

پیش‌بینی ظرفیت فعال خودروهای برقی در اتصال به شبکه‌های هوشمند با شبکه عصبی بیزین

سید پیمان موسوی مبارکه

گنورگ قره پتیان ، حسین عسکریان

پژوهشگاه نیرو

دانشگاه صنعتی امیرکبیر

Pmousavi@nri.ac.ir

Griptian@aut.ac.ir, Askarian@aut.ac.ir

چکیده:

هدف از این مقاله پیش‌بینی عملکرد خودروهای برقی در شبکه‌های هوشمند می‌باشد که می‌تواند در تخمین بار شبکه و تخصیص رزرو محلی مورد استفاده قرار گیرد. تا کنون روشهایی متعددی بمنظور پیش‌بینی بار مصرفی ارائه شده است که در هیچ یک از آنها تاثیر خودروهای برق در نظر گرفته نشده است. خودروهای برقی با داشتن ماهیت تزریق و شارژ انرژی به شبکه می‌توانند تاثیر بسزایی در ایجاد یا به هم زدن تعادل بار در منطقه داشته باشند و نیازمند طیف وسیعی از داده‌های ورودی برای تخمین آن خواهد بود و این موضوع موجب می‌گردد که با بدلیل فراوانی داده‌های مورد نیاز در بردارهای ورودی متفاوت امکان استفاده از سریهای زمانی و شبکه‌های عصبی ساده وجود نداشته باشد. از اینرو پیش‌بینی عملکرد خودروهای برق نیازمند روشهای می‌باشد که با تکیه بر محتوای احتمالاتی این خودروها نسبت به پیش‌بینی تزریق یا شارژ آنها مبادرت نماید، و بدین منظور در این مقاله از یک نوع شبکه عصبی احتمالاتی به نام شبکه عصبی بیزین که دارای قابلیت ارزش‌گذاری داده‌های محتمل بر مبنای داده‌های ورودی است استفاده می‌گردد تا با ارائه تابع احتمالی نرمال و یا حتی غیر نرمال برای هر ساعت به پیش‌بینی عملکرد این خودروها پرداخته شود.

واژه‌های کلیدی: خودروهای برقی، شبکه هوشمند، پیش‌بینی ظرفیت فعال، شبکه عصبی بیزین

1 - مقدمه:

امروزه با گسترش روز افزون خودروهای برقی بعد جدیدی به سیستمهای قدرت اضافه شده است که علاوه بر ساختار شبکه قدرت وابسته به ساختار

جغرافیای منطقه می‌باشد. این خودروها با امکان شارژ و دشارژ انرژی در شبکه تاثیر بسزایی در متعادل نمودن یا نا متعادل نمودن بر شبکه دارند. از این رو پیش‌بینی عملکرد این خودروها از اهمیت بسزایی در برنامه ریزی تولید و مدیریت بار شبکه برخوردار می‌باشد. تا کنون پیش‌بینی بار در شبکه‌های قدرت مبتنی بر بارهایی با جایگاه ثابت انجام می‌پذیرفته است اما با ورود این خودروها لازم است که عملکرد این خودروها در این حوزه مورد بررسی قرار گیرد. متدهای پیش‌بینی بار دارای قدمت زیادی بود و تا کنون روشهای مختلفی بدین منظور مورد استفاده قرار گرفته است که می‌توان آنها را در دودسته دسته بندی نمود. دسته اول روشهای مبتنی بر رگرسیون چند گانه، تجزیه طیفی، هموار سازی نمایی، فضای حالت و سری زمانی تصادفی بوده است [۲،۶] و دسته دوم روشهای متکی بر هوش مصنوعی همچون شبکه عصبی که جایگاه خاصی در این حوزه داشته و با رویکرد بیشتری همراه بوده است. اما با ورود خودروهای برقی و با وجود عدم قطعیتهای ناشی از تغییر مسیر حرکت و برنامه کاری خودروسواران لازم است که یک روش ترکیبی احتمالاتی و عصبی در این حوزه مورد استفاده قرار گیرد. یکی از متدهای که پیش از این در پیش‌بینی بارهای مصرفی مورد استفاده قرار گرفته است متد شبکه عصبی بیزین است که بر مبنای محتوای احتمالاتی داده‌ها و با تکیه بر روشهای مونت کارلو می‌باشد. در این روش بجای تکیه بر روی داده‌های نرمال با میانگین و واریانس مشخص از روشهای داده نگاری بهره‌گیری می‌شود که توانایی مدلسازی داده‌هایی با توزیع غیر نرمال را نیز خواهد داشت. در این مقاله با تکیه بر این متد به پیش‌بینی ظرفیت فعال خودروهای برق در شبکه پرداخته می‌شود.

