

АЛГОРИТМ РЕГУЛИРОВАНИЯ ЦЕНЫ В УСЛОВИЯХ НЕОПРЕДЕЛЕННОСТИ

Папкович А. С.

Кафедра информационных технологий автоматизированных систем,
Белорусский государственный университет информатики и радиоэлектроники
Минск, Республика Беларусь
E-mail: pasalex94@gmail.com

Рассматривается алгоритм регулирования цены в условиях неопределенности. Алгоритм состоит из алгоритма принятия решений в условиях неопределенности и нейросети обученной на поиск и анализ необходимой информации.

Ключевые слова: Алгоритм принятия решений, неопределенность, нейросеть, регулирование цены

ВВЕДЕНИЕ

Для прогнозирования и регулирования цен на продукт предлагается использовать алгоритм регулирования цены в условиях неопределенности, работа которого основана на алгоритме принятия решений в условиях неопределенности, а так же использует нейросеть направленную на анализ новостей и других источников информации. Алгоритм позволит скорректировать цену на прогнозируемый период, на основе графиков предыдущих цен и анализа новостей связанных с этим продуктом.

I. АКТУАЛЬНОСТЬ

Современная экономика диктует участникам торгово-экономических отношений определенные правила взаимодействий. Одним из таких правил является своевременное регулирование цен на товар. Итоговая цена кроме себестоимости так же включает и наценку.

Наценка это часть стоимости продукта, которая составляет разницу между конечной ценой товара и его себестоимостью.

Факторы определения наценки:

- Налогообложение;
- расходы, связанные с реализацией;
- спрос;
- ситуация на рынке.

Если налогообложение и расходы это преимущественно статическая информация, то спрос и ситуация на рынке всегда динамичны.

Данный алгоритм на основе имеющейся информации позволит скорректировать цену следующего периода на анализе информации предыдущих периодов (новости, цены и спрос предыдущих периодов и т.д.).

II. ПРИМЕНЕНИЕ НЕЙРОСЕТИ В ЗАДАЧАХ ПРОГНОЗИРОВАНИЯ

Нейросети и инвестиционная деятельность

Нейронные сети привлекательны с интуитивной точки зрения, ибо они основаны на примитивной биологической модели нервных систем. В будущем развитие таких нейробиологи-

ческих моделей может привести к созданию действительно мыслящих компьютеров.

Предсказание финансовых временных рядов - необходимый элемент любой инвестиционной деятельности. Сама идея инвестиций - вложение денег сейчас с целью получения дохода в будущем - основывается на идее прогнозирования будущего. Соответственно, предсказание финансовых временных рядов лежит в основе деятельности всей индустрии инвестиций - всех бирж и небиржевых систем торговли цennыми бумагами.

Известно, что 99% всех сделок - спекулятивные, т.е. направлены не на обслуживание реального товарооборота, а заключены с целью извлечения прибыли. Все они основаны на предсказаниях изменения курса участниками сделки. Причем предсказания участников каждой сделки противоположны друг другу. Так что объем спекулятивных операций характеризует степень различий в предсказаниях участников рынка, т.е. степень непредсказуемости финансовых временных рядов.

Нейросетевое моделирование в чистом виде базируется лишь на данных, не привлекая никаких априорных соображений. В этом заключается его преимущество и одновременно – его недостаток. Имеющихся данных может не хватить для обучения, размерность потенциальных входов может оказаться слишком велика.

Применение нейронных сетей в задачах прогнозирования

Задачи прогнозирования особенно важны для практики, в частности, для финансовых приложений, поэтому следует рассмотреть способы применения нейронных сетей в этой области более подробно.

Рассмотрим практическую задачу, ответ в которой неочевиден - задачу прогнозирования курса драгоценных металлов на 1 день вперед.

Пусть имеется база данных, содержащая значения курса за последние 628 дней. Необходимо построить прогноз завтрашней цены на основе курсов за последние несколько дней. Прогнозирующая нейронная сеть должна иметь всего

один выход и столько входов, сколько предыдущих значений будет использоваться для прогноза.

