times 3 \times 0.5$ см, энергопотребление: 6 Вт, цена: \$ 300. Нейронный модуль в чипе iPhone XS.

Выводы

К достоинствам использования нейронных сетей можно отнести:

- Универсальность. Нейронные сети не зависят от свойств входных данных, для них не существует требования к определенному типу распределения исходных данных (во многих моделях присутствует предположение о нормальности распределения исходных данных, в нейросетевых моделях такое предположение не требуется). А также нет требования к линейности целевых функций - это главное преимущество нейронных сетей - они могут "видеть" нелинейные связи, в отличие от большинства стандартных моделей, которые основаны на линейных связях
- Простота. Использование нейронной сети не требует специальной подготовки, для практического применения. Нет необходимости глубоко вникать во внутренние механизмы работы сети, в отличие от статистических методов, требующих фундаментальных знаний из области теории вероятностей и математической статистики.
- Нейронные сети способны моделировать зависимости в случае большого числа переменных.
- Помимо положительных сторон у нейросетевых моделей есть существенные недостатки:
- Сложность построения архитектуры сети для конкретной задачи. Для подавляющего большинства реальных задач не разработано стандартных схем, в результате в каждом случае конструирование приходится начинать "с нуля".
- Сложность интерпретации результатов обучения. В нейронной сети происходит множество нелинейных преобразований, причем, чем больше слоев у нейронной сети, тем сложнее интерпретировать эти преобразования.

Литература

1. *Иванюк В.А., Абдикеев Н.М., Пащенко Ф.Ф.* Нейросетевая модель многофакторного анализа экономической эффективности предприятия // Датчики и системы. 2019. № 10 (240). С. 9-17.
2. *Иванюк В.А.* Введение в нейронные сети на примере прогнозирования финансовых временных рядов // Самоуправление. 2019. Т. 2. № 3 (116). С. 129-133.
3. *Иванюк В.А.* Модели и методы прогнозирования финансовых временных рядов на примере курса USD/RUB // Мягкие измерения и вычисления. 2019. № 6 (19). С. 38-41.
4. *Плеханов П. А.* Применение искусственных нейронных сетей для нахождения взаимосвязей в экономике //Современные тенденции в экономике и управлении: новый взгляд. – 2014. – №. 26. – С. 130-133.