۲- شبکه عصبی بیزین

بزرگ باشد، همواره در نواحی اشباع تابع تحریک نرون خواهیم بود و رفتار خروجی، براونی خواهد بود.

همچنین اگر معکوس واریانس توابع گوسی لایه مخفی به خروجی متناسب با تعداد نورونهای لایه مخفی باشد، می‌توان نورونهای لایه میانی را به هر تعداد زیاد کرد ولی شبکه دچار یادگیری بیش از حد نشود. در واقع با افزایش نورونهای لایه مخفی، واریانس وزنها لایه خروجی کاهش می‌یابد. ما نیز از ساده ترین و یکی از کارآمدترین توابع، یعنی تابع توزیع گوسی با میانگین صفر برای وزنها شبکه استفاده کرده و آن را به این شکل نمایش می‌دهیم

$$p(\underline{w}) = \frac{1}{Z_w(\alpha)} \exp\left(-\frac{\alpha}{2} \|\underline{w}\|^2\right) \quad (4)$$

که $Z_w(\alpha)$ ثابت نرمال سازی است و به گونه ای محاسبه می‌شود که $p(\underline{w})$ تابع توزیع باشد. در واقع تابع توزیع گوسی مانند فانکشنال تنظیم کاهش وزن عمل می‌کند. α نیز معکوس واریانس توزیع پیشین وزنها شبکه است و نقشی مشابه ضریب تنظیم را بر عهده دارد. از آنجا که این ضریب، کنترل توزیع پارامترهای دیگر مثل وزنها و بایاسها را بر عهده دارد، به آن ابر پارامتر^۵ می‌گویند.

$$E_w = \frac{1}{2} \|\underline{w}\|^2 = \frac{1}{2} \sum_{i=1}^N w_i^2 \quad (5)$$

N تعداد کل پارامترهای شبکه است. زمانی که $\|\underline{w}\|$ بزرگ باشد E_w بزرگ خواهد بود، لذا $p(\underline{w})$ کوچک می‌شود و به این معنا می‌باشد که بزرگ بودن وزنها شبکه دور از انتظار است. گوسی بودن تابع توزیع پیشین این مزیت را دارد که ثابت نرمال‌ساز آن به سادگی محاسبه می‌شود

$$Z_w(\alpha) = \left(\frac{2\pi}{\alpha}\right)^{N/2} \quad (6)$$

در قدم بعدی لازم است که مدلی برای نویز جمع شونده در خروجی در نظر بگیریم. در حالت کلی می‌توانیم، تابع احتمال وقوع $p(D|\underline{w})$ را به فرم نمایی زیر در نظر بگیریم

$$p(D | \underline{w}) = \frac{1}{Z_D(\beta)} \exp(-\beta E_D) \quad (7)$$

در E_D رابطه اخیر تابع خطا و β ابر پارامتر دیگری است که مدل نویز را کنترل می‌کند. $Z_D(\beta)$ نیز عامل نرمال ساز است و به طریق زیر محاسبه می‌شود

در یادگیری بیزین یک تابع توزیع احتمال روی فضای وزنها در نظر گرفته می‌شود که نشان دهنده میزان باور نسبی ما به مقادیر متفاوت وزنها شبکه می‌باشد. قبل از در نظر گرفتن داده های یادگیری، این باور توسط توزیع پیشین $p(\underline{w})$ روی وزنها شبکه بیان می‌شود.

$\underline{w} = [w_1, w_2, \dots, w_N]$ برداری شامل کلیه پارامترهای شبکه اعم از وزنها و بایاسها می‌باشد. اگر زوج داده های یادگیری $D = \{(\underline{x}_1, y_1), \dots, (\underline{x}_N, y_N)\}$ باشند، تابع توزیع پسین وزنها شبکه از روی قانون بیز به طریق زیر یافته می‌شود.

$$P(\underline{w}|D) = \frac{P(\underline{w})P(D|\underline{w})}{P(D)} \quad (2)$$

که مخرج کسر، عامل نرمال ساز است و می‌تواند به شکل زیر نوشته شود $P(D) = \int P(D|\underline{w})P(\underline{w}) d\underline{w}$ (3)

$P(D|\underline{w})$ نشان دهنده مدل نویز روی داده های خروجی است و معادل تابع احتمال وقوع^۶ است. روند یادگیری در روش بیزین به این شرح است که ابتدا با یک تابع توزیع پیشین روی وزنها شبکه شروع می‌کنیم. از آنجا که در این مرحله اطلاعات کمی راجع به مقدار وزنها داریم، این توزیع گسترده می‌باشد. با مشاهده داده ها و از طریق رابطه (۲) تابع توزیع پسین وزنها محاسبه می‌شود که گستردگی کمتری نسبت به قبل خواهد داشت. همانطور که مشخص است انتخاب تابع توزیع پیشین نقش مهمی در یادگیری بازی می‌کند.

۲-۱- تابع توزیع پیشین

تابع توزیع پیشین، بازتابی از ذهنیت قبلی ما راجع به مقادیری است که آن کمیت اختیار می‌کند. ولی در مورد وزنها شبکه های عصبی، ذهنیتی راجع به اینکه چه مقداری باید داشته باشند نداریم. برای شبکه عصبی با یک لایه مخفی که توابع تحریک تانژانت هیپربولیک دارند، استفاده از توزیع گوسی برای تابع توزیع پیشین وزنها لایه مخفی به خروجی، به یک پروسه گوسی^۷ برای تابع خروجی منجر خواهد شد. این پروسه، با توجه به واریانس توزیع پیشین گوسی وزنها لایه ورودی به لایه مخفی، می‌تواند هموار^۸، براونی^۹ و یا قسمتی براونی^{۱۰} باشد. اگر مقدار این واریانس خیلی

1 Likelihood function
2 Gaussian process
3 Smooth
4 Brownian

5 Fractional Brownian
6 Hyper parameter

$$p(\underline{w}|D) = \frac{1}{Z_S(\alpha, \beta)} \exp(-\beta E_D - \alpha E_w) \quad (13) \quad Z_D(\beta) = \int \exp(-\beta E_D) dD \quad (8)$$


$$= \frac{1}{Z_S(\alpha, \beta)} \exp(-S(\underline{w}))$$

که در آن Z_S ثابت نرمال ساز است و S نیز عبارتست از

$$S(\underline{w}) = \beta E_D + \alpha E_w = \quad (14)$$

$$\frac{\beta}{2} \sum_{i=1}^n (y_i - f(\underline{x}_i, \underline{w}))^2 + \frac{\alpha}{2} \sum_{i=1}^N w_i^2$$

در این مرحله یافتن یک مقدار یکتا (w_{MP}) به عنوان بهترین وزن شبکه، معادل حداقل کردن مجموع مربعات خطا به همراه فانکشنال تنظیم کاهش وزن است. با دقت در عبارت (۱۴) ملاحظه می‌شود که مقدار بخش اول، با افزایش داده‌های یادگیری زیاد می‌شود، در صورتیکه بخش دوم ثابت باقی می‌ماند. بنابراین می‌توان گفت که اگر α, β ثابت باشند، با افزایش داده‌های یادگیری تخمین w_{MP} به سمت w_{MP} خواهد رفت ولی اگر تعداد داده‌های یادگیری کم باشد، بخش دوم عبارت (۱۴) که مربوط به دانش قبلی در مورد وزنه‌های شبکه است نقش زیادی در یافتن w_{MP} بازی خواهد کرد. یادگیری بیزین با توابع توزیع گوسی پیشین را می‌توان به صورت شماتیک به صورت شکل (۱) نمایش داد. همانطور که دیده می‌شود، واریانس تابع پسین نسبت به پیشین کاهش یافته است. مقدار w_{MP} جایی است که توزیع پسین حداکثر می‌شود. ولی در عمل ممکن است این توزیع بیش از یک مقدار بیشینه داشته باشد.



شکل ۱: یادگیری بیزین برای وزنه‌های شبکه

۲-۳- تابع توزیع خروجی شبکه

در چارچوب بیزین شبکه آموزش دیده با تابع پسین، خروجی شبکه نیز به صورت تابع توزیع خواهد بود. اگر ورودی تست \underline{x}_{n+1} باشد، خروجی آن برابر خواهد بود با

اگر نویز جمع شونده در خروجی را گوسی در نظر بگیریم، برای یک زوج داده یادگیری مثل (y, x) می‌توان نوشت

$$p(y | x, w) \propto \exp\left(-\frac{\beta}{2} (y - f(x, w))^2\right) \quad (9)$$

که f نشان دهنده نگاشتی از فضای ورودی به خروجی شبکه عصبی است. β معکوس واریانس نویز است و از همین طریق مدل نویز را کنترل می‌کند. اگر برای همه داده‌ها نویز را گوسی و آنها را مستقل از هم فرض کنیم، می‌توان نوشت

$$p(D|\underline{w}) = \prod_{i=1}^n p(y_i | \underline{x}_i, \underline{w}) = \frac{1}{Z_D(b)} \exp\left(-\frac{b}{2} \sum_{i=1}^n (y_i - f(\underline{x}_i, \underline{w}))^2\right) \quad (10)$$

همانطور که مشاهده می‌شود، با فرض نویز گوسی در خروجی شبکه، تابع خطای E_D به صورت مجموع مربعات خطا روی داده‌های یادگیری خواهد بود. ثابت نرمال‌ساز نیز برابر خواهد بود با

$$Z_D(\beta) = \left(\frac{2\pi}{\beta}\right)^{n/2} \quad (11)$$

اکنون می‌توان نشان داد که روش مرسوم یادگیری در شبکه‌های عصبی که با استفاده از الگوریتم‌های مبتنی بر گرادیان، تابع هزینه را حداقل می‌کند و به نوعی بیانگر تخمین بیشترین احتمال وقوع (w_{ML}) می‌باشد، فقط از اطلاعات $p(D|\underline{w})$ استفاده می‌کند. این مطلب را می‌توان با یافتن تابع احتمال وقوع نشان داد

$$L(\underline{w}) = \ln p(D|\underline{w}) = -\sum_{i=1}^n \frac{\beta}{2} |y_i - f(\underline{x}_i, \underline{w})|^2 + C \quad (12)$$

C ثابتی است که به w بستگی ندارد. حداکثر کردن این تابع، در واقع همان حداقل کردن مجموع مربعات خطا می‌باشد.

۲-۲- تابع توزیع پسین

برای یافتن تابع توزیع پسین وزنه‌های شبکه، کافی است که روابط (۴) و (۱۰) را در قانون بیز (۲) جایگذاری کنیم. در اینصورت داریم

و g گرادیان تابع f در w_{MP} است. عبارت ۲۶ از دو بخش تشکیل شده است. بخش اول به مشخصات نویز خروجی بستگی دارد و بخش دوم آن ناشی از عرض تابع توزیع پسین پارامترهای شبکه است. اگر نویز خروجی خیلی زیاد (یعنی β کم باشد) و یا توزیع پسین خیلی باریک باشد، در اینصورت عامل غالب بخش اول است و واریانس تابع توزیع پیش بینی خروجی توسط واریانس نویز تعیین می‌شود. ولی اگر میزان نویز کم (β بزرگ) و یا توزیع پسین خیلی گسترده باشد، در اینصورت عامل غالب بخش دوم بوده و واریانس تابع توزیع پیش بینی خروجی توسط عرض توزیع پسین مشخص می‌گردد. در هر صورت نکته مهم این است که برخلاف روشهای قبلی که یک وزن بهینه را در نظر می‌گرفتند، در اینجا طبق رابطه (۲۰) اثر همه وزنها در محاسبه خروجی دخالت داده می‌شود. در حالی نیز که از تقریب گوسی استفاده می‌شود، ابتدا با حداقل کردن تابع خطای $S(w)$ ، وزن w_{MP} یافته می‌شود، سپس از طریق رابطه (۲۰) واریانس تابع توزیع پیش‌بینی خروجی محاسبه می‌شود.

۳- شبکه مورد مطالعه

شبکه مورد مطالعه از مرجع [1] انتخاب گردیده است. در این شبکه ۱۰۰۰ دستگاه خودرو برقی در سه نوع متفاوت زیر وجود دارد:

| | Power Capacity | Plug-in-Probability |
|-----------|----------------|---------------------|
| Vehicle#1 | 3.3 kw | 0.4 |
| Vehicle#2 | 6.6 kw | 0.5 |
| Vehicle#3 | 19.2 kw | 0.1 |

در این حالت احتمال توامان خودروها بصورت ذیل می‌گردد

| Possible APC Instances KW | Probability |
|---------------------------|-------------|
| . | 0.27 |
| V1only | 0.18 |
| V2only | 0.27 |
| V3only | 0.03 |
| V1& V2 | 0.18 |
| V1& V3 | 0.02 |
| V2& V3 | 0.03 |
| V1& V2&V3 | 0.02 |

جدول احتمالاتی اتصال هر یک از این خودروها در هر ساعت از یک هفته

به قرار ذیل است:

| Hour | Sun | Mon | Tue | Wed | Thu | Fri | Sat |
|---------|------|------|------|------|------|------|------|
| 0am-1am | 0.90 | 0.95 | 1.00 | 0.99 | 1.00 | 0.95 | 0.75 |
| 1am-2am | 0.95 | 0.95 | 0.98 | 1.00 | 1.00 | 1.00 | 0.85 |
| ... | ... | ... | ... | ... | ... | ... | ... |

$$P(y_{n+1} | \underline{x}_{n+1}, D) = \quad (20)$$

$$\int_{R^N} P(y_{n+1} | \underline{x}_{n+1}, D, \underline{w}) P(\underline{w} | D, \underline{x}_{n+1}) d\underline{w}$$

چون تابع توزیع پسین فقط از روی داده های یادگیری به دست می‌آید، بنابراین داریم

$$P(\underline{w} | D, \underline{x}_{n+1}) = P(\underline{w} | D) \quad (21)$$

با توجه به رابطه اخیر، می‌توانیم رابطه (۲۰) را بازنویسی کنیم

$$P(y_{n+1} | \underline{x}_{n+1}, D) = \quad (22)$$

$$\int_{R^N} P(y_{n+1} | \underline{x}_{n+1}, D, \underline{w}) P(\underline{w} | D) d\underline{w}$$

عبارت اول داخل انتگرال، همان مدل نویز برای داده تست بوده که در رابطه (۹) بیان شد و عبارت دوم نیز تابع توزیع پسین وزنها شبکه می‌باشد.

می‌توانیم میانگین تابع اخیر را به عنوان خروجی نقطه ای در نظر بگیریم

$$\hat{y} = E\{P(y_{n+1} | \underline{x}_{n+1}, D)\} = \quad (23)$$

$$\int_{R^N} f(\underline{x}_{n+1}, \underline{w}) P(\underline{w} | D) d\underline{w}$$

برای محاسبه تابع توزیع پیش بینی خروجی (رابطه ۲۲) به کمک تقریب گوسی (رابطه ۱۷) می‌توانیم بنویسیم

$$P(y_{n+1} | \underline{x}_{n+1}, D) \approx \quad (24)$$

$$\int_{R^N} \exp\left(-\frac{\beta}{2}(y_{n+1} - f(\underline{x}_{n+1}, \underline{w}))^2\right) \times$$

$$\exp\left(-\frac{1}{2}\Delta \underline{w}^T A \Delta \underline{w}\right) d\underline{w}$$

اگر عرض تابع توزیع پسین را خیلی باریک فرض کنیم، می‌توانیم از تقریب

مرتبه اول تابع غیرخطی f ، حول w_{MP} استفاده کنیم. به این ترتیب

می‌توانیم رابطه ۲۴ را به این شکل بنویسیم


$$P(y_{n+1} | \underline{x}_{n+1}, D) = \quad (25)$$

$$\frac{1}{(2\pi\sigma^2)^{1/2}} \exp\left(-\frac{(y_{n+1} - f(\underline{x}_{n+1}, \underline{w}_{MP}))^2}{2\sigma^2}\right)$$

که در آن واریانس برابر است با


$$\sigma^2 = \frac{1}{\beta} + g^T A^{-1} g \quad (26)$$

در شکل (۱) تفاوت بین نتایج پیش‌بینی و روز مورد نظر ارائه شده است.



شکل (۱) مقایسه نتایج و مقادیر حقیقی

در شکل (۲) برای ساعات ۲۱، ۲۲، ۲۳، ۲۴ منحنی تابع احتمالاتی بیزین آن روز ارائه شده است.



شکل (۲) تابع احتمال ظرفیت در ساعات ۲۱ تا ۲۴

۵- نتیجه گیری

از آنجایی که با گسترش روز افزون خودروهای برقی، تاثیر این خودروها بیش از پیش در شبکه مشاهده می‌گردد از اینرو مدلسازی خودروهای برقی تاثیر بسزایی در پیش‌بینی صحیح بار و تخصیص رزرو شبکه خواهد داشت. در این مقاله سعی گردید با تکیه بر یک متد احتمالاتی متکی بر شبکه عصبی با وزن دهی به داده های ورودی به پیش‌بینی دقیقتری از عملکرد این خودروها پرداخته شود و علاوه بر پیش‌بینی میانگین و انحراف معیار تخصیص ظرفیت فعال آنها در شبکه

| | | | | | | | |
|-----------|------|------|------|------|------|------|------|
| 6am-7am | 0.90 | 0.70 | 0.21 | 0.80 | 0.95 | 0.95 | 0.35 |
| 7am-8am | 0.25 | 0.00 | 0.00 | 0.15 | 0.75 | 0.70 | 0.45 |
| 8am-9am | 0.65 | 0.30 | 0.62 | 0.00 | 0.05 | 0.20 | 0.76 |
| ... | ... | ... | ... | ... | ... | ... | ... |
| 1pm-2pm | 0.33 | 0.70 | 0.93 | 0.95 | 0.10 | 0.15 | 0.25 |
| ... | ... | ... | ... | ... | ... | ... | ... |
| 9pm-10pm | 0.45 | 0.15 | 0.83 | 0.75 | 0.30 | 0.40 | 0.45 |
| 10pm-11pm | 0.80 | 0.45 | 0.87 | 0.85 | 0.30 | 0.45 | 0.45 |
| 11pm-12pm | 0.97 | 0.80 | 0.90 | 0.95 | 0.90 | 0.92 | 0.56 |

در حقیقت از آنجایی که بنا بر مرجع [۱] مثلاً شارژ یک باطری ۱۶ کیلوواتی با ولتاژ ۲۴۰ ولت و ۴ ساعت و با ولتاژ ۱۲۰ ولت ۱۰ ساعت بطول می‌انجامد، از این رو خودروها برقی نمی‌توانند در لحظه اتصال به شبکه تمامی ظرفیت فعال خود را در اختیار سیستم گذاشته و این ظرفیت در بازه صفر تا ۳ کیلووات است. در این مثال خودروها از دیدگاه شارژ خودرو به صورت ذیل تقسیم می‌گردد

| | | | | | | |
|---------|---------|---------|---------|-----|---------|-----|
| ... | 0.3~0.4 | 0.4~0.5 | 0.4~0.5 | ... | 0.9~1.0 | |
| 0.0~0.2 | ... | 0 | 0 | ... | 0 | |
| ... | ... | ... | ... | ... | ... | |
| 1.8~2.0 | ... | 4 | 6 | 9 | ... | 6 |
| 2.0~2.2 | ... | 10 | 17 | 16 | ... | 10 |
| 2.2~2.4 | ... | 9 | 10 | 28 | ... | 14 |
| ... | ... | ... | ... | ... | ... | ... |
| 2.6~2.8 | ... | 3 | 2 | 2 | ... | 2 |
| 2.8~3.0 | ... | 0 | 1 | 1 | ... | 0 |

۴- نتایج پیش‌بینی ظرفیت فعال خودروهای برقی

بمنظور شبیه سازی شبکه عصبی بیزین، از محیط مطلب استفاده گردید. در این مطالعه از اطلاعات موجود برای پیش‌بینی ظرفیت فعال خودروهای برقی استفاده شده است نتایج حاصل برای ۲۴ ساعت روز شنبه پیش‌بینی و با داده‌های این روز ارائه گردیده است. علاوه بر پیش‌بینی میانگین داده‌ها، شبکه عصبی بیزین برای هر ساعت منحنی احتمالاتی متناسب با آن ساعت را نیز ارائه می‌کند.

| Hour | CapacityMW | Hour | CapacityMW |
|------|------------|------|------------|
| 1 | 967.56 | 13 | 152.77 |
| 2 | 1018.49 | 14 | 152.77 |
| 3 | 1018.49 | 15 | 152.77 |
| 4 | 1018.49 | 16 | 152.77 |
| 5 | 1018.49 | 17 | 152.77 |
| 6 | 1018.49 | 18 | 152.77 |
| 7 | 967.56 | 19 | 152.77 |
| 8 | 712.94 | 20 | 152.77 |
| 9 | 203.70 | 21 | 152.77 |
| 10 | 203.70 | 22 | 407.40 |
| 11 | 203.70 | 23 | 458.32 |
| 12 | 203.70 | 24 | 937.01 |

نسبت به ارائه یک تابع احتمالاتی بدون محدودیت نرمال بودن پرداخت. تابعی که می‌تواند پس از این به منظور مدیریت ریسک و یا ارزش ریسک در ادامه کار مورد بهره‌گیری قرار گیرد.

مراجع :

- [1] Estimation of Achievable Power Capacity From Plug-in Electric Vehicles for V2G Frequency Regulation: Case Studies for Market Participation Sekyung Han, IEEE TransElectronics, vol. 11, no. 2, , Feb. 2011
- [2]H. Lund and W. Kempton, "Integration of renewable energy into the transport and electricity sectors through V2G," Energy Policy, vol. 36, pp. 3578–3587, Sep. 2008.
- [3]T. B. Gage, "Final report: Development and evaluation of a plug-in HEV with vehicle-to-grid power flow," AC Propulsion, Inc., Dec. 2003.
- [4] W. Kempton and S. E. Letendre, "Electric vehicles as a new power source for electric utilities," Transp. Res.-D, vol. 2, no. 3, pp. 157–175, 1997.
- [5] S. E. Letendre and W. Kempton, "The V2G concept: A new model for power?," Public Utilities Fortnightly, pp. 16–26, 2002.
- [6] W. Kempton, J. Tomic, S. Letendre, A. Brooks, and T. Lipman, "Vehicle-to-grid power: Battery, hybrid and fuel cell vehicles as resources for Distributed Electric Power in California," CARB, CEPA, L.A. Dept. of Water and Power, Electric Transportation Program, , 2001.
- [7] W. Kempton and T. Kubo, "Electric-drive vehicles for peak power in Japan," Energy Policy, vol. 28, pp. 9–18, 2000.
- [6]G. Zhang, B. E. Patuwo, and M.Y. Hu, "Forecasting with artificial neural networks: The state of the art", Elsevier, Int. J. Forecast., vol. 14, pp. 35–62, 1998.
- [7]L. Gorr, "Research prospective on neural network forecasting", International Journal of Forecasting, Vol. 10, pp. 1–4, 2004.
- [8]F. Acernese, R. de rosa, L. milano, "A hierarchical Bayesian learning framework for autoregressive neural network modeling of time series", IEEE Proceedings of 3rd international Symposium on image and signal processing, 2003
- [9]F. Acernese, A. eleuteri, I. milano, "A hierarchical Bayesian learning scheme for autoregressive neural network: application to the CATS benchmark", IEEE Proceeding