Возникает вопрос, прогнозировать абсолютные или относительные значения? В качестве входов и выходов нейросети не следует выбирать сами значения котировок. Действительно значимыми для предсказаний являются изменения котировок. Поскольку эти изменения, как правило, гораздо меньше по амплитуде, чем сами котировки, между последовательными значениями курсов имеется большая корреляция – наиболее вероятное значение курса в следующий момент равно его предыдущему значению. Между тем, для повышения качества обучения следует стремиться к статистической независимости входов, т.е. к отсутствию подобных корреляций.

Поэтому в качестве входных переменных следует выбирать наиболее статистически независимые величины, например, изменения котировок или логарифм относительного приращения. Последний выбор хорош для длительных временных рядов, когда уже заметно влияние инфляции. В этом случае простые разности в разных частях будут иметь различную амплитуду, т.к. фактически измеряются в различных единицах. Напротив, отношения последовательных котировок не зависят от единиц измерения и будут одного масштаба несмотря на инфляционное изменение единиц измерения. В итоге, большая стационарность ряда позволит использовать большую историю и обеспечит лучшее обучение.

Входные данные

Вторым и наиболее важным этапом является определение состава входов. Распространенной ошибкой является то, что на вход подается большое количество разнообразной и часто ненужной информации и считается, что нейросеть сама выберет важные показатели.

Действительно, нейросеть умеет отсеивать незначимые входы, но каждый «лишний» вход утяжеляет сеть, затрудняет обучение, а главное – снижает качество прогноза. При большом числе «лишних» входов нейросеть чаще всего делает прогноз по предшествующим показателям. Поэтому необходимо очень аккуратно подходить к добавлению новых входов. На входы нейросетей можно подавать самую разнообразную информацию, как дискретную (различные события) так и непрерывную (цены, индексы, индикаторы). Наиболее значимыми входами являются индика-

торы технического анализа и различные фондовые индексы.

Большой проблемой при определении состава входов является определение глубины «погружения» – размера временного окна, данные из которого подаются на вход нейросети. Возникает вопрос, сколько баров истории подавать на вход, чтобы качественно обучить нейросеть? Эта величина определяется только из собственного опыта и должна быть адекватной прогнозируемому периоду. Например, при дневных прогнозах разумная глубина погружения находится в пределах 5-20 дней.

Необходимо отметить, что многие популярные нейропакеты имеют функцию определения чувствительности по входам, которая рекомендуется разработчиками пакетов как универсальный способ отсеивания «лишних» входов. Хотя эта функция является полезной при определении состава входов, ее автоматическое использование может принести больше вреда, чем пользы. Это обусловлено тем, что проблема определения чувствительности по входам для многослойных нейронных сетей пока математически не решена, и решается различными эмпирическими способами и алгоритмами. Поэтому рекомендуется пользоваться этой функцией с осторожностью и результаты проверять другими косвенными методами, например, статистическими.

ЗАКЛЮЧЕНИЕ

Предлагаемый алгоритм позволит скорректировать цену на прогнозируемый период, на основе графиков предыдущих цен и анализа новостей связанных с этим продуктом. Алгоритм не будет гарантировать предлагаемую им динамику цен со стопроцентной точностью, однако позволит минимизировать риски планирования продаж, предотвратить возможность случайного какого-либо ключевого фактора в процесс анализа и принятия решений.

1. Математические методы принятия решений / В. И. Бодров, Т. Я. Лазарева, Ю. Ф. Мартемьянов // Издательство ТГТУ, 2004
2. Machine Learning and Big Data Analytics Paradigms: Analysis, Applications and Challenges [1st ed. 2021] / A. E. Hassanien, A. Darwish. – Springer, 2021.
3. Осовский С. / Нейронные сети для обработки информации М.: Финансы и статистика, 2004.
4. S. M. Obraztsov , A. L. Shimkevich An Zero Order Minimization Algorithm Using a Neural Network // Proceedings of the International Joint Conference on Neural Networks, Washington. July 10-16. – 1999. – V. 1. – 1999. – P. 643-